



Universidade Federal da Paraíba
Centro de Tecnologia
Programa de Pós-graduação em Engenharia Mecânica
- Mestrado - Doutorado

**DIAGNÓSTICO DE FALHAS EM ROLAMENTOS
DE MOTORES DE INDUÇÃO TRIFÁSICOS VIA
ABORDAGEM DENSIDADE DE MÁXIMOS A
PARTIR DO SINAL DA CORRENTE DO ESTATOR**

Por

JULIO CESAR DA SILVA

*Tese de doutorado apresentada à Universidade Federal da Paraíba para
obtenção do grau de Doutor*

JULIO CESAR DA SILVA

**DIAGNÓSTICO DE FALHAS EM ROLAMENTOS DE
MOTORES DE INDUÇÃO TRIFÁSICOS VIA
ABORDAGEM DENSIDADE DE MÁXIMOS A
PARTIR DO SINAL DA CORRENTE DO ESTATOR**

Tese apresentada ao Programa de Pós-graduação em Engenharia Mecânica da Universidade Federal da Paraíba, em cumprimento às exigências para obtenção do Grau de Doutor.

Orientador: Prof. Dr. Abel Cavalcante Lima Filho

Catálogo na publicação
Seção de Catalogação e Classificação

S586d Silva, Julio Cesar da.

Diagnóstico de falhas em rolamentos de motores de indução trifásicos via abordagem densidade de máximos a partir do sinal da corrente do estator / Julio Cesar da Silva. - João Pessoa, 2024.

210 f. : il.

Orientação: Abel Cavalcante Lima Filho.

Tese (Doutorado) - UFPB/CT.

1. Motor de indução trifásico. 2. Rolamento. 3. Corrente do estator. 4. Teoria do caos. I. Lima Filho, Abel Cavalcante. II. Título.

UFPB/BC

CDU 621.313.333(043)



Universidade Federal da Paraíba
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia Mecânica
Mestrado e Doutorado

1 ATA DA DEFESA PÚBLICA DE TESE DE DOUTORADO DO ALUNO **JULIO CESAR DA SILVA** DO
2 PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA DO CENTRO DE TECNOLOGIA DA
3 UNIVERSIDADE FEDERAL DA PARAÍBA. Aos vinte (20) dias do mês de junho do ano de dois mil e vinte e
4 quatro (2024), às **9h**, por videoconferência, teve lugar a apresentação da **Tese de Doutorado** intitulada
5 **“DIAGNÓSTICO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO TRIFÁSICOS VIA**
6 **ABORDAGEM DENSIDADE DE MÁXIMOS A PARTIR DO SINAL DA CORRENTE DO ESTATOR”** pelo
7 aluno JULIO CESAR DA SILVA, com vistas à obtenção do título de Doutor em Engenharia Mecânica. A
8 Comissão Examinadora foi composta pelos seguintes professores: Dr. Abel Cavalcante Lima Filho – UFPB
9 (Orientador), Dr. Francisco Antônio Belo – UFPB (Examinador Interno), Dr. Marcelo Cavalcanti Rodrigues –
10 UFPB (Examinador Interno), Dr. Thyago Leite de Vasconcelos Lima – IFPB (Examinador Externo) e Dr.
11 Carlos Alberto Nóbrega Sobrinho – IFPB (Examinador Externo). Instalada a Banca Examinadora, o Senhor
12 Presidente passou a palavra ao aluno para apresentar a defesa do seu trabalho de tese e este iniciou a
13 apresentação declarando perante a Banca Examinadora e o público presente que o trabalho apresentado é
14 original e de sua autoria. A exposição oral iniciou às **9h**, sendo concluída às **9h49**. Logo a seguir, iniciou-se
15 a arguição pelos examinadores, finalizada às **11h30**. Em seguida, o Senhor Presidente convidou a Banca
16 Examinadora a reunir-se reservadamente para deliberação. Concluída a Reunião, o Senhor Presidente
17 convocou o aluno e demais presentes para proclamar o resultado, tendo sido atribuído, por unanimidade, ao
18 doutorando o conceito Aprovado nos termos do Regulamento Geral dos Cursos e Programas de Pós-
19 Graduação Stricto Sensu da Universidade Federal da Paraíba (Resolução N° 34/2014/CONSEPE) e do
20 Regulamento do Programa de Pós-Graduação em Engenharia Mecânica do Centro de Tecnologia da
21 Universidade Federal da Paraíba (Resolução N° 13/2019/CONSEPE). Ao final da sessão, após os
22 agradecimentos por parte do aluno, o Senhor Presidente, por recomendação dos membros da Banca,
23 estabeleceu um prazo máximo de **30 (trinta)** dias para o doutorando providenciar as correções
24 recomendadas, ficando a emissão do diploma condicionada a essas retificações que serão verificadas pelo
25 orientador. Às **11h50**, o Senhor Presidente encerrou os trabalhos, determinando a leitura para fins de
26 aprovação e a lavratura da presente ata que vai assinada por todos os membros da Comissão
27 Examinadora.

João Pessoa, 20 de junho de 2024.

Prof. Dr. Abel Cavalcante Lima Filho
Orientador

Prof. Dr. Francisco Antônio Belo
Examinador Interno

Documento assinado digitalmente



THYAGO LEITE DE VASCONCELOS LIMA
Data: 26/06/2024 17:01:48-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Marcelo Cavalcanti Rodrigues
Examinador Interno

Prof. Dr. Thyago Leite de Vasconcelos Lima
Examinador Externo

Documento assinado digitalmente



CARLOS ALBERTO NOBREGA SOBRINHO
Data: 09/07/2024 07:24:56-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Carlos Alberto Nóbrega Sobrinho
Examinador Externo

DEDICATÓRIA

A Deus pelo dom da vida. A minha mãe, Maria Aparecida da Silva por todo o sacrifício e empenho em prover as condições necessárias (muitas vezes renunciando suas próprias necessidades) para que eu pudesse continuar estudando. A minha outra mãe-avó Santana Dias da Silva por todas as palavras de motivação e pelas orações. A meu pai-avô, Paulo José da Silva pela compreensão e incentivos.

AGRADECIMENTOS

A Deus por todas as graças alcançadas. Ao meu orientador professor Dr. Abel Cavalcante Lima Filho pelos incentivos, ajuda e por estar sempre disponível para sanar dúvidas. Ao professor Dr. Francisco Antônio Belo pelas conversas frutíferas, conselhos e ajuda. Aos professores: Dr. Marcelo Cavalcanti Rodrigues, Dr. Thyago Leite de Vasconcelos Lima e Dr. Carlos Alberto Nóbrega Sobrinho, pela ajuda e disponibilidade em avaliar este trabalho.

A minha namorada Anne Louise, pelos incentivos constantes, ajuda e pela compreensão.

Aos amigos, Álef Gomes, Nayara Formiga, Marlio Antonio e Hugo Pimentel, pelas palavras de incentivo e conhecimentos compartilhados.

A José Anselmo pela ajuda nos mais diversos cenários seja na parte experimental do trabalho seja no dia a dia. A Ricardo C. Soares pela ajuda e incentivos. A Rômulo Damião pela ajuda.

Aos amigos de laboratório do GPICEEMA: Anderson, Pedro Bichara, Renan Arruda, Paulo Almeida, Marcos Ramon, Flávio, Kalleby Rocha, Luiz, Rachel, Eduardo, Thiago, Elimar e Edgard Vieira. A Fábio Araújo de Lima, pelo incentivo e ajuda, a Manoel Brasileiro e Marceu Adissi.

Em especial a Diógenes Montenegro pela ajuda nas montagens elétricas e eletrônicas realizadas na bancada de testes, pelo incentivo e pelas conversas frutíferas. Agradeço também aos técnicos mecânicos: Sergio, Gustavo e Arthur. Também estendo os agradecimentos a Josivan Paz e Jackson Farias pelo suporte nas montagens mecânicas.

A todos os professores do corpo docente do PPGEM da UFPB.

A coordenação do PPGEM pela ajuda e suporte, em especial a Mônica Rodrigues da Silva pela disponibilidade e ajuda nas questões burocráticas, a Rosângela e a Thiago.

Aos funcionários da limpeza nas pessoas de Carla e seu Nildo. As secretárias: Lia e Eliane.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 (Portaria nº 206, de 4 de setembro de 2018).

DIAGNÓSTICO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO TRIFÁSICOS VIA DENSIDADE DOS MÁXIMOS A PARTIR DO SINAL DA CORRENTE DO ESTATOR

RESUMO

Os motores de indução trifásicos (MITs) são amplamente utilizados na indústria devido à sua confiabilidade, robustez e baixo custo, sendo a principal força motriz no setor industrial. Falhas em rolamentos representam mais de 40% das falhas em motores de indução, resultando em paradas inesperadas, aumento dos custos de produção e possíveis acidentes. Neste contexto, este trabalho propõe um novo método não invasivo para o diagnóstico de falhas em rolamentos de MITs, utilizando a análise da corrente do estator combinada com a técnica SAC-DM (*Signal Analysis based on Chaos using Density of Maxima*) e uma rede neural artificial do tipo MLP (*Multilayer Perceptron*). Para comparação, foram implementados dois métodos adicionais que utilizam sinais de vibração mecânica e sonora emitidos pelo MIT, juntamente com a técnica do envelope de Hilbert. Os sinais foram coletados simultaneamente sob seis condições de carga: 0%, 20%, 40%, 60%, 80% e 100% da carga nominal. Foram analisadas condições de rolamento saudável, com falha na pista externa, pista interna e falha mista. Para a falha na pista externa, a análise dos sinais de vibração apresentou um erro relativo percentual máximo de 0,60%, enquanto para o som o erro foi de 0,53%. Para a falha na pista interna, o erro relativo percentual máximo foi de 0,49% para vibração e 0,36% para o som. O novo método proposto, utilizando SAC-DM, detectou falhas nos rolamentos com uma acurácia de classificação de 96,82%, mesmo com o motor operando sob carga variável. Esta nova metodologia pode, portanto, contribuir significativamente para o diagnóstico de falhas em rolamentos de MITs, oferecendo uma alternativa mais eficiente e não invasiva em comparação com os métodos tradicionais.

Palavras-Chave: Motor de indução trifásico, rolamento, corrente do estator, teoria do caos.

FAULT DIAGNOSIS IN BEARINGS OF THREE-PHASE INDUCTION MOTORS THROUGH THE MAXIMUM DENSITY FROM THE CURRENT SIGNAL

ABSTRACT

Three-phase induction motors (TIMs) are widely used in the industry due to their reliability, robustness, and low cost, being the main driving force in the industrial sector. Bearing failures account for more than 40% of induction motor failures, resulting in unexpected downtimes, increased production costs, and potential accidents. In this context, this work proposes a new non-invasive method for diagnosing bearing failures in TIMs, using stator current analysis combined with the SAC-DM (Signal Analysis based on Chaos using Density of Maxima) technique and a Multilayer Perceptron (MLP) artificial neural network. For comparison, two additional methods were implemented that use mechanical vibration and sound signals emitted by the TIM, together with the Hilbert envelope technique. The signals were collected simultaneously under six load conditions: 0%, 20%, 40%, 60%, 80%, and 100% of the nominal load. Conditions of healthy bearings, outer race failure, inner race failure, and mixed failure were analyzed. For outer race failure, the vibration signal analysis showed a maximum relative percentage error of 0.60%, while for sound the error was 0.53%. For inner race failure, the maximum relative percentage error was 0.49% for vibration and 0.36% for sound. The proposed new method, using SAC-DM, detected bearing failures with a classification accuracy of 96.82%, even with the motor operating under variable load. This new methodology can, therefore, significantly contribute to the diagnosis of bearing failures in TIMs, offering a more efficient and non-invasive alternative compared to traditional methods.

Keywords: Three-phase induction motor, bearing, stator current, chaos theory.

SUMÁRIO

CAPÍTULO I	1
1. INTRODUÇÃO.....	1
1.1. ESTADO DA ARTE	3
1.1.1. Técnicas relacionadas aos sinais de vibração mecânica e sonora	3
1.1.2. Técnicas relacionadas ao sinal de corrente do estator.	11
1.2. MOTIVAÇÃO	17
1.3. HIPÓTESES	19
1.4. OBJETIVOS	19
1.4.1. Objetivo geral	19
1.4.2. Objetivos específicos	19
1.5. ORGANIZAÇÃO DO TRABALHO.....	20
CAPÍTULO II	21
2. FUNDAMENTAÇÃO TEÓRICA	21
2.1. MOTOR DE INDUÇÃO TRIFÁSICO.....	21
2.2. ROLAMENTOS	24
2.2.1. Principais tipos de rolamentos.....	26
2.2.2. Principais causas de falhas em rolamentos.....	27
2.3. TÉCNICAS UTILIZADAS NA DETECÇÃO DE FALHAS EM ROLAMENTOS	30
2.3.1. Detecção de falhas via vibração mecânica	33
2.3.2. Análise de falha via sinal sonoro.....	36
2.3.3. Detecção de falha via MCSA	36

2.3.4.	Detecção de falhas via análise termográfica.....	39
CAPITULO III		41
3.	TÉCNICAS DE PROCESSAMENTO DE SINAIS E ANÁLISE DO CAOS.....	41
3.1.	TIPOS DE SINAIS E SUAS CLASSIFICAÇÕES	41
3.1.1.	Classificação dos sinais	41
3.1.2.	Formas de ondas do sinal	43
3.1.3.	Taxa de amostragem.....	45
3.2.	TRANSFORMADA RÁPIDA DE FOURIER	46
3.3.	TÉCNICA DO ENVELOPE.....	50
3.4.	REDES NEURAIAS ARTIFICIAIS	54
3.4.1.	Redes <i>perceptron</i> de múltiplas camadas (PMC)	56
3.4.2.	Funções de ativação.....	58
3.4.3.	Funções de custo.....	61
3.4.4.	Algoritmos de otimização.....	62
3.4.5.	Overfitting e underfitting.....	71
3.4.6.	Matriz de confusão	73
3.5.	ALGUNS CONCEITOS SOBRE O CAOS	74
3.5.1.	Breve Histórico sobre o caos	75
3.5.2.	Pêndulo duplo.....	79
3.6.	TESTES PARA O DETERMINISMO	83
3.6.1.	Teste da árvore de símbolos	84
3.6.2.	Método do Teste 0-1 para detecção de Caos	88
3.6.3.	Método do comprimento de correlação	92
3.6.4.	Análise de sinal baseado no caos usando densidade de máximos.....	95
CAPITULO IV		100
4.	MATERIAIS E MÉTODOS.....	100
4.1.	BANCADA DE TORQUE CONTROLÁVEL.....	100

4.1.1.	Acionamento do motor de indução.....	103
4.1.2.	Motor CC e seu acionamento	105
4.1.3.	Circuito Elétrico de Frenagem Eletromagnética do Motor CC	106
4.1.4.	Sistemas de medição.....	108
4.2.	PREPARAÇÃO DAS FALHAS SIMULADAS NO ROLAMENTO	113
4.3.	Banco de dados	118
4.3.1.	Metodologia de análise de falha utilizando os sinais de vibração e sinais acústicos.	120
4.3.2.	Detecção das frequências características de falha usando o método MCSA	122
4.3.3.	Detecção das falhas através do método SAC-DM.....	123
CAPITULO V		126
5.	RESULTADOS E DISCUSSÕES.....	126
5.1.	DETECÇÕES DAS FREQUÊNCIAS DE FALHA POR MEIO DO SINAL DE VIBRAÇÃO	126
5.1.1.	Análise da falha na pista externa (BPFO)	127
5.1.2.	Análise da falha na pista interna (BPFI).....	131
5.1.3.	Análise da falha mista (BPFO e BPFI).....	132
5.2.	DETECÇÕES DAS FREQUÊNCIAS DE FALHA POR MEIO DO SINAL ACÚSTICO	134
5.2.1.	Análise da falha na pista externa (BPFO)	135
5.2.2.	Análise de falha na pista interna (BPFI).....	138
5.2.3.	Análise de falha mista (BPFI e BPFO).....	140
5.3.	COMPARAÇÃO ENTRE OS SINAIS DE VIBRAÇÃO MECÂNICA E SONORA EMITIDOS PELO MIT	142
5.3.1.	Comparação de resultados para a falha na pista externa (BPFO).....	142
5.3.2.	Comparação de resultados para a falha na pista interna (BPFI).....	147

5.4. DETECÇÕES DAS FREQUÊNCIAS DE FALHA POR MEIO DO SINAL DA CORRENTE	151
5.4.1. Detecção das frequências de falha na pista externa (BPFO).....	152
5.4.2. Detecção das frequências de falha na pista interna (BPFI)	157
5.5. MÉTODO PROPOSTO SAC-DM	161
5.5.1. Teste da árvore de símbolos	163
5.5.2. Teste 0-1	164
5.5.3. Teste da autocorrelação para o caos	165
5.5.4. Detecção das falhas pelo método SAC-DM.....	166
5.5.5-Rede Neural Perceptron Multicamadas.....	174
CAPITULO VI.....	177
6. CONSIDERAÇÕES FINAIS	177
6.1. Sugestões de trabalhos futuros.....	179
REFERÊNCIAS	180

LISTA DE FIGURAS

Figura 1.1- Principais tipos de falhas em motores de indução (Fonte: Adaptado de (CHOUDHARY <i>et al.</i> , 2019)).....	17
Figura 2.1- Classificação dos tipos de motores de indução trifásicos (Fonte: WEG, 2023)	21
Figura 2.2- Componentes do MIT (Fonte: Adaptado de (WEG, 2023))	22
Figura 2.3 – Rolamento rígido de esferas e seus principais componentes.	25
Figura 2.4- Tipos de rolamentos a) Rolamento rígido de esferas, b) rolamento axial de esferas, c) rolamento de rolos cilíndricos, d) rolamento axial de rolos cilíndrico. (Fonte: (SKF, 2015)).....	26
Figura 2.5- Principais causas de falhas em rolamentos (Fonte: (SKF, 2022))	27
Figura 2.6 - Tipos de falhas comuns em motores de indução (Fonte: Adaptado de (GANGSAR e TIWARI, 2020)).....	30
Figura 2.7- Variáveis geométricas do rolamento.....	31
Figura 2.8 - Organograma dos métodos de detecção de falhas (Fonte: Adaptado de (CRUZ, 2015))	33
Figura 2.9 - Pontos de leitura dos sensores de vibração	34
Figura 2.10 - Diferentes formas de montar um acelerômetro (Fonte: Adaptado de (KLUCZYK e GRZĄDZIELA, 2017))	35
Figura 2.11- Tipos de excentricidade no motor de indução (Fonte: Adaptado de (FAIZ e MOOSAVI, 2016)).....	38
Figura 2.12 - Representação da aquisição do sinal de corrente com excentricidade provocada por falha no rolamento.	38
Figura 2.13 - Imagem termográfica de um MIT operando a 22 N.m com falha na pista externa com diâmetro de 0,5 mm.	40

Figura 3.1- Representação sinal analógico (Fonte: (FIGLIOLA e BEASLEY, 2020))	42
Figura 3.2- Representação e onda padrão de sinal digital (Fonte: (FIGLIOLA e BEASLEY, 2020))	42
Figura 3.3-Sinal de tempo discreto (Fonte: (FIGLIOLA e BEASLEY, 2020))	43
Figura 3.4- Exemplo de sinais dinâmicos.(Fonte: (FIGLIOLA e BEASLEY, 2020))	44
Figura 3.5- Amostragem de um sinal analógico (Fonte: (FLIGIOLA e BEASLEY (2020)).	45
Figura 3.6-Representação da mudança de domínios utilizando a transformada de Fourier	46
Figura 3.7- Transformada de Fourier digital (Fonte: Adaptado de (https://community.sw.siemens.com/s/article/digital-signal-processing-sampling-rates-bandwidth-spectral-lines-and-more))	47
Figura 3.8- Comparação do numero de operações entre a DFT padrão e a FFT (Fonte: (CHAPRA e CANALE, 2011. p.454.))	48
Figura 3.9- Espectro do sinal de corrente do motor de indução obtido por meio da FFT.....	49
Figura 3. 10- Transformada Janelada de Fourier com certa localização, mas com janela constante (Fonte: (CASTILHO <i>et al.</i> , 2012))......	50
Figura 3.11-Representação da extração do envelope de um sinal.....	51
Figura 3.12- Falha na pista externa de um rolamento e o sinal de vibração com seu envoltório.....	52
Figura 3.13-Representação das etapas necessárias para detectar as frequências de falha em um rolamento usando a técnica do envelope.	53
Figura 3.14- Ilustração de um (a) neurônio biológico comparado com (b) neurônio artificial.....	55
Figura 3.15-Representação da arquitetura de uma rede <i>perceptron</i> de múltiplas camadas com duas camadas ocultas (Fonte: adaptado de (SILVA et al., 2016)).....	57
Figura 3.16- Diferentes Funções de ativação utilizadas em redes neurais a) sigmoide; b) tangente hiperbólica; c) ReLu e d) Leaky ReLu.....	60
Figura 3.17- Gradiente descendente e custo mínimo (Fonte: Adaptado de (HOSSAIN, 2024)).	63
Figura 3.18-Representação gráfica treinamento do gradiente descendente com momentum (Fonte: Adaptado de (SILVA et al., 2016)).....	65
Figura 3.19-Comparação do Adam com outros algoritmos de otimização em uma rede neural multicamadas (Fonte: Adaptado de (KINGMA e BA, 2014)).	67

Figura 3.20 - Analogia ao PSO usando o exemplo de uma revoada de pássaros procurando a árvore ideal para repousar durante à noite.	71
Figura 3.21-O efeito do <i>overfitting</i> e do <i>underfitting</i> nos dados de treinamento (Fonte: Adaptado de (HOSSAIN, 2024)).	72
Figura 3.22- Representação de uma matriz de confusão.....	73
Figura 3.23- Atrator de Lorenz (Fonte:(STROGATZ, 2018))	77
Figura 3.24- Representação de fractais, á esquerda o triângulo de Sierpinski e a direita o fractal floco de neve de Koch.	78
Figura 3.25- Modelo simplificado de um Pêndulo duplo e suas coordenadas generalizadas	80
Figura 3.26- Pêndulo duplo e seus componentes na posição de lançamento para: a) 0° e b) 0.1°	81
Figura 3.27- Trajetória da segunda barra do pêndulo duplo para lançamentos de 0° e 0.1°	82
Figura 3.28- Gráfico da variação da velocidade em um pêndulo duplo ao decorrer do tempo.	82
Figura 3. 29- Função de autocorrelação. a) Sinal periódico $x_t = \cos t$; b) sinal quase-periódico $x_t = \cos 3t + \cos \pi t$; c) sinal quase-periódico $x_t = \cos t + 2\cos \pi t$; d) sinal caótico. (Fonte: Adaptado de (FIEDLER-FERRARA e DO PRADO, 1994. p.293))	84
Figura 3.30- Representação da árvore de símbolos. (Fonte: Adaptado de (YANG e ZHAO, 1998)).....	85
Figura 3.31- Representação do processo de transformação de uma série temporal em uma série simbólica no teste da árvore de símbolos.....	86
Figura 3.32- Teste da árvore de símbolos, espectro da árvore de símbolos para uma série: a) periódica; b) caótica; c) aleatória.	87
Figura 3.33-Teste 0-1 para o caos usando o mapa logístico resultados para a) uma série com dinâmica regular b) uma série com dinâmica caótica.....	91
Figura 3.34-Função parcial de autocorrelação para o sinal de corrente de um MIT.....	93
Figura 3.35-Coeficiente de comprimento de correlação (Fonte: Adaptado de (Bazeia <i>et al.</i> , 2017)).	94
Figura 3.36-Curva de uma função $x(t)$ de um sistema modelado por equações diferenciais de primeira ordem e a direita sua função de autocorrelação. (Fonte: Adaptado de (BAZEIA <i>et al.</i> , 2017)).	98

Figura 4.1- Representação da bancada de torque controlável e seus acessórios.	101
Figura 4.2- Bancada de torque controlável e seus principais componentes	102
Figura 4.3- a) Motor de indução trifásico HERCULES IEC100 IR3 de 5 cv e 4 pólos b) adaptador utilizado para fixar o acelerômetro.	104
Figura 4.4-Modelo do Inversor de frequência, WEG CFW 700 utilizado na bancada.	104
Figura 4.5-Quadro de comando da bancada de torque controlável, a esquerda parte externa e a direita a parte interna.....	105
Figura 4.6- motor de corrente contínua VARIMOT 132S (Fonte:(LYRA, 2014)).....	106
Figura 4.7-Sistema de acionamento do motor CC: [1] regulador de tensão; [2] ponte retificadora; [3] multímetro.	107
Figura 4.8-circuito elétrico de acionamento do motor cc (Fonte: (ADISSI, 2015))	107
Figura 4.9- Resistores elétricos de 24Ω e 2000 W aletados conectados à armadura (Fonte: (ADISSI, 2015)).	108
Figura 4.10-Sensores de corrente e tensão, a) Sensor de corrente por efeito Hall, b) Sensor de corrente não invasivo, c) Transformador de potência.....	109
Figura 4.11- Torquímetro HBM-T40B-200 a esquerda; escala no modo de frequência a direita.....	110
Figura 4.12-Tacômetro digital modelo MDT-2238B e seu modo de operação a direta....	110
Figura 4.13-a) Acelerômetro; b) Circuito elétrico de acionamento do acelerômetro; b) Placa eletrônica de acionamento do acelerômetro.....	111
Figura 4.14-Resposta de frequência acelerômetro HS-1001000202.....	111
Figura 4.15- Microfone utilizado na aquisição do sinal de áudio.	112
Figura 4.16-Dispositivo de aquisição de dados NI USB- 6215.....	112
Figura 4.17-Representação de um rolamento de esferas e as dimensões utilizadas para o cálculo das frequências de falha.	114
Figura 4.18- Processo de fabricação de uma falha simulada usando eletroerosão.....	114
Figura 4.19- Peça guia impressa em material ABS projetada para auxiliar na simulação de falhas em rolamentos pelo processo de eletroerosão.....	115
Figura 4.20-Posicionamentos dos eletrodos utilizados para gerar as falhas nos rolamentos.	116
Figura 4.21- Falha BPFO 0,5 mm	116
Figura 4.22- Falha BRFI 0,5 mm.....	117

Figura 4.23-Falha mista com BPFI 0,5 mm e BPFO 1mm.	117
Figura 4.24-Diagrama com todos os sinais aqusitados na bancada de torque controlável.	120
Figura 4.25-Diagrama do processo de detecção das frequências de falha.	121
Figura 4.26- Diagrama com as etapas utilizadas no método MCSA.....	123
Figura 4.27-Fluxograma do algoritmo proposto usando sinal da corrente e densidade dos máximos (SAC-DM)	124
Figura 4.28-Arquitetura da rede neural MLP, utilizada para auxiliar na classificação de falhas no rolamento.	125
Figura 5.1- Detecção da FCF (BPFO) por meio da análise da vibração, sob carga a 0%. .	128
Figura 5.2-Detecção da FCF (BPFO) por meio da análise da vibração, sob carga a 60%. .	129
Figura 5.3- Detecção da FCF (BPFO) por meio da análise da vibração, sob carga a 100%.	130
Figura 5.4- Detecção da FCF (BPFI) por meio da análise da vibração, sob carga a 0%. .	131
Figura 5.5- Detecção da FCF (Mista) por meio da análise da vibração, com carga a 0%. .	133
Figura 5.6-Detecção da FCF (BPFO) por meio do sinal acústico, sob carga a 0% da nominal.....	135
Figura 5.7-Detecção da FCF (BPFO) por meio do sinal acústico, sob carga a 60% da nominal.	136
Figura 5.8-Detecção da FCF (BPFO) por meio do sinal acústico, sob carga a 100% da nominal.	137
Figura 5.9-Detecção da FCF (BPFI) por meio do sinal acústico, sob carga a 0% da nominal.	139
Figura 5.10- Detecção da FCF (Mista) por meio do sinal acústico, sob carga a 0% da nominal.	141
Figura 5.11- Comparação entre as FCFs teóricas e experimentais para falha na pista externa.	143
Figura 5.12- Comparação entre as FCF experimentais, obtidas através da análise dos sinais de vibração mecânica e sonora e as FCF teóricas obtidas de forma analítica para falha do tipo BPFO.....	144
Figura 5.13-Comparação entre os valores teóricos da FCF e os valores experimentais com seus respectivos erros relativos percentuais para uma falha do tipo BPFO.	145

Figura 5.14-Comparação entre as FCFs teóricas e experimentais para falha na pista interna.	147
Figura 5.15-Comparação entre as FCF experimentais, obtidas através da análise dos sinais de vibração mecânica e sonora e as FCF teóricas obtidas de forma analítica para falha do tipo BPFI.	148
Figura 5.16- Comparação entre os valores teóricos da FCF e os valores experimentais com seus respectivos erros relativos percentuais para uma falha do tipo BPFI.	149
Figura 5.17-Espectro de frequência do sinal de corrente com e sem falha para 0% da carga nominal.	154
Figura 5.18-Espectro de frequência do sinal de corrente com e sem falha para 60% da carga nominal.	155
Figura 5.19-Espectro de frequência do sinal de corrente com e sem falha para 100% da carga nominal.	157
Figura 5.20-Espectro de frequência do sinal de corrente com e sem falha para 0% da carga nominal.	159
Figura 5.21-Espectro de frequência do sinal de corrente com e sem falha para 60% da carga nominal.	160
Figura 5.22 -Espectro de frequência do sinal de corrente com e sem falha para 100% da carga nominal.	161
Figura 5.23-Soma dos sinais de corrente <i>ia</i> e <i>ic</i> e extração do envelope do sinal resultante. Motor operando a 20% da carga nominal.	162
Figura 5.24- Teste árvore de símbolos para o sinal da corrente do MIT.	163
Figura 5.25- Teste 0-1 para o sinal da corrente do motor de indução trifásico.	165
Figura 5.26- Função de autocorrelação para o sinal da corrente do MIT, sem falha e com falha na pista externa do rolamento.	166
Figura 5.27 - Sinal do envelope e detecção dos picos.	167
Figura 5.28- Descrição do processo para obter os pontos de densidade de máximos para cada intervalo δt , obtidos a partir do sinal do envelope da corrente.	168
Figura 5.29- Resultado do SAC-DM para (a) $\delta t = 0,25$ e (b) $\delta t = 0,5$. Sinais com o rolamento saudável, com falha na pista interna, pista externa e falha mista, sob 0% da carga nominal.	170
Figura 5.30- Valores médios e desvio padrão do SAC-DM para o rolamento com e sem falha atuando sob carga a 0% da nominal.	170

Figura 5.31- Resultado do SAC-DM para (a) $\delta t = 0,25$ e (b) $\delta t = 0,5$. Sinais com o rolamento saudável, com falha na pista interna, pista externa e falha mista, sob 60% da carga nominal.	171
Figura 5.32-Valores médios e desvio padrão do SAC-DM para o rolamento com e sem falha atuando sob carga a 60% da nominal.	172
Figura 5.33-Resultado do SAC-DM para (a) $\delta t=0,25$ e (b) $\delta t=0,5$. Sinais com o rolamento saudável, com falha na pista interna, pista externa e falha mista, sob 60% da carga nominal.	173
Figura 5.34-Valores médios e desvio padrão do SAC-DM para o rolamento com e sem falha atuando sob carga a 100% da nominal.	173
Figura 5.35- Curvas de perda de treinamento e validação ao longo das épocas para a rede neural de classificação de falhas.....	174
Figura 5.36- Matriz de confusão para a rede MLP.....	175

LISTA DE TABELAS E QUADROS

Tabela 2.1- Modos de falhas em rolamentos e suas causas (Fonte: (BLOCH e GEITNER, 2012))	29
Tabela 3.1- Classificação das formas de onda (Fonte: (FIGLIOLA e BEASLEY, 2020))	44
Tabela 3.2 - Breve histórico sobre a evolução da dinâmica e os principais cientistas que contribuíram para a compreensão do caos. Fonte: (Traduzido de (STROGATZ, 2018, p.5)).	79
Tabela 4.1-Principais dados da geometria do rolamento referência 6206-ZZ	113
Tabela 4.2 - Matriz de ensaios para os dados coletados.....	118
Tabela 5.1- Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 0%. ..	128
Tabela 5.2-Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 60% ..	129
Tabela 5.3- Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 100%.	130
Tabela 5.4- Comparação entre a FCF (BPFI) experimental e teórica, sob carga a 0%	132
Tabela 5.5- Comparação entre a FCF (Mista) experimental e teórica, sob carga a 0%. ...	133
Tabela 5.6-Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 0%. ...	135
Tabela 5.7-Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 60% ..	136
Tabela 5.8-Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 100%. 137	
Tabela 5.9- Comparação entre a FCF (BPFI) experimental e teórica, sob carga a 0%.....	139
Tabela 5.10-Comparação entre a FCF (Mista) experimental e teórica, sob carga a 0 % ..	141
Tabela 5.11-Comparação entre as FCFs teóricas e experimentais para defeito na pista externa (BPFO) do rolamento SKF 6206 ZZ com furo de 0.5 mm de diâmetro feito na diagonal	146
Tabela 5.12-Comparação entre as FCFs teóricas e experimentais para defeito na pista interna (BPFI) do rolamento SKF 6206 ZZ com furo de 0.5 mm de diâmetro feito na diagonal	150

Tabela 5.13- Frequências características de falha para defeito na pista externa usando MCSA para 0% da carga nominal.	153
Tabela 5.14- Frequências características de falha para defeito na pista externa usando MCSA para 60% da carga nominal	154
Tabela 5.15- Frequências características de falha para defeito na pista externa usando MCSA para 100% da carga nominal	156
Tabela 5.16- Frequências características de falha para defeito na pista interna usando MCSA para 0% da carga nominal.	158
Tabela 5.17-Frequências características de falha para defeito na pista interna usando MCSA para 60% da carga nominal.	159
Tabela 5.18-Frequências características de falha para defeito na pista interna usando MCSA para 100% da carga nominal.	160
Tabela 5.19-Valores do SAC-DM para rolamento com e sem falha.....	169
Tabela 5.20-Compilação dos resultados da matriz de confusão e seus principais parâmetros	175
Quadro 1.1- Técnicas utilizadas na detecção e diagnóstico de falhas em rolamentos de motores de indução.	8
Quadro 1.2 - Técnicas utilizando o sinal da corrente na detecção e diagnóstico de falhas em rolamentos de motores de indução	15

LISTA DE SIGLAS E ABREVIATURAS

BPI	<i>Ball Pass Frequency of Inner ring</i>
BPFO	<i>Ball Pass Frequency of Outer ring</i>
CSA	<i>Current Signature Analysis</i>
CWRU	<i>Case Western Reserve University</i>
CWT	<i>Continuous Wavelet Analysis</i>
DFT	<i>Discrete Fourier Transform</i>
DSP	<i>Digital Signal Processing</i>
DWT	<i>Discrete Wavelet Transform</i>
FCF	Frequência Característica de Falha
FFT	<i>Fast Fourier Transform</i>
FFPE	Frequência de falha na pista externa
GPICEEMA	Grupo de Pesquisa em Instrumentação e Controle em Estudo de Energia e Meio Ambiente
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
MCSA	<i>Motor Current Signature Analysis</i>
MER	Mancais de Elementos Rolantes
MIT	<i>Motor de indução trifásico</i>
NN	<i>Nearest Neighbour</i>
RMS	<i>Root Mean Square</i>
SAC-DM	<i>Signal Analysis based on Chaos using Density of Maxima</i>
SNR	<i>Signal-to-Noise Ratio</i>
STFT	<i>Short Time Fourier Transform</i>
TC	Transformador de corrente
UFPB	Universidade Federal da Paraíba

LISTA DE SÍMBOLOS

n	Quantidade de elementos rolantes
fr	Frequência de rotação
fs	Frequência da rede elétrica (60 Hz)
D, d	Diâmetro
θ	Ângulo de atuação da carga (graus)
S_l	Sequência de símbolos
L	Nível no espectro de símbolos
l	Comprimento da partição
N	Comprimento da série temporal variáveis
c	Intervalo aleatório $(0, \pi)$ das variáveis de conversão
$\emptyset(j)$	Função observável construída a partir da série temporal
$M_c(n)$	Função deslocamento quadrático médio
$D_c(n)$	Deslocamento quadrado médio modificado
K_c	Taxa de crescimento assintótica
δ_t	Variação no tempo
$\langle \rho_i \rangle$	Densidade máxima média teórica
$C_i(\delta_t)$	Função de autocorrelação
C_i''	Derivada segunda da função de autocorrelação
C_i^4	Derivada quarta da função de autocorrelação
τ	Coefficiente de comprimento de autocorrelação

CAPÍTULO I

1. INTRODUÇÃO

Segundo dados publicados pela Empresa de Pesquisa Energética EPE¹ (2022), no Balanço Energético Nacional (BEN-2021), a indústria continua sendo o setor que mais utiliza energia elétrica no Brasil, sendo responsável por consumir 37,4% de toda energia elétrica produzida no país. Em um guia técnico divulgado pela ELETROBRAS (2016), entre 62% a 68% da energia consumida pela indústria foi utilizada por máquinas elétricas para gerar força motriz. Estima-se que os motores elétricos sejam responsáveis pelo consumo de 25% da energia gerada no Brasil.

A maior parte da energia elétrica produzida é consumida por motores de empresas comerciais e industriais (YETGIN, 2020). Mesmo com uma grande variedade de tipos de motores, sejam eles de corrente alternada ou corrente contínua, os motores de indução são amplamente utilizados pela indústria (LU *et al.*, 2008; RINKEVIČIENE e PETROVAS, 2009) podendo ser considerados também a espinha dorsal da indústria moderna (YE *et al.*, 2003).

Mesmo com os impactos da Pandemia do Coronavírus (COVID-19) provocada pelo vírus SARS-Cov-2 que atingiu o mundo e teve início em 2020, o tamanho do mercado global de motores elétricos para o corrente ano foi avaliado em 106,3 bilhões de dólares e

¹<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2022>

deve atingir 207,3 bilhões de dólares até 2030, é o que revela o relatório publicado pela *Allied Market Research*² (2022).

Os motores de indução trifásicos (MITs) correspondem a 90% dos motores elétricos utilizados na indústria (HANITSCH, 2002). Isso se deve em grande parte a sua eficiência, robustez mecânica, versatilidade de aplicações, ampla faixa de potência nominal de operação, além de uma boa relação custo-benefício (ADISSI, 2015).

Monitorar os motores elétricos, principalmente os de elevada potência, é de suma importância, a fim de identificar e prevenir falhas, evitando assim quebras inesperadas. Vale ressaltar que na maioria das vezes esses motores estão vinculados a trabalhos vitais nos processos industriais (ADISSI *et al.*, 2017), já que são empregados nos mais diversos setores, como por exemplo, petroquímico, naval, automobilístico, sucroalcooleiro, dentre vários outros segmentos (LIMA FILHO, 2009).

Dependendo de sua origem, as falhas nos motores elétricos de indução trifásicos podem ser divididas em duas categorias: falhas elétricas e mecânicas. Dentre as principais falhas no motor 44% correspondem a falhas nos rolamentos, falhas no estator corresponde a 26%, falhas no rotor 8% e 22% correspondem a outros tipos de falhas (PANDARAKONE *et al.*, 2018).

Apesar do relativo baixo custo, os rolamentos utilizados em motores elétricos em aplicações comerciais e industriais, apresenta a maior taxa de defeitos, sendo a principal causa das falhas mecânicas nas indústrias, particularmente nas classes de motores de pequena e média potência. Tais falhas podem ocasionar interrupção do funcionamento de um setor ou até de uma fábrica inteira, além de provocar eventuais acidentes (LUCENA-JUNIOR *et al.*, 2020; PANDARAKONE *et al.*, 2018).

O diagnóstico de falhas em máquinas elétricas rotativas tem sido amplamente discutido nas últimas décadas, entretanto foi nos últimos 30 anos que esse interesse se intensificou, devido principalmente ao aumento do número destas máquinas (HENAO *et al.*, 2014, SOBRINHO *et al.*, 2015).

Com o objetivo de evitar falhas repentinas que possam interferir ou até mesmo parar processos importantes nos mais diversos setores produtivos, intensificou-se a busca por melhores métodos para diagnosticar e classificar falhas em motores elétricos, em

²<https://www.alliedmarketresearch.com/electric-motor-market>

especial destaque para os motores de indução trifásicos, já que corresponde a maior fatia dos motores elétricos em operação.

Na literatura podem ser encontrados diversos métodos e ferramentas inovadoras que auxiliam no diagnóstico e análise de falhas em motores de indução trifásicos, em especial destaque para as falhas mais frequentes, que acometem principalmente os rolamentos, estatores e rotores. Os principais sinais utilizados são: sinal da corrente do motor, conhecido também como *Motor Current Signature Analysis* (MCSA) (BESSOUS *et al.*, 2019; DEEKSHIT KOMPELLA *et al.*, 2018; MARTINEZ-MONTES *et al.*, 2018; SHARMA *et al.*, 2017), análise de vibração mecânica (AMAR *et al.*, 2015; KUMAR *et al.*, 2018; PRUDHOM *et al.*, 2017; TIAN *et al.*, 2016), análise termográfica (CHOUDHARY *et al.*, 2019; KARVELIS *et al.*, 2014; LOPEZ-PEREZ e ANTONINO-DAVIU, 2017; NUNEZ *et al.*, 2016; RESENDIZ-OCHOA *et al.*, 2018) e análise da emissão acústica (ELMALEEH e SAAD, 2008; GLOWACZ, 2019; GLOWACZ e GLOWACZ, 2017; KEMALKAR e BAIRAGI, 2016; PRAINETR *et al.*, 2017).

1.1. ESTADO DA ARTE

No presente item serão abordados alguns trabalhos relacionados às principais técnicas empregadas no diagnóstico e caracterização de falhas em motores elétricos com especial destaque para as falhas de rolamentos em MITs.

1.1.1. Técnicas relacionadas aos sinais de vibração mecânica e sonora

Os motores de indução por ser a ponta de lança no setor industrial demanda muita atenção, eles estão presentes em diversas etapas do processo produtivo de forma que a parada repentina em algum desses processos pode provocar atrasos ou até mesmo acidentes graves. Por tal motivo, fazem-se necessárias pesquisas contínuas, com o intuito de desenvolver a melhor metodologia para detectar, classificar e diagnosticar falhas ainda em estágio inicial.

A análise do sinal de vibração mecânica ainda é o carro chefe quando se trata de diagnóstico de falhas em rolamento. FENG *et al.* (2015) utiliza o sinal da vibração e descreve a implementação da análise de envelope via nó de sensor sem fio para obter um sistema de monitoramento de condição (CM – *Condition Monitoring*) mais conveniente e confiável. O sistema de monitoramento é composto por uma rede de sensores sem fio

baseada em *Zigbee* (WSN) e utiliza um microcontrolador *cortex-M4F* de baixo custo como processador central para implementar o algoritmo de análise de envelope no nó sensor. O espectro do envelope foi calculado a partir de um quadro de dados de 2048 pontos, os resultados da avaliação experimental mostrou que o algoritmo de análise de envelope pode diagnosticar com sucesso falhas simuladas de rolamento, o sistema possibilita ainda a ampliação para um grande número de nós de sensores para monitoramento em tempo real.

A técnica do envelope baseada na transformada de Hilbert pode ser associada a outras técnicas com o intuito de aperfeiçoar e facilitar a extração das frequências características de falha. Em seu trabalho *AGRAWAL et al. (2015)* apresentaram novos métodos baseados na fusão da transformada de Hilbert e técnicas de resolução de alta frequência estimativa do parâmetro de sinal pela técnica de invariância rotacional (ESPRIT) e classificação de sinais múltiplos de raiz (*root MUSIC*) para extrair frequências de defeitos de rolamentos de motores de indução, através do sinal de vibração. Ainda segundo os autores, através da série de resultados, concluiu-se que a janela deslizante Hilbert-ESPRIT foi mais precisa e computacionalmente eficiente do que a janela deslizante Hilbert-root MUSIC para a estimativa das frequências características do rolamento, de modo que o método proposto pode ser usado para detecção de falhas em tempo real.

Em *TYAGI e PANIGRAHI (2017)* foi empregada otimização por exame de partículas (PSO- *Particle Swarm Optimisation*) para selecionar a janela do envelope mais ideal, para passar em banda os sinais de vibração emanados da transmissão rotativa que foi executada em rolamentos de elementos rolantes normais e com falhas simuladas. Já os envelopes dos sinais passa-banda foram extraídos com o auxílio da transformada de Hilbert. Segundo os autores foi demonstrando que a seleção da janela do envelope pelo PSO torna a detecção do envelope torna o método especialmente útil para identificar falhas em rolamentos com defeito em estágio incipiente.

Quando se trata de monitoramento em tempo real dos rolamentos um dos desafios é a alta transferência de dados. Em *LIU et al. (2019)* um *hashing* perceptivo é proposto como uma forma de computação de borda, visando não apenas reduzir a dimensionalidade dos dados, mas também extrair e representar as informações de condição da máquina. Tal método permite que *hashes* de condição de máquina sejam compactados e transmitidos em vez de sinais de vibração brutos. Segundo os autores, Técnicas como Wavelet Packet, transformadas discreta de cossenos bidimensional e aproximação de agregação simbólica também foram utilizadas devido a sua eficiência computacional. Ainda segundo os autores

os recursos de sub-banda extraídos puderam efetivamente revelar o padrão de distribuição de frequência nos sinais de vibração.

Embora tenha havido grandes avanços na tecnologia e nas técnicas destinadas ao diagnóstico de falhas em rolamentos de motores elétricos faltam estudos que abordem aspectos tutoriais neste campo é o que afirma KIM *et al.* (2020). Os autores, em seu trabalho, propuseram um tutorial para diagnóstico de falhas de rolamentos de elementos rolantes usando análise de envelope no MATLAB, e utilizaram o modelo autorregressivo, a curtose espectral e a análise de envelope, para demonstrar o processo de diagnóstico do rolamento, foram utilizados sinais de vibração simulados computacionalmente e dois banco de dados um da *Korea Aerospace University* (KAU) feito pelos autores e outro amplamente utilizado em testes de diagnóstico de falhas em rolamentos da *Case Western Reserve University* (CWRU). Os autores através de tal iniciativa contribuíram para o ensino e melhor compreensão do diagnóstico de falhas em elementos rolantes, além de gerar banco de dados para outras técnicas sejam implementadas.

MALIUK *et al.* (2021) propuseram um novo método de diagnóstico de falha em rolamento usando seleção de banda de falha baseada em modelo de mistura Gaussiana. No artigo é proposto um método de seleção de banda de falha de rolamento baseado em modelo de mistura gaussiana (GMM-WBBS) para processamento de sinal. Os sinais utilizados foram adquiridos a uma frequência de amostragem de 64 kHz e foram analisadas falhas simuladas na pista interna e externa. O método proposto, segundo os autores, atua selecionando exclusivamente harmônicos de frequência de falha de rolamento, e elimina a interferência de vibrações normais de rolamento nas frequências mais baixas, frequências naturais de rolamento e os conteúdos de frequência mais alta que provam ser úteis apenas para detecção de anomalias, mas não fornecem nenhuma visão sobre a localização da falha de rolamento. A classificação das falhas é feita através do método k-vizinhos mais próximos KNN. O método GMM-WBBS proposto mostrou desempenho de classificação aprimorado em todos os casos para diagnóstico de falha cujo sinal apresente uma única falha presente.

Os motores elétricos de indução estão sujeitos a apresentar falhas simultâneas, sejam falhas elétricas ou falhas mecânicas, de tal forma que a detecção de múltiplas falhas é mais difícil do que a detecção de uma única falha com método de diagnóstico baseado em Transformada de Fourier. O método proposto por KABUL e ÜNSAL (2022) utilizou a análise de envelope de Hilbert com um filtro adaptativo *Normalized Least Mean Square*

(NLSM), para diagnosticar falhas no rolamento, excentricidade e barras quebradas, através da análise dos sinais da corrente elétrica do estator e de vibração. Os resultados foram verificados experimentalmente sob condições de carga de 25%, 50%, 75%, 100%. Segundo os autores Os resultados demonstraram que o desempenho do método proposto foi melhor do que o desempenho da análise FFT dos sinais de corrente do motor de indução com falhas simultâneas em baixos níveis de carga, de forma que a principal contribuição do trabalho foi à detecção bem-sucedida de componentes harmônicos característicos de baixa amplitude de falhas simultâneas em motores de indução.

LOPEZ-GUTIERREZ *et al.* (2022) propuseram uma metodologia para detectar falhas em rolamentos de um motor de indução. A falha foi gerada artificialmente através do processo de eletroerosão, com os sinais de vibração amostrados a uma taxa de 12,8 kHz. Segundo os autores a primeira parte da metodologia utiliza um método de processamento de sinal chamado transformada wavelet empírica (EWT), que decompõe o sinal de vibração em múltiplos componentes para extrair uma série de componentes modulados em amplitude e frequência (AM-FM) com um espectro de Fourier. Três tipos de testes de qualidade de ajuste são usados, sendo eles: Kuiper, Kolmogorov-Smirnov e qui-quadrado de Pearson, que são utilizados para classificar os sinais e determinar quais pertencem a um motor danificado. Ainda segundo os autores o método EWT elimina muitas das limitações em comparação com o método DWT tradicional e permite que o espectro de Fourier seja segmentado de forma adaptativa, de forma que as informações sobre os danos gerados na pista externa dos mancais do motor podem ser detectados nos sinais de vibração.

Os sinais acústicos emitidos pelo motor, quando em operação, podem revelar características intrínsecas interessantes, quanto ao comportamento do mesmo, bem como pode mascarar possíveis falhas.

DELGADO-ARREDONDO *et al.* (2017) propuseram uma metodologia para detecção de falhas em motores de indução em regime permanente baseada na análise de sinais acústicos de som e vibração. A abordagem proposta usa a Decomposição de Modo Empírico de Conjunto Completo (CEEMD) para decompor o sinal em várias funções de modo intrínseco. Segundo os autores, posteriormente, a frequência marginal da representação de Gabor é calculada para obter o conteúdo espectral do IMF (funções de modo intrínseco) no domínio da frequência. Como resultado, as características dos espectros obtidos facilitam a observação e identificação de componentes espectrais associados às falhas analisadas. Entretanto, segundo os autores, a metodologia proposta

tem algumas limitações. A primeira está associada ao uso do CEEMD. Também não é possível saber a priori o número de modos em que o sinal é decomposto e qual modo ou IMF conterá os componentes espectrais de interesse.

Em GLOWACZ (2019) foi desenvolvido e implementado um método de extração de características de sinais acústicos – SMOFS-22-MULTIEXPANDED (*Shortened Method of Frequencies Selection Multiexpanded*), que tem como objetivo diagnosticar falhas em rolamento, estator e rotor de um motor de indução monofásico, como classificador para as falhas o autor utiliza o método *Nearest Neighbour* (NN), os sinais das falhas foram captadas por um microfone com uma frequência de amostragem de 44,1 kHz. Segundo o autor os métodos propostos tiveram bons resultados para diagnóstico de falhas em mancais, estator e rotor do motor de indução monofásico. A abordagem desenvolvida mostrou-se apta a encontrar aplicações para diagnóstico de falhas de outros tipos de máquinas rotativas.

Em seu trabalho LUCENA-JUNIOR *et al.* (2020) utilizando como sinal o som emitido pelo motor de indução trifásico apresentou uma nova abordagem baseada na quantificação do comportamento caótico para a caracterização de falha de rolamento rígido de um motor de indução trifásico através do método chamado análise de sinal baseada no caos usando densidade de máximos (SAC-DM). Segundo os autores a técnica é baseada em um algoritmo que conta os picos contidos no sinal sonoro do motor, no domínio do tempo, para detectar falhas usando apenas um sensor e um algoritmo com baixo custo computacional. Resultados com dados experimentais, mostrou que a técnica SAC-DM permite o diagnóstico de falha em rolamento mesmo sob condições de carga variável. Para uma janela de aquisição de apenas 0,28 segundos a precisão obtida foi de 100%, já para uma janela de 0,1 segundos, por exemplo, os autores obtiveram 92,18% de acurácia na detecção e 82,83% de acurácia no diagnóstico.

Através da análise de sinais emitidos pelo motor de indução DEL ROSARIO *et al.* (2023) propuseram o uso de *Lock-In Amplification* (LIA) para detecção de falhas em rolamentos, a fim de superar limitações de SNR (*Signal to Noise Ratio*) e permitir detecção específica. Segundo os autores na prática, o LIA é sincronizado com a frequência do eixo do motor através de um sintetizador de frequência PLL (*phase-locked loop*) fracionário, fornecendo frequências características para falhas de rolamento. Ainda segundo os autores os resultados confirmam que a técnica utilizando o LIA de harmônicos fracionários foi

capaz de detectar frequências características de condições livres de falhas, abrindo caminho para a detecção precoce de falhas e monitoramento contínuo.

CHOUDHARY *et al.* (2023) apresentaram uma técnica de fusão vibroacústica para um diagnóstico preciso de falhas em condições de trabalho variadas. O método sugerido funde as características de vibração e sinais acústicos usando a técnica *Multi Input-Convolutional Neural Network* (MI-CNN), segundo os autores sinais brutos de vibração e acústicos são adquiridos em velocidades variáveis e convertidos em um espectro de frequência de tempo usando a Transformada de Gabor Constante Q-Não Estacionária (CQ-NSGT). Os resultados demonstraram que a abordagem sugerida pelos autores foi precisa e confiável não apenas para motores de indução, mas também para outros componentes críticos de máquinas rotativas, incluindo rolamentos e engrenagens, atingindo uma precisão máxima de 99,9 %. Os autores fazem uma ressalva relatando que, embora a fusão de recursos de múltiplas entradas tenha mostrado excelentes resultados, deve-se notar que sempre aumenta o custo computacional.

É apresentado no Quadro 1.1 um compilado com os resumos dos principais trabalhos relacionados a falha de rolamentos de motores de indução trifásicos, contendo o tipo de falha, tipo de sinais que foram utilizados do MIT (motor de indução trifásico), frequência de amostragem (Fs), e descrição das técnicas utilizadas pelos autores.

Quadro 1.1- Técnicas utilizadas na detecção e diagnóstico de falhas em rolamentos de motores de indução.

Autor	Tipo de falha	Sinal	Fs	Descrição
(FENG <i>et al.</i> , 2015)	Falha na pista externa	Sinal de Vibração	10 kHz	<ul style="list-style-type: none"> • Motor elétrico de indução • Transformada de Fourier • Técnica do envelope
(AGRAWAL <i>et al.</i> , 2015)	Falha na pista interna e externa	Sinal de vibração	12 kHz	<ul style="list-style-type: none"> • Motor elétrico de indução • Carga variável • Técnicas de resolução de alta frequência. • (ESPRIT; root MUSIC) • Técnica do envelope
(TYAGI e PANIGRAHI, 2017)	Falha na pista interna, externa e esfera.	Sinal de vibração	48 kHz	<ul style="list-style-type: none"> • Motor elétrico de indução; • Carga Variável • PSO

				<ul style="list-style-type: none"> • Técnica do envelope
(LIU <i>et al.</i> , 2019)	Falha na pista interna, externa e nas esferas.	Sinal de vibração	48 kHz	<ul style="list-style-type: none"> • Motor elétrico de indução; • Carga variável • Wavelet Packet • Transformada discreta de cossenos bidimensional • Aproximação de agregação simbólica • <i>Hashing</i>
(KIM <i>et al.</i> , 2020)	Falha na pista interna e externa	Sinal de vibração	51,2 kHz 12 kHz 48 kHz	<ul style="list-style-type: none"> • Motor de corrente contínua, carga variável. • Motor de indução trifásico, carga variável. • Carga variável • FFT, STFT • Curtose espectral • Modelo autorregressivo • Transformada de Hilbert.
(MALIUK <i>et al.</i> , 2021)	Falha na pista interna e externa	Sinal de vibração	64 kHz	<ul style="list-style-type: none"> • Motor síncrono de ímã permanente (PMSM) • Carga variável; • <i>Machine learning</i> • Gaussian mixture model-based (GMMs) • KNN
(KABUL e ÜNSAL, 2022)	Falha na pista interna e externa, excentricidade e barras quebradas.	Sinal de vibração Sinal de corrente	25 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Carga variável – 25%, 50%, 75%, 100% • FFT • Técnica do envelope • Filtro adaptativo (Mínimo quadrado médio normalizado (NLSM))
(LOPEZ-GUTIERREZ <i>et al.</i> , 2022)	Falha na pista externa	Sinal de vibração	12,8 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Sem carga • Transformada Wavelet Empírica (EWT)
Utilizando o som emitido pelo motor				

(DELGADO-ARREDONDO <i>et al.</i> , 2017)	Falha na pista externa Barras quebradas Desbalanceamento	Sinal de vibração Som emitido pelo MIT	1,5 kHz (vibração) 2 kHz (som)	<ul style="list-style-type: none"> • Motor de indução • Carga regime permanente • Decomposição de modo empírico de conjunto completo (CEEMD)
(GLOWACZ, 2019)	Falha na gaiola do rolamento Barras quebradas Estator	Som emitido pelo motor	44,1 kHz	<ul style="list-style-type: none"> • Motor de indução Monofásico • Carga em regime permanente • FFT • Método Abreviado de Seleção de Frequências Multi-expandido (SMOFS-22-MULTIEXPANDED) • Classificador Nearest Neighbors (NN)
(LUCENA-JUNIOR <i>et al.</i> , 2020b)	Falha na pista interna e externa	Som emitido pelo MIT	44,1 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Carga variável (0% , 50% e 100%) • Teste da árvore de símbolos • Teste 0-1 • FFT • SAC_DM
(BAUTISTA-MORALES e PATIÑO-LÓPEZ, 2023)	Falhas na pista externa, interna, na gaiola e nas esferas	Som emitido pelo motor	500 kHz	<ul style="list-style-type: none"> • Motor de indução • Sem carga • FFT • <i>Lock-In Amplification</i> (LIA)
(CHOUDHARY <i>et al.</i> , 2023)	Falha na pista externa e interna Caixa de engrenagens	Sinal de Vibração som	6,4 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Sem carga e com carga • Rede neural multi-convolucional de entrada (MI-CNN)

1.1.2. Técnicas relacionadas ao sinal de corrente do estator.

Em seu estudo de revisão do estado da arte sobre diferentes tipos de falhas em motores de indução e seus esquemas de diagnóstico CHOUDHARY *et al.* (2019) chegaram a uma das conclusões que a análise da assinatura da corrente do motor (MCSA) não invasiva é uma técnica muito útil para identificar falhas.

Em LEITE *et al.* (2015) descreve a detecção experimental de falha em rolamento de um motor de indução trifásico analisando o espectro de envelope quadrado da corrente do estator. Utilizando algoritmos baseados em curtose espectral, kurtograma rápido e o kurtograma wavelet, também são aplicados para melhorar a análise do envelope. Testes experimentais foram realizados, considerando falhas de rolamentos na pista externa em diferentes estágios. O método proposto foi capaz de detectar um defeito de ponto único na pista externa de um rolamento sem a necessidade de qualquer modelagem ou análise com base na corrente do estator da máquina em condição saudável. Segundo os autores o espectro de corrente não foi eficaz para detecção de falhas. Por outro lado, a análise de envelope quadrado da corrente produziu resultados promissores.

YANG *et al.* (2016) apresentou um novo esquema para detecção de falhas on-line em motores de indução que faz uso de um banco de dados de conhecimento de recursos saudáveis e defeituosos recém-criado, tornando o método altamente escalável. O esquema proposto baseia-se na análise dos sinais de corrente do estator de treinamento, os métodos FFT e AIC são aplicados para extrair componentes independentes. Os recursos FFT-ICA foram posteriormente analisados para formar um banco de dados de conhecimento de recursos. Por meio de estudos de caso, este trabalho demonstrou a alta precisão, simplicidade e robustez do esquema de detecção de falhas em motores de indução.

Em SINGH *et al.* (2017) é proposto um método para detecção de falhas em rolamentos baseado na decomposição de modo empírico de conjunto completo com análise de ruído adaptativo (CEEMDAN) dos sinais de corrente do motor. O CEEMDAN é usado para decompor o sinal de corrente do estator em várias funções de modo intrínseco independentes (IMF), então o IMF mais sensível pode ser extraído. Por fim, os resultados experimentais obtidos mostram que o método proposto é capaz de detectar com eficiência falhas em rolamentos usando a análise da assinatura de corrente do estator.

ELBOUCHIKHI *et al.* (2017) propuseram um novo detector de falhas MCSA baseado em uma técnica de subespaço casado. O detector proposto consiste em três etapas. Primeiro, a influência da frequência de alimentação fundamental é removida do sinal de corrente usando uma técnica de cancelamento de interferência baseada em projeção oblíqua. Em seguida, a frequência relacionada à falha é estimada a partir do sinal livre de interferência usando o princípio da máxima verossimilhança. Finalmente, a detecção de falhas é realizada usando um teste de razão de verossimilhança generalizada. Simulação e resultados experimentais ilustram a eficácia da abordagem proposta para falha de excentricidade, falhas de rolamento e detecção de barras quebradas do rotor.

SINGH *et al.* (2017) em seu trabalho apresentam a detecção de falhas em rolamentos e seu diagnóstico em um motor de indução trifásico usando a transformada de Stockwell das correntes do estator. Os gráficos de magnitude máxima e ângulo de fase máximo são obtidos da transformação S para várias condições de rolamento, tanto no lado do eixo quanto no lado do ventilador. O desvio padrão desses gráficos é utilizado para detectar e analisar as falhas do rolamento. O estudo experimental mostra que a extração de características baseada na transformação S pode ser efetivamente utilizada para detecção e diagnóstico de falhas em rolamentos em motores de indução trifásicos.

Em seu trabalho DEEKSHIT KOMPELLA *et al.* (2018) a corrente do estator é monitorada por meio de subtração espectral de frequência usando várias transformadas wavelet para suprimir os componentes dominantes. A subtração espectral usando transformada de wavelet discreta, transformada de wavelet estacionária e decomposição de pacote de wavelet é realizada e uma análise comparativa é realizada por meio de diferentes parâmetros de indexação de falhas. Enquanto a transformada de wavelet discreta pode dar uma melhor indicação para falhas severas na potência total a transformada wavelet estacionária prevê as falhas mesmo em estágios incipientes Concluindo que a subtração espectral baseada na transformação de wavelet estacionária da corrente do estator tem uma boa indicação para qualquer tipo de falha.

NOUREDDINE *et al.* (2020) estuda o desempenho de três técnicas de detecção e diagnóstico de falhas em rolamentos. A primeira técnica é baseada na análise da corrente do estator (MCSA-FFT), a segunda utiliza a análise do sinal de vibração (MVSA-FFT) e a última técnica é dedicada à assinatura do fluxo parasita (SFSA-FFT). Em resumo, a análise MCSA-FFT não revelou nenhuma variação de amplitude significativa de excentricidade mista ou frequências de falha na pista interna específicas no espectro de corrente do

estator. O MVSA-FFT forneceu bons índices no espectro do sinal de vibração, mas o desempenho da análise de vibração na aplicação prática pode ser facilmente influenciado por fontes externas como variação de carga, desalinhamento do eixo, etc. Análise de assinatura de fluxo disperso sensível a REB forneceu boas informações sobre a frequência de falha na pista interna. Essa falha modifica o espectro de corrente, vibração e fluxo parasita porque esses três sinais estão sempre ligados entre si. É, portanto, encontrado no fluxo disperso; harmônicos ligados à corrente e à vibração, mas em comparação com o MVSA, esta técnica de detecção é insensível às vibrações externas do motor.

Em seu trabalho sobre falhas em rolamentos HOANG e KANG (2020) propõe um método de diagnóstico de falha baseado em sinal de corrente do motor utilizando aprendizado profundo e fusão de informações que pode ser aplicado a rolamentos externos em sistemas de máquinas rotativas. O método proposto utiliza sinais brutos de várias fases da corrente do motor como entrada direta, as características são extraídas dos sinais de corrente de cada fase. Em seguida, cada conjunto de recursos é classificado separadamente por uma rede neural convolucional. Os autores perceberam que a precisão da medição tem uma profunda influência no resultado do processo de diagnóstico de falhas. Os autores concluíram que o método de diagnóstico de falha de rolamento proposto é promissor para ser aplicado em aplicações reais.

NAKAMURA e MIZUNO (2022) propuseram um método confiável para diagnosticar falhas em rolamentos, que envolve a alteração da velocidade de rotação do motor e a medição das correntes de carga de motores saudáveis e defeituosos. A relação entre a amplitude dos sinais e a velocidade de rotação foi identificada como um novo recurso e diagnósticos baseados em aprendizado de máquina foram realizados. Os resultados mostraram que a adição da velocidade de rotação como um novo recurso levou a uma alta precisão no diagnóstico de falhas, independentemente do algoritmo de aprendizado de máquina utilizado. Esses métodos foram capazes de detectar um pequeno orifício de apenas 0,5 mm de diâmetro em um rolamento, o que pode abrir caminho para o desenvolvimento de uma técnica para detecção precoce de falhas e rastreamento de sua progressão.

EL IDRISSEI *et al.* (2022) objetivaram o diagnóstico de falhas em rolamentos de motores de indução controlados por uma Rede Neural Artificial - Controle Direto de Torque (ANN-DTC), utilizando a Transformada de Hilbert. O foco é na detecção de defeitos em diferentes localizações dos rolamentos sob várias condições operacionais, com

ênfase na minimização das ondulações do torque eletromagnético e no aumento da amplitude dos espectros relacionados aos defeitos em comparação com outras harmônicas. A técnica é validada no ambiente MATLAB/SIMULINK, demonstrando a eficácia do filtro de Hilbert em conjunto com o controle ANN-DTC para o diagnóstico precoce e preciso de defeitos em rolamentos.

Em ZHUKOVSKIY *et al.* (2023) os autores propuseram uma abordagem utilizando a decomposição em valores singulares (SVD) da amostra original aplicada ao sinal de corrente do estator de motores elétricos para identificar padrões que caracterizam a ocorrência e evolução de falhas em rolamentos. Ainda segundo os autores a análise dos resultados permitiu concluir que certos componentes são mais responsáveis pelo desenvolvimento dessas falhas, confirmando a viabilidade de identificar defeitos em fases iniciais com base na assinatura do sinal de corrente, utilizando o algoritmo proposto.

CISZEWSKI *et al.* (2023) investigou e validou, pela primeira vez, novas tecnologias de correlações cruzadas de ordem superior de módulos espectrais (CCSM) on-line, não lineares e de ordem superior, para o diagnóstico de falhas em máquinas rotativas, por meio de modelagem e experimentação. Os resultados experimentais, obtidos com essa nova metodologia, validada confirmaram altas probabilidades de diagnóstico correto de falhas em rolamentos, mesmo em estágios iniciais de desenvolvimento de danos.

Para estimar parâmetros elétricos de motores de indução trifásicos GUEDES *et al.* (2024) conduziram a pesquisa cujo objetivo era aplicar algoritmos de Evolução Diferencial, Otimização por Enxame de Partículas e Recozimento Simulado para analisar falhas em MITs. A classificação das falhas é realizada com Redes Neurais Artificiais, Máquinas de Vetor de Suporte e k-Vizinhos Mais Próximos. Segundo os autores os resultados experimentais confirmam a eficácia dessa abordagem na detecção precoce de falhas como curto-circuito no estator, barras quebradas no rotor e falha de rolamentos.

No Quadro 1.2 é apresentado o resumo com os principais artigos tratados neste item, e classificados de acordo com o tipo de falha, sinal utilizado nas análises, a frequência de amostragem do sinal (F_s) e a descrição com as principais técnicas utilizadas.

Quadro 1.2 - Técnicas utilizando o sinal da corrente na detecção e diagnóstico de falhas em rolamentos de motores de indução .

Autor	Tipo de falha	Sinal	Fs	Descrição
(LEITE <i>et al.</i> , 2015)	Falha na pista externa	Sinal da corrente	50 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Curtose Espectral • Técnica do envelope
(YANG <i>et al.</i> , 2016)	Falha na pista interna e externa	Sinal da corrente	50 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Transformada rápida de Fourier (FFT) • Análise de componentes independentes (ACI)
(ELBOUCHIKHI <i>et al.</i> , 2017)	Falha na pista externa e interna	Sinal da corrente	2,4 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Subespaço casado • Analise de assinatura da corrente do motor(MCSA)
(SINGH <i>et al.</i> , 2017)	Falha na pista externa, interna, gaiola e esferas.	Sinal da corrente	5 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Transformada de Stockwell • Transformada - S
(DEEKSHIT KOMPELLA <i>et al.</i> , 2018)	Falha na pista interna e externa	Sinal da corrente	10 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Subtração espectral de frequência • Transformadas wavelet discreta, estacionária.
(SAADI <i>et al.</i> , 2018)	Falha na pista externa, interna, gaiola e esfera.	Sinal da corrente	50 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Transformada de Hilbert Huang • EMD (Decomposição de modo empírico)
(NOUREDDINE <i>et al.</i> , 2020)	Falha na pista interna	Sinal da corrente e vibração	50 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • MCSA-FFT • MVSA-FFT • (SFSA-FFT)
(HOANG e	Falha na pista	Sinal da	64 kHz	<ul style="list-style-type: none"> • Motor de indução • Rede neural

KANG, 2020)	externa, interna	corrente		convolucional <ul style="list-style-type: none"> • Algoritmo de Aprendizado profundo • Fusão de informação de nível de decisão.
(NAKAMURA e MIZUNO, 2022)	Falha na pista externa	Sinal da corrente	10 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Machine Learning • Support Vector Machine (SVM), • Random Forest (RF), • Neural Network (NN).
(EL IDRISSEI <i>et al.</i> , 2022)	Falha na pista interna, externa, gaiola e elemento rolante.	Sinal da corrente	10 kHz	<ul style="list-style-type: none"> • Simulações/ Matlab • Motor de indução • Hilbert • FFT • Rede Neural
(ZHUKOVSKIY <i>et al.</i> , 2023)	Falha na pista interna	Sinal da corrente	10 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Decomposição em valores singulares (SVD - Singular Value Ration)
(CISZEWSKI <i>et al.</i> , 2023)	Falha na pista interna e externa	Sinal da corrente	65 kHz	<ul style="list-style-type: none"> • Motor de indução trifásico • Correlações cruzadas de ordem superior de módulos espectrais (CCSM)
(GUEDES <i>et al.</i> , 2024)	Falha de rolamento, estator, barras quebradas.	Sinal da corrente tensão e velocidade	---	<ul style="list-style-type: none"> • Motor de indução trifásico • Redes neurais • Máquina de vetores de suporte (SVM) • Otimização por enxame de partícula (PSO) • Evolução diferencial • K-vizinhos mais próximos

1.2. MOTIVAÇÃO

Os motores de indução trifásicos devido a sua confiabilidade, robustez e relativo baixo custo estão presentes em praticamente todos os processos fabris, desde o mais simples até o mais complexo, sendo por isso a principal força motriz do setor industrial.

Avaliar as condições de operação e evitar falhas nos MITs são fatores primordiais para manter esses equipamentos em boas condições de operação. Aos profissionais responsáveis pela manutenção desses equipamentos, é fundamental que estejam atualizados sobre as melhores práticas e tecnologias utilizadas no diagnóstico de falhas em motores de indução trifásicos, medidas que podem reduzir paralisações inesperadas na produção e que contribuem na redução de custos de reparos e substituições.

Estudos estatísticos sobre as principais falhas em motores de indução, realizados pela IEEE (*Institution of Electrical and Electronics Engineers*), pela ABB (*ASEA Brown Boveri*) e pela EPRI (*Electric Power Research Institute*) estimaram que entre 40 a 51% das falhas que ocorrem em motores de indução estão relacionados a falhas em rolamentos (CHOUDHARY *et al.*, 2019; LUCAS *et al.*, 2021). Na **Figura 1.1** verificam-se os principais componentes que mais apresentam falhas nos motores de indução, o principal índice de ocorrência de falhas ocorre nos rolamentos, seguido de falhas no estator.

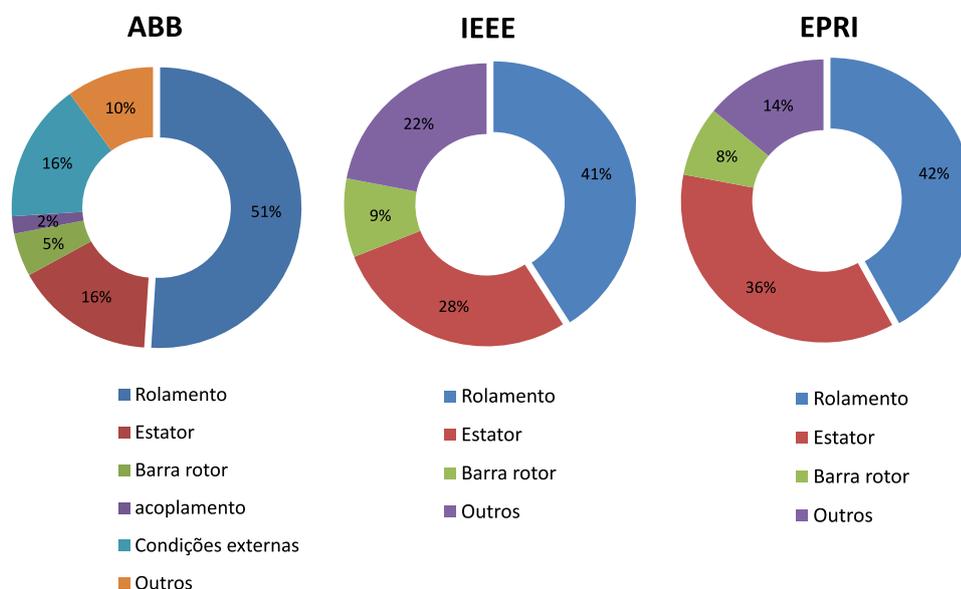


Figura 1.1- Principais tipos de falhas em motores de indução (Fonte: Adaptado de (CHOUDHARY *et al.*, 2019)).

A análise da vibração mecânica é praticamente o meio mais utilizado na indústria para detectar falhas em rolamentos em MITs, tendo como restrições seu relativo alto custo

e em alguns casos inacessibilidade para fixar o acelerômetro na carcaça de motores que demandam aplicações específicas. O método utilizando o som emitido pelo motor, não é invasivo e possui relativo baixo custo, por usar apenas um microfone na captura de sinais, entretanto é um método suscetível a interferências devido a ruídos presentes no meio, ruídos esses que estão presentes constantemente no chão de fábrica. Já o método MCSA utiliza a corrente do motor para detectar falhas em rolamentos e em muitos casos não demanda sensores de correntes adicionais, o que torna o processo menos custoso e mais acessível. O método é considerado como não invasivo. Tais fatores tem despertado interesse cada vez maior na sua aplicação como ferramenta no auxílio de diagnóstico de falhas em rolamentos de MITs.

Na literatura, por meio da aplicação do método MCSA, a principal técnica utilizada para detectar as frequências características de falhas nos rolamentos utiliza a FFT como ferramenta de análise do espectro do sinal da corrente. A grande desvantagem do método MCSA é sua ineficácia de detectar falhas em estágio incipiente, ou até mesmo falhas já avançadas. Essa problemática está associada a diversos fatores, sendo o principal deles a incapacidade da falha no rolamento de gerar excentricidade suficiente para que ocorra a modulação da frequência de falha na corrente elétrica do MIT. Consequentemente, essa modulação não pode ser detectada por meio da análise do sinal da corrente.

Há uma necessidade crescente no desenvolvimento de novos métodos de detecção e diagnóstico de falhas em rolamentos e estudos contínuos para suplantam métodos clássicos, que possuem limitações em termos de precisão, sensibilidade e nível de invasividade.

No presente trabalho, foi adotada uma abordagem experimental que utilizou os sinais de corrente de um motor de indução trifásico (MIT) e a técnica SAC-DM (*Signal Analysis based on Chaos using Density of Maxima*) em conjunto com uma rede neural MLP (*Multi-Layer Perceptron*). O objetivo foi desenvolver uma nova metodologia para diagnosticar falhas em rolamentos, garantindo que o novo método proposto seja confiável, robusto e de baixo custo, tanto em termos computacionais quanto em relação aos equipamentos envolvidos no processo.

Pretende-se, com esta nova abordagem, contribuir para o desenvolvimento de novos métodos de diagnóstico de falhas em rolamentos que possam ser efetivamente utilizados no chão de fábrica. Esses métodos auxiliariam na redução de paradas inesperadas de maquinários que utilizam motores de indução trifásicos, contribuindo para a redução de custos e aumento da segurança.

1.3. HIPÓTESES

Este trabalho, de cunho experimental, foi realizado no laboratório do GPICEEMA (Grupo de Pesquisa em Instrumentação e Controle em Estudo de Energia e Meio Ambiente) localizado no centro de tecnologia da UFPB. Foi utilizada uma bancada de torque controlável projetada para realizar testes de eficiência e diagnóstico de falhas em motores de indução trifásicos.

A pesquisa utilizou dados coletados de diversos sensores usados no monitoramento da bancada, com especial destaque para: Sensores de corrente e tensão, velocidade, torque, vibração e som.

Foram realizados estudos para diagnosticar falhas em rolamentos utilizando o sinal da corrente e um desdobramento da teoria do caos conhecido por SAC-DM. Outros dois métodos utilizando os sinais de vibração mecânica e sonora foram implementados como métodos comparativos.

A partir dos sinais da corrente do MIT a seguinte hipótese foi formulada:

- É possível diagnosticar falhas insipientes em rolamentos utilizando o sinal da corrente através da técnica SAC-DM.

1.4. OBJETIVOS

1.4.1. Objetivo geral

O objetivo geral do presente trabalho consiste no desenvolvimento de um método de diagnóstico de falhas em rolamentos de motores de indução trifásicos via abordagem densidade de máximos a partir do sinal da corrente do estator.

1.4.2. Objetivos específicos

- Instrumentalizar a bancada de torque controlável, a fim de adquirir diversos sinais como: tensão, corrente, torque, velocidade, vibração e som;
- Desenvolver algoritmos de aquisição de sinais;

- Simular falhas no motor de indução trifásico, especificamente nos rolamentos, e posteriormente fazer a aquisição de diversos sinais de interesse;
- Implementação de algoritmos a fim de detectar as frequências características de falha de rolamento através dos sinais de vibração mecânica e sonora;
- Utilizar a técnica SAC-DM em conjunto com uma rede neural artificial para diagnosticar falhas em rolamentos por meio da análise do sinal da corrente;
- Criação de um banco de dados para pesquisas futuras.

1.5. ORGANIZAÇÃO DO TRABALHO

O presente trabalho está dividido em 6 capítulos, a saber:

- **Capítulo I** – É apresentada uma introdução sobre falhas em rolamentos de motores de indução trifásicos, posteriormente é apresentado um compilado com os principais trabalhos acerca dos métodos e técnicas utilizadas no diagnóstico de falhas em rolamentos, em sequência é apresentada a motivação e os objetivos da pesquisa.
- **Capítulo II** – Neste capítulo é apresentada a fundamentação teórica, mostrando os principais aspectos dos MITs e as principais características dos rolamentos bem como as principais técnicas utilizadas na detecção de frequências características de falhas em rolamentos.
- **Capítulo III** – São apresentadas algumas técnicas de processamento de sinais e alguns fundamentos da teoria do caos, bem como algumas técnicas de análise de séries temporais para determinar sua dinâmica caótica determinística, é apresentada também a técnica SAC-DM e uma breve explanação sobre redes neurais artificiais.
- **Capítulo IV** – São apresentados todos os componentes experimentais utilizados no trabalho bem como os métodos desenvolvidos para detecção das frequências características de falhas.
- **Capítulo V** – São apresentados os resultados da análise dos sinais de vibração mecânica e sonora bem como dos sinais da corrente, com intuito de detectar as falhas no rolamento.
- **Capítulo VI** – São apresentadas as conclusões finais alcançadas neste trabalho.

CAPÍTULO II

2. FUNDAMENTAÇÃO TEÓRICA

2.1. MOTOR DE INDUÇÃO TRIFÁSICO

Por ser robusto, relativo baixo custo, ter um bom rendimento e simplicidade de acionamento, o motor de indução é o mais utilizado de todos os tipos de motores elétricos. As máquinas de indução são designadas assim pelo fato de que uma tensão é induzida nos enrolamentos do rotor em vez de ser fornecida por meio de uma conexão física (CHAPMAN, 2013).

Os motores de corrente alternada são motores robustos que podem ser alimentados diretamente da rede elétrica sem a necessidade de retificação da energia o que permite sua empregabilidade nos mais diversos setores. Na **Figura 2.1** é possível verificar as principais categorias de motores de indução trifásicos.

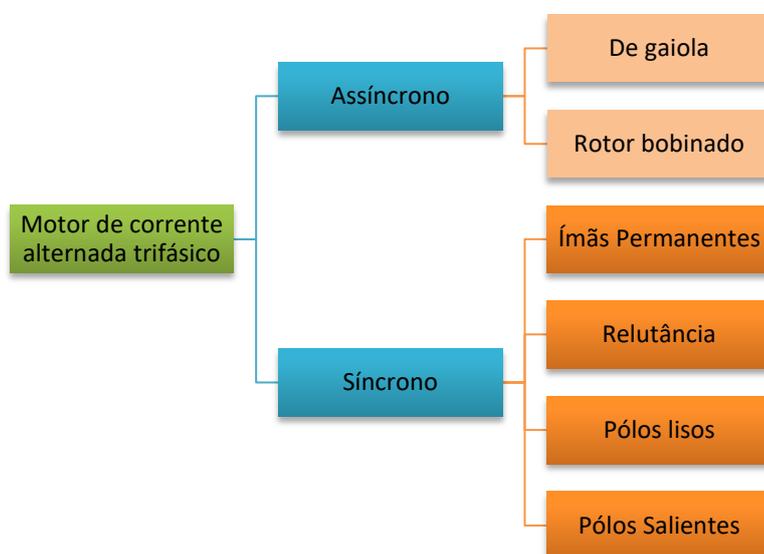


Figura 2.1-Classificação dos tipos de motores de indução trifásicos (Fonte: WEG, 2023)

O motor síncrono funciona com uma velocidade fixa, ou seja, sem interferência no escorregamento, geralmente é utilizado para grandes potências ou quando há a necessidade de velocidade invariável. O motor de indução funciona com uma velocidade constante, podendo variar de acordo com a carga mecânica aplicada. Por suas qualidades o motor de indução é o mais comercializado de todos e pode substituir em vários casos os motores de corrente contínua, isso se deve ao fato de que com a utilização do inversor de frequência é possível ter um controle de velocidade eficiente possibilitando reduzir gastos e prevenir falhas (WEG, 2023).

Além do estator e do rotor outras peças globais fazem parte do MIT, o que lhe permite ser transportado, fixado e receber a alimentação da rede elétrica. Na **Figura 2.2** são mostrados os principais componentes de um motor de indução trifásico e suas principais características, segundo (WEG, 2023).

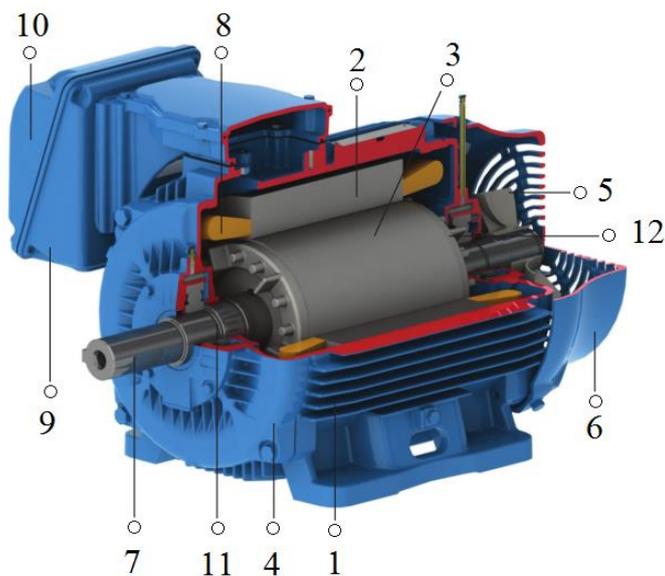


Figura 2.2- Componentes do MIT (Fonte: Adaptado de (WEG, 2023))

Componentes do estator:

- **(1) carcaça** – É o corpo do motor, a parte externa, estrutura geralmente feita de ferro fundido, aço ou alumínio injetado, materiais resistentes a corrosão e possui aletas para ajudar na dissipação do calor;
- **(2) Núcleo de chapas** – As chapas são geralmente de aço magnético permitindo criar campo magnético entre a bobina e o rotor;

- **(8) Enrolamento trifásico** – Composto por três conjuntos de bobinas, sendo uma para cada fase, formando um sistema trifásico responsável pela criação do campo girante, é alimentado pela rede de alimentação trifásica.

Componentes do rotor:

- **(7) Eixo** – Responsável por transmitir potência mecânica desenvolvida pelo motor;
- **(3) Núcleo de chapas** – Também feitas de aço magnético, responsável por criar campo magnético;
- **(13) Barras e anéis de curto-circuito** – Geralmente feitos de alumínio injetado sob pressão numa peça única, materiais como alumínio permite reduzir o peso do motor.

Outros componentes

- **(4) Tampa** – Responsável por proteger o motor além de ser ponto de apoio do eixo atrás de um enrolamento;
- **(5) Ventilador** – Responsável por refrigerar internamente o motor, é fixado na parte de trás, aproveitando assim o movimento de rotação do próprio eixo;
- **(6) Tampa defletora**- Responsável por proteger a parte traseira do motor
- **(9) Caixa de ligação**- É onde se encontra a parte de ligação elétrica do motor, permitindo receber alimentação da rede trifásica;
- **(10) Terminais**- São os terminais das bobinas do motor. Parte responsável por receber a alimentação da rede trifásica, permitindo o acionamento do motor, geralmente tem duas configurações de acionamento em estrela ou triângulo;
- **(11) Rolamento** – Responsável por apoiar o rotor permitindo que ele gire, oferecendo baixa resistência ao movimento de rotação.

2.2. ROLAMENTOS

A humanidade distingue-se das demais espécies pela sua capacidade de adaptação e engenhosidade para a criação de ferramentas, tais habilidades vem sendo aperfeiçoadas ao longo da história. O primeiro registro da utilização dos mancais de rolamento vem dos trabalhadores egípcios que atuavam na construção e que tinham o árduo trabalho de mover pesados blocos de pedras, provavelmente antes do ano 200 a.C. Os Assírios também utilizaram mecanismo semelhante em cerca de 650 a.C. Entretanto, foi graças a Leonardo da Vinci, por volta de 1500, que lançou os fundamentos modernos sobre os mancais de rolamento do tipo esferas e roletes. Na França do século XVIII algumas poucas unidades de mancais de esferas e de roletes foram construídos, principalmente para serem empregados em carruagens (JUVINALL e M.MARSHEK, 2008).

Segundo NORTON (2013, p. 653), foi somente no século 20 que materiais melhores e tecnologia de manufatura permitiram que fossem feitos mancais precisos de elementos rolantes. Desde a segunda guerra* mundial graças aos esforços consideráveis em pesquisa resultaram em mancais de elementos rolantes de alta qualidade e alta precisão e que podem ser encontrados a um preço razoável.

Graças à padronização métrica adota na fabricação dos rolamentos é possível encontrar diversos modelos a um relativo baixo custo, a depender das características de projeto. Segundo NORTON (2013) os mancais de elementos rolantes podem ser agrupados em duas categorias gerais, sendo eles: mancais de esferas e mancais de rolos, ambos com muitas variações dentro dessas divisões. Mancais de esferas são mais adequados para aplicações pequenas e de alta velocidade, já para sistemas grandes e de carga pesada os mancais de rolos têm a preferência.

Ainda de acordo com o autor supracitado, um mancal de elemento rolante consiste basicamente em: Dois anéis – um interno e outro externo; Um conjunto de elementos girantes, colocados entre as pistas dos anéis, que gira para que as cargas axiais e radiais possam ser transmitidas. Na **Figura 2.3** é possível observar os elementos que compõem um mancal de esfera típico. Os mancais rígidos de esferas são os mais populares, e podem suportar carga axial e radial podem ainda operar em velocidades mais altas (JUVINALL e M.MARSHEK, 2008).

* Fato histórico – Durante a ofensiva dos aliados contra o eixo, na segunda guerra mundial, os alvos prioritários dos bombardeiros eram as fábricas de rolamentos, tendo em vista que praticamente todas as máquinas de guerra utilizavam esse importante elemento mecânico.

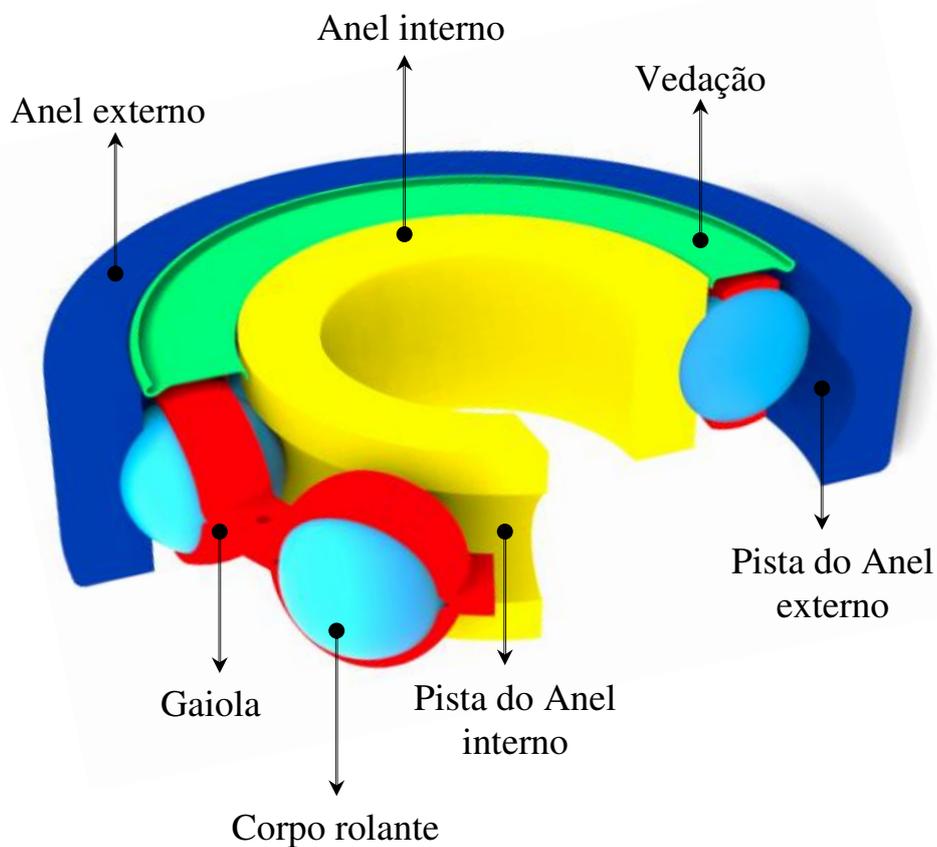


Figura 2.3 – Rolamento rígido de esferas e seus principais componentes.

A maioria dos mancais de esferas modernos é feito de aço AISI 5210 e endurecida a um alto grau, inteiramente ou somente na superfície. Essa liga de cromo-aço é endurecível completamente a HRC 61-65. Mancais de rolos são frequentemente feitos de ligas de aços endurecíveis AISI 3310, 4620 e 8620. Melhorias recentes nos processos de manufatura de aço resultaram em aços para mancais com níveis reduzidos de impurezas. Mancais feitos com esses aços “limpos” mostram vida útil mais extensa e confiabilidade. Embora se considere que os mancais de rolamento tenham vida finita quanto à fadiga, e isso ainda se aplica aos mancais “comuns”, os mancais de elementos rolantes (MER) feitos de aços “limpos” têm dado evidências, recentemente, de limite de resistência de vida infinita quanto à fadiga superficial (NORTON, 2013).

Todos os maiores fabricantes de rolamentos utilizam dimensões padronizadas definidas pela Associação dos Fabricantes de Mancais Antiatrio (AFBMA) e Organização Internacional de Padrões (ISO), de forma que um mancal de rolamento quando precise ser substituído possa ser trocado por outro de igual especificação independente do fabricante.

2.2.1. Principais tipos de rolamentos

A finalidade de um rolamento é suportar uma carga enquanto permite o movimento relativo entre dois elementos de uma máquina. Os principais tipos de rolamentos são os rolamentos de esferas e os rolamentos de rolos, ambos podendo ser divididos nas categorias axial e radial. De forma geral os mancais de elementos rolantes são compostos por diversas partes, uma pista interna, uma pista externa e um separador ou gaiola que tem por objetivo evitar a fricção entre os rolos ou esferas e manter o espaçamento correto entre os elementos rolantes. A depender do tipo do rolamento e das necessidades de projeto os mancais de rolamento podem receber tampas para vedação, para manter a lubrificação e evitar partículas que podem reduzir a vida útil do elemento.

Rolamentos de esferas são utilizados em aplicações nas quais a carga é radial com alguma carga axial presente. Já os rolamentos de rolos utilizam como elementos rolantes rolos retos, cônicos ou abaulados, que correm entre pistas. Os mancais de rolos podem suportar cargas estáticas e dinâmicas (choque) maiores que os mancais de esferas e são mais baratos para tamanhos maiores e cargas maiores (NORTON, 2013). Na **Figura 2.4** é possível visualizar alguns tipos de rolamentos, sendo o mais comum o de esferas (a) para cargas radiais e (b) para cargas axiais, e rolamentos de rolos cilíndricos (c) para cargas radiais e (d) para cargas axiais.

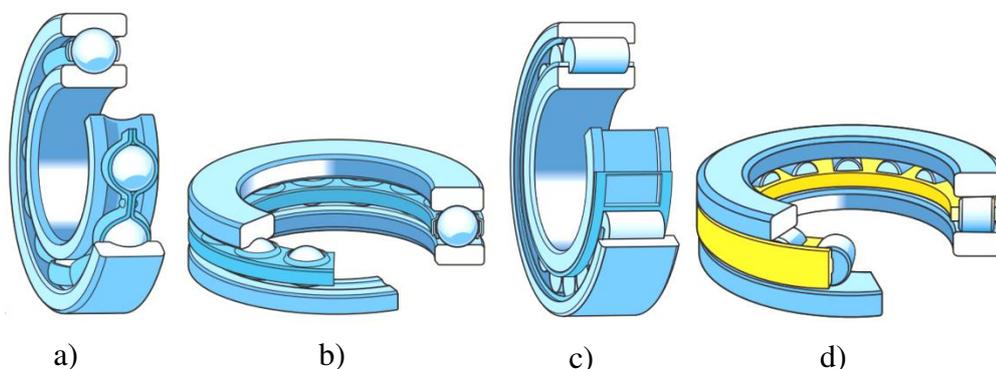


Figura 2.4- Tipos de rolamentos a) Rolamento rígido de esferas, b) rolamento axial de esferas, c) rolamento de rolos cilíndricos, d) rolamento axial de rolos cilíndrico. (Fonte: (SKF, 2015)).

2.2.2. Principais causas de falhas em rolamentos

A função dos rolamentos em motores elétricos é de apoiar e alinhar o rotor, manter o espaço do entreferro consistente, além de transferir cargas ao eixo para a carcaça do motor. Outra função importante dos rolamentos consiste em minimizar o atrito e economizar energia. O projetista deve considerar muitos parâmetros ao selecionar o tipo e o arranjo de rolamento a ser utilizado, a fim de atender aos requisitos de qualquer aplicação específica do motor, o projeto deve ser econômico tanto em termos de fabricação quanto de manutenção (SKF, 2015).

Falha em um único mancal de rolamento pode comprometer toda uma cadeia produtiva, sendo fundamental uma boa manutenção e se possível monitoramento constante desses elementos. Os principais fatores de falhas estão ilustrados na **Figura 2.5** e estão subdividido em quatro partes principais. Vale ressaltar que os danos e conseqüentemente os números variam de acordo com a indústria e aplicação. Na indústria de papel e celulose, por exemplo, uma das principais causas de falhas do rolamento é a contaminação e lubrificação inadequada (SKF, 2022).

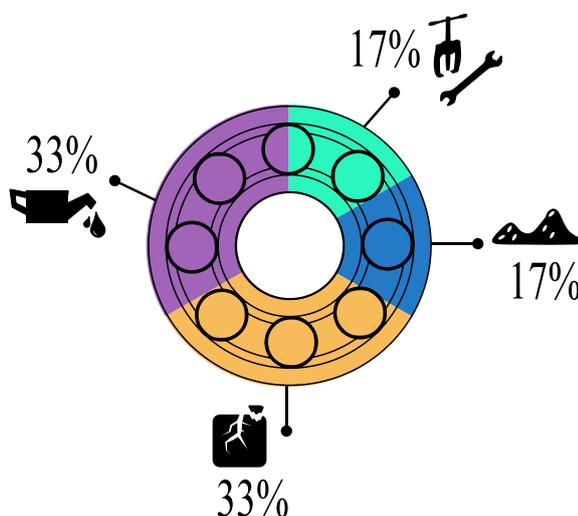


Figura 2.5- Principais causas de falhas em rolamentos (Fonte: (SKF, 2022)).

Segundo dados fornecidos pela SKF (*Svenska Kullager Fabriken*), multinacional sueca que atua na fabricação de rolamentos, existem diversas razões que podem levar um rolamento a falha, de modo geral, 1/3 dessas falhas estão relacionadas a fadiga; 1/3 esta relacionado a problemas de lubrificação (lubrificante errado, quantidade errada, intervalo

de lubrificação); outros 1/6 falham devido a contaminação (problemas de vedação ineficiente), já as falhas dos 1/6 restantes, estão relacionadas a outros motivos (montagem incorreta, manuseio inadequado, carregamento diferente do previsto, erro de manufatura). Cada um desses eventos produz uma marca de danos única, de tal forma que analisando esses padrões é possível, detectar a causa raiz dos danos e conseqüentemente aplicar ações corretivas para evitar a recorrência do problema (SKF, 2022; NORTON, 2013).

Segundo BUDYNAS e NISBETT (2020) se um rolamento estiver limpo e devidamente lubrificado, for montado e selado contra a entrada de poeira e outros contaminantes, for mantido nessa condição e for operado em temperaturas razoáveis, a fadiga do metal será a única causa de falha. A falha é considerada prestes a ocorrer quando a pista ou as esferas (ou rolos), exibirem a primeira vala, geralmente a pista falhará primeiro. O mancal tende a dar sinais que a cavitação começou ao dar aviso audível emitindo ruído e vibração. O mancal de rolamento poderá continuar operando além desse ponto, entretanto continua a se deteriorar com o barulho e a vibração aumentando, de modo que mais cedo ou mais tarde virá a ocorrer fragmentação dos elementos rolantes, podendo ocasionar paradas repentinas e quebras de outros mancais (NORTON, 2013).

A seguradora Allianz de Munique na Alemanha compilou falhas típicas de rolamentos utilizando-se de uma amostra de mil e quatrocentos (1400) rolamentos esféricos constatando que cerca de 30% das falhas funcionais ocorreram por desgaste ou lubrificação (BLOCH e GEITNER, 2012). Na são listados os defeitos do rolamento de esfera simples ou modos de falha com suas causas mais prováveis. Em cada caso, os defeitos refletem a experiência com as metalurgias tradicionais dos rolamentos apresentada em BLOCH e GEITNER (2012).

Tabela 2.1- Modos de falhas em rolamentos e suas causas (Fonte: (BLOCH e GEITNER, 2012))

		Modos de falha																
		Fratura/Separação				Deformação						Desgaste			Corrosão			
		Descamação/Lascamento	Trincas de calor	Raspagem (Empastamento) -> Emperramento	Fratura na gaiola	Deformação da gaiola	Indentações	Amassos por fragmentos	Brinelamento/Falso brinelamento	Pista da esfera - Alargado	Pista da esfera - Enviésado	Pista da esfera - Zona de cargas desiguais	Esfriamento	Desgaste da gaiola	Desgaste abrasivo/ Desgaste	Superaquecimento -> Queimadura -> Desgaste por roçamento	Corrosão/ Ataque químico	Corrosão e fretagem em juntas
		Causas da falha																
Montagem	Aplicação de calor desigual/ Excessiva	☞																
	Pancadas de martelo		☞			☞		☞										
	Ferramentaria Imprópria				☞	☞		☞										
	Montagens frouxas/ Apertadas		☞											☞			☞	
	Caixas de rolamentos distorcidas	☞						☞		☞								
	Desbalanceamento do rotor										☞							
	Desalinhamento				☞	☞				☞	☞			☞				
Condições operacionais	Vibração Móvel/estacionário	☞				☞		☞					☞		☞		☞	
	Passagem de corrente											☞				☞		
	Fim da vida útil/ Fadiga	☞																
	Sobrecarga	☞	☞							☞					☞			
	Erro de projeto		☞	☞										☞				
	Contaminação						☞	☞					☞	☞		☞		
Vedação	Entrada de umidade															☞	☞	
	Falta de lubrificante			☞	☞								☞	☞	☞		☞	
Lubrificação	Excesso de lubrificante			☞										☞				
	Lubrificante não compatível			☞					☞				☞	☞	☞		☞	

2.3. TÉCNICAS UTILIZADAS NA DETECÇÃO DE FALHAS EM ROLAMENTOS

Os motores de indução trifásicos podem ser divididos fundamentalmente em três elementos, o rotor o indutor e os rolamentos. É possível que as falhas possam ocorrer em qualquer um desses elementos, podendo ser divididas em falhas mecânicas e falhas elétricas. Na **Figura 2.6** são apresentados os principais tipos de falhas que podem ocorrer em um motor de indução, sendo o rolamento o componente que apresenta o maior número de falhas podendo chegar a 41% do total de falhas presente no MIT. Vale destacar ainda o rotor, que pode apresentar tanto falhas mecânicas quanto falhas elétricas (GANGSAR e TIWARI, 2020; LUCAS *et al.*, 2021)

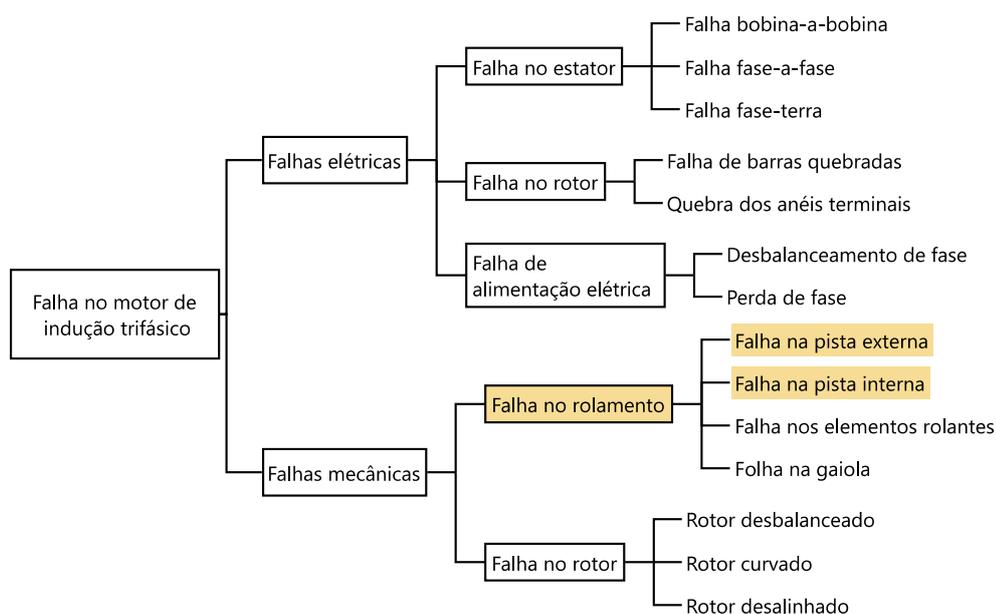


Figura 2.6 - Tipos de falhas comuns em motores de indução (Fonte: Adaptado de (GANGSAR e TIWARI, 2020))

As frequências de defeito do rolamento são funções lineares da velocidade de operação do motor. Segundo OCAK e LOPARO (2004) para uma geometria de rolamento específica, falhas na pista interna, na pista externa e no elemento rolante geram espectros de vibração com componentes de frequência exclusivos. São esses componentes de

frequência únicos e suas magnitudes que tornam possível determinar a condição do rolamento. Já a frequência Características de Falha (FCF) para falha na pista externa e falha na pista interna, também são funções lineares do número de esferas no rolamento.

Segundo LUCENA-JUNIOR *et al.* (2020) o sinal de vibração de um rolamento defeituoso pode ser interpretado como uma forma de onda de amplitude modulada com a frequência de ressonância da estrutura como a frequência da portadora e FCF como a frequência do sinal de amplitude modulada. Um motor elétrico com rolamento defeituoso pode gerar pelo menos cinco frequências características.

Em TAYLOR (2003) capítulo cinco, o autor demonstra através de conceitos físicos e matemáticos o desenvolvimento analítico das equações em sua forma mais abrangente, de forma a obter as equações para o cálculo teórico das frequências de falha para a pista externa, interna, nos elementos rolantes e na gaiola. Na **Figura 2.7** são evidenciadas as variáveis geométricas utilizadas no cômputo das frequências de falha, de forma que o número de elementos rolantes e a velocidade de rotação do eixo são preponderantes neste processo.

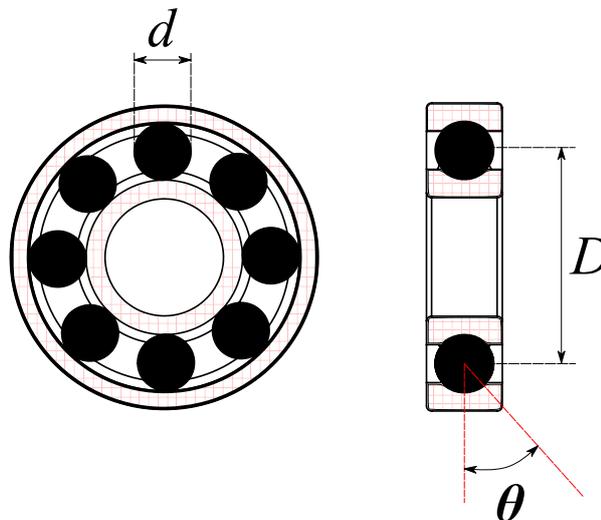


Figura 2.7- Variáveis geométricas do rolamento

Frequência de passagem do elemento rolante na pista externa:

$$BPFO = \frac{Nf_r}{2} \left(1 - \frac{d}{D} \cos\theta\right) \quad (2.1)$$

Frequência de passagem do elemento rolante na pista interna:

$$BPFI = \frac{Nf_r}{2} \left(1 + \frac{d}{D} \cos\theta\right) \quad (2.2)$$

Frequência fundamental do trem (velocidade da gaiola):

$$FTF = \frac{f_r}{2} \left(1 - \frac{d}{D} \cos\theta\right) \quad (2.3)$$

Frequência de rotação do elemento rolante (esfera ou rolo):

$$BSF = \frac{Df_r}{2d} \left[1 - \left(\frac{d}{D} \cos\theta\right)^2\right] \quad (2.4)$$

De modo, que: BPFO é a frequência da pista externa, BPFI frequência da pista interna, BSF é a frequência da esfera ou rolo e FTF é a frequência da gaiola, já para as variáveis geométricas do rolamento: D corresponde ao diâmetro primitivo do rolamento, d é o diâmetro da esfera e θ é o Ângulo de contato, já N é Número de esferas e f_r é a frequência de rotação do eixo. Na maioria dos casos, a pista externa do rolamento é estacionária (nos motores de indução trifásicos este caso se aplica).

São vários os tipos de técnicas utilizadas no diagnóstico de falhas em máquinas rotativas. Os defeitos que ocorrem em uma máquina sempre exibem um sintoma na forma de vibração ou algum outro parâmetro. No entanto, isso pode ou não ser facilmente detectado em sistemas de máquinas com percepções humanas. As técnicas utilizadas pela manutenção preditiva e detectiva, detectam sintomas dos defeitos que ocorrerem nas máquinas e auxiliam no diagnóstico do mesmo, conseguindo em alguns casos estimar a gravidade dos defeitos. Cada técnica, em específico, depende do tipo de equipamento disponível na planta. Entre as principais técnicas usadas no diagnóstico de falhas em máquinas elétricas rotativas, destacam-se, monitoramento da vibração mecânica, monitoramento da corrente elétrica, emissão acústica e análise termográfica (GIRDHAR e SCHEFFER, 2004).

Na **Figura 2.8** são exemplificados os principais tipos de testes e técnicas utilizadas na detecção de falhas em motores de indução trifásicos, em especial destaque para as três técnicas utilizadas no presente trabalho.

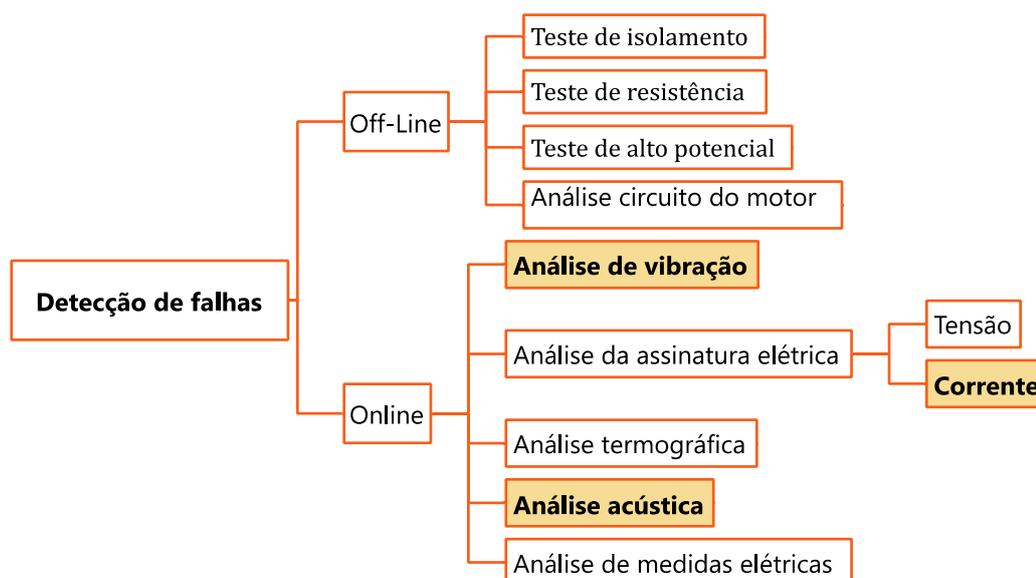


Figura 2.8 - Organograma dos métodos de detecção de falhas (Fonte: Adaptado de (CRUZ, 2015))

2.3.1. Detecção de falhas via vibração mecânica

A detecção de falhas através da vibração mecânica é sem duvidas a técnica mais eficaz para detectar defeitos mecânicos em máquinas rotativas, o que inclui os MITs (GIRDHAR e SCHEFFER, 2004; AMAR *et al.*, 2015). Destaca-se também por ser de relativo baixo custo e por ter medição do sinal de vibração imediata. O sinal da vibração pode ser utilizado para detectar falhas elétricas, como: curto em enrolamentos, barras quebradas entre outros, e falhas mecânicas, a saber, rolamentos, desbalanceamentos no eixo do motor (GLOWACZ, 2019).

A vibração mecânica pode ser definida como o movimento oscilante, alternativo ou outro movimento periódico de um corpo ou meio rígido ou elástico forçado a partir de uma posição ou estado de equilíbrio (RAYNER, 1995).

Quando se trata de máquinas rotativas (como é o caso do motor de indução trifásico) a vibração é o parâmetro mais comumente monitorado e há duas razões para isso, a primeira é que pode ser medida por meio de instrumentação apropriada, e a segunda é que as vibrações fornecem uma reflexão abrangente do estado de uma máquina rotativa (LEES, 2020).

A principal forma de medir o nível de vibração em uma máquina rotativa para decidir se está dentro dos limites aceitáveis é utilizando acelerômetro(s) associado a algum dispositivo de aquisição de dados. Há no mercado uma gama muito diversa desses

equipamentos, de modo que requer por parte do especialista a escolha adequada para determinada aplicação, levando-se em consideração a faixa de frequência que se pretende medir e a sensibilidade necessária, além de levar em consideração o ambiente que o mesmo vai operar (SUJATHA, 2023).

Um passo importante no processo de coleta dos dados de vibração é definir onde fixar o acelerômetro, em se tratando de análise de falhas em rolamentos, de modo geral os transdutores devem estar localizados o mais próximo possível dos mancais de modo a obter os valores máximos de vibração (ISO 13373, 2002). Quando é possível ter acesso ao motor elétrico e não há impedimentos para fixar o acelerômetro na carcaça do motor é desejável que ele fique em uma das posições exemplificadas na norma ISO 10816, de modo a atender os critérios de avaliação de níveis de vibração para estimar a gravidade dos defeitos (SANTOS, 2017).

Algumas carcaças de motores elétricos de indução trifásicos já dispõem de pontos de fixação para acelerômetros. Por exemplo, Os motores das carcaças 160 a 355 da fabricante Weg foram projetados com áreas planas em sua extremidade para receber esses instrumentos. Na **Figura 2.9** é ilustrado os pontos de fixação (ou pontos de leitura) para os acelerômetros, conforme normas descritas acima. O acelerômetro pode ser fixado tanto na direção radial quanto na direção axial, recomenda-se nomear cada leitura durante o processo de aquisição de forma clara, de modo a permitir a organização e repetitividade das medições.

Outro ponto fundamental quando se trabalha com aquisição de sinais de vibração com acelerômetros é o tipo de fixação que será adotado, levando-se em consideração o acesso à máquina rotativa, locais de fixação, tipo de material, temperatura no ponto de

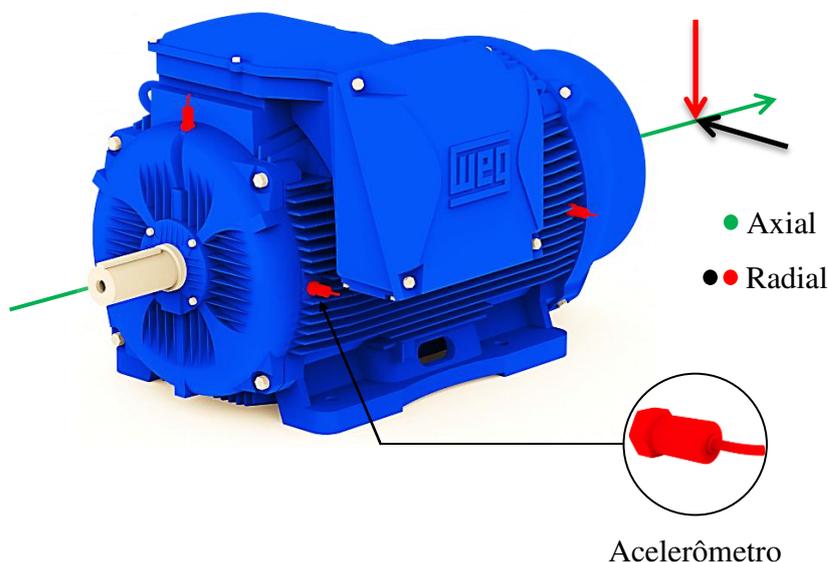


Figura 2.9 - Pontos de leitura dos sensores de vibração

apoio para a leitura, entre outros fatores. Na **Figura 2.10** é exemplificada os tipos mais comuns de fixação dos acelerômetros, observa-se na figura que a curva de frequência do acelerômetro muda conforme o tipo de fixação utilizada. Percebe-se ainda que a fixação número 6 tende a ser a mais eficiente, por receber um maior nível de vibração e também por ter uma faixa de frequência mais ampla até atingir o ponto de ressonância. Entretanto em determinadas aplicações torna-se impraticável por ser um tipo de fixação invasiva.

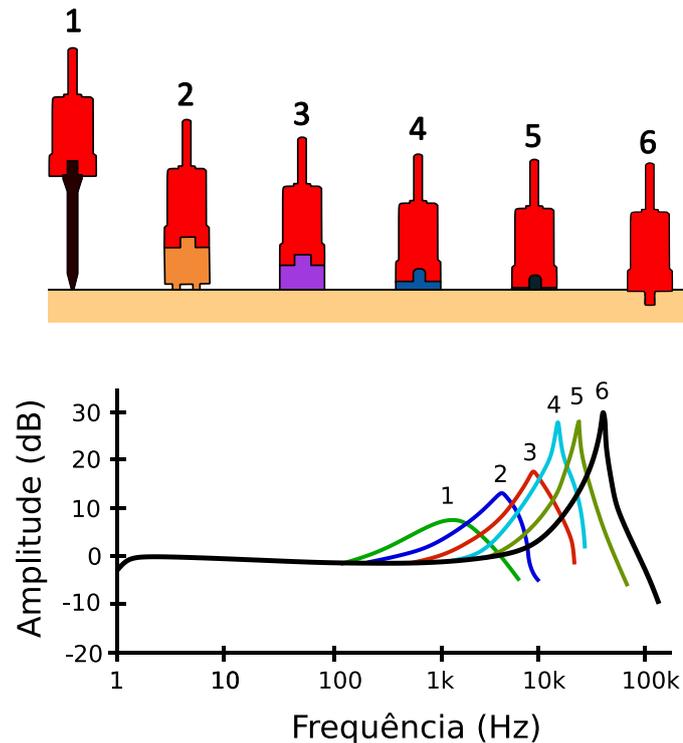


Figura 2.10 - Diferentes formas de montar um acelerômetro (Fonte: Adaptado de (KLUCZYK e GRZĄDZIELA, 2017))

Onde: 1- tipo sonda, 2-ímã de polo duplo, 3- ímã plano, 4-almofada adesiva fixada por cola, 5- fixação apenas com cola (adesivo), 6- fixado via rosca na estrutura.

Segundo KLUCZYK e GRZĄDZIELA (2017) a falta de consciência sobre o impacto de diferentes tipos de montagem do sensor no espectro registrado pode levar à decisão errada sobre a operação posterior da máquina.

Embora tenha grandes vantagens o método de detecção de falhas através da vibração mecânica, é um método invasivo, que requer a instalação de um ou mais acelerômetros próximo ao motor sendo de preferência instalado na carcaça do mesmo, assim sendo, em alguns casos essa instalação torna-se impraticável devido o difícil acesso

a que certos tipos de aplicação dos motores elétricos exigem. Ainda assim, é considerada a principal técnica de diagnóstico de falhas em rolamentos na indústria.

2.3.2. Análise de falha via sinal sonoro

Intuitivamente quebras estão associadas a sons, a exemplo, de estalos de uma árvore prestes a cair, do rompimento de um duto metálico, etc. Entretanto alguns sons indicam que alguma anomalia está acontecendo, e algo não está dentro do esperado, a exemplo de estalos periódicos em um casco de navio, na asa de uma aeronave, em um automóvel, etc. Já nas máquinas elétricas rotativas, esse fenômeno não é diferente, sons anômalos podem indicar forte indicio de falhas.

A análise do som emitido por MITs em operação pode revelar características interessantes, sendo possível, inclusive, estimar com precisão a velocidade do motor, torque e eficiência (DA SILVA, 2018). No diagnóstico de falhas as principais vantagens do método da análise sonora se destaca por ser um método não invasivo, de fácil acesso ao sinal acústico, microfones com bom custo benefício, além de ser possível analisar falhas elétricas e mecânicas (barras quebradas, falha em rolamentos, desbalanceamento, etc).

Algumas desvantagens também estão presentes, a saber, sinais acústicos emitidos pelo MIT são misturados por outros sinais acústicos presentes no ambiente, o que acaba gerando ruídos e conseqüentemente faixas de frequências indesejáveis, outra desvantagem é sua aplicação em ambientes industriais, haja vista, que a precisão da técnica de detecção de falha é reduzida devido ao ruído de fundo (GLOWACZ, 2019).

As frequências características de falhas nos rolamentos podem ser interpretadas de forma semelhante às FCFs utilizadas na abordagem usando vibração mecânica conforme Equações (2.1) a (2.4), tendo em vista que o sinal captado pelo microfone trata-se de uma onda mecânica propagada através de um meio elástico.

2.3.3. Detecção de falha via MCSA

O método de análise de assinatura de corrente do motor (*MCSA-Motor Current Signature Analysis*) é utilizado para diagnosticar os defeitos do motor ou até mesmo do inversor utilizado como fonte de acionamento do mesmo, utilizando informações da corrente do estator do motor.

O método tem grandes vantagens, tendo em vista que os sensores de corrente em muitos casos já são utilizados para monitorar as condições de operação do motor, como, por exemplo, monitorar a potência elétrica, sendo assim o método não exige sensores adicionais. Trata-se de um método não invasivo, pois não necessita de acesso direto ao motor. O método MCSA voltado para o monitoramento de motores de indução trifásicos encontra aplicações em usinas nucleares, máquinas rotativas *offshore*, indústria de defesa, além de aplicações industriais onde o motor atua em local de difícil acesso (SAADI *et al.*, 2018).

Os defeitos em rolamentos podem provocar um pequeno movimento radial do rotor (ou excentricidade), o que acabada causando distúrbios na forma de onda do fluxo do entreferro e variações pequenas no entreferro, de forma que o movimento radial tende a aumentar a medida que a severidade da falha também aumenta, o rolamento pode entrar em colapso e ocorrer fricção entre o estator e o rotor ocasionando ainda mais danos ao motor (THOMSON e CULBERT, 2016).

Segundo TOLIYAT *et al.* (2017), quando há uma excentricidade no entreferro, as indutâncias variáveis causam um fluxo magnético desequilibrado no entreferro que cria harmônicos de falha na corrente de linha, que podem ser identificados através do espectro. Existem dois tipos principais de falhas de excentricidade: excentricidade estática e excentricidade dinâmica, podendo ainda ocorrer à combinação de ambas, formando uma excentricidade mista.

Na excentricidade estática, o eixo de rotação coincide com o eixo do rotor, mas se desloca do eixo do estator. Na excentricidade dinâmica, o eixo de rotação coincide com o eixo do estator, mas não com o eixo do rotor já na excentricidade mista, o eixo de rotação é diferente dos eixos do estator e do rotor, (FAIZ e MOOSAVI, 2016; LI *et al.*, 2021) . Ainda segundo os autores os motores de indução são mais sensíveis às variações do comprimento do entreferro do que outros tipos de máquinas com tamanho e desempenho semelhantes, porque o comprimento do entreferro é muito menor. Na **Figura 2.11** são representadas as configurações de tipos de excentricidade que podem afetar o motor de indução. Uma das causas do aparecimento da excentricidade dinâmica em MITs pode ser falha no rolamento.

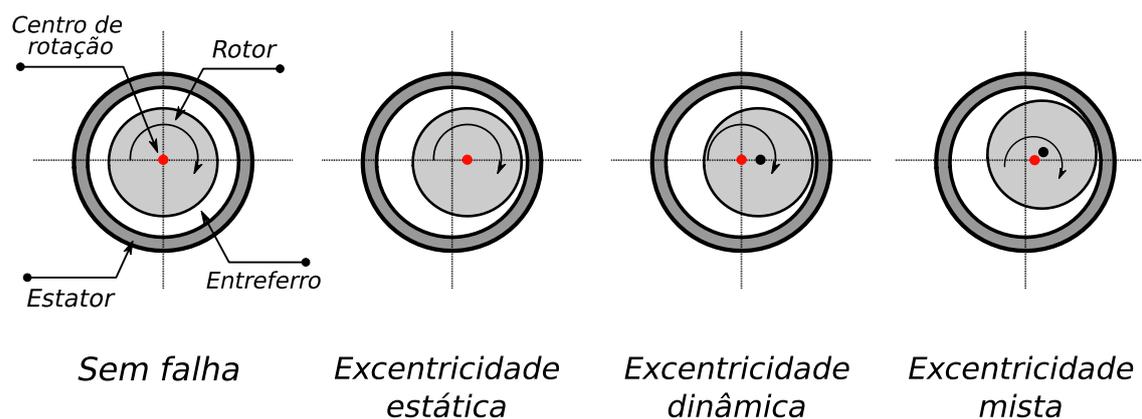


Figura 2.11- Tipos de excentricidade no motor de indução (Fonte: Adaptado de (FAIZ e MOOSAVI, 2016))

O impacto provocado pelos rolos do rolamento ao passar pelo local da falha (seja pista externa ou interna) provoca excentricidade instantânea no rotor que eleva o estado de deslocamento do entreferro além do seu estado ‘normal’ de funcionamento, de tal forma que há uma modulação desses impactos no fluxo da corrente. Dependendo do nível de severidade e das dimensões do rotor, esses impactos podem ser captados através do sinal da corrente e suas características podem ser extraídas no domínio da frequência a fim de encontrar frequências características de falhas que possam indicar a causa do problema. Na **Figura 2.12** é representado este processo, um rolamento com defeito na pista externa gera deslocamento do entreferro e através de um sensor de corrente o sinal de interesse é adquirido.

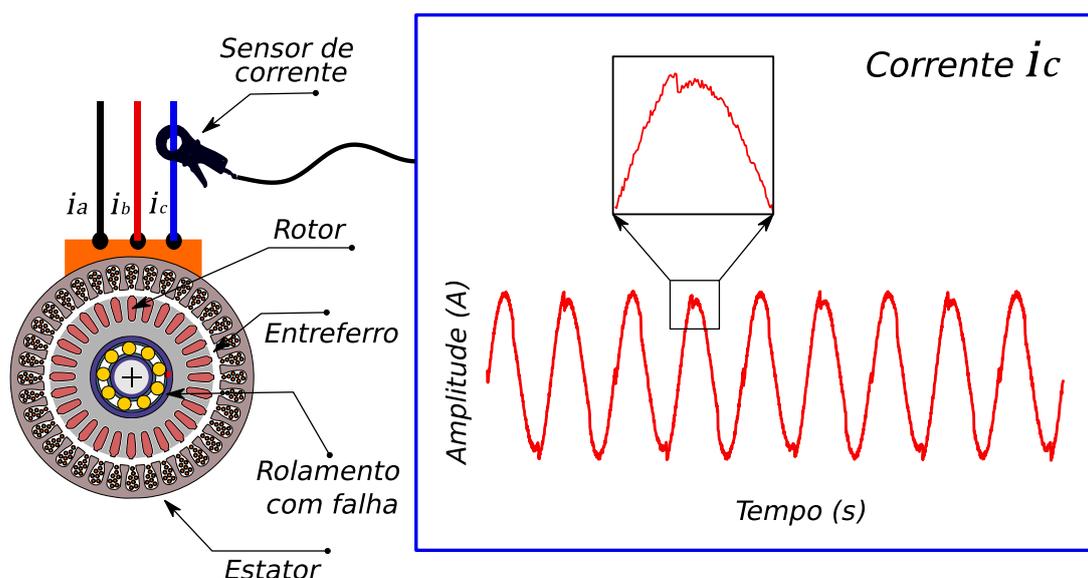


Figura 2.12 - Representação da aquisição do sinal de corrente com excentricidade provocada por falha no rolamento.

Cerca de 80% das falhas mecânicas estão relacionadas à excentricidade do rotor (LI *et al.*, 2021). Rolamento danificado faz com que o entreferro da máquina varie de uma maneira que pode ser descrita por uma combinação de excentricidades de rotação movendo-se em ambas as direções, ou seja, no sentido horário e anti-horário. De tal forma que essas variações geram correntes no estator em frequências previsíveis (BARTHELD *et al.*, 1995). A equação (2.5) relaciona às frequências vibracionais e de alimentação elétrica, tais frequências podem aparecer no espectro do sinal da corrente do estator e podem ser obtidas por:

$$f_{falha_Rolamento} = |f_s \pm kf_c| \quad (2.5)$$

Onde, f_s é a frequência da rede elétrica [Hz], k é um número inteiro positivo ($k=1,2,3\dots$) e f_c são as frequências naturais dos componentes do rolamento refletidas na corrente do estator [Hz] e $f_{falha_Rolamento}$ é a componentes espectral da corrente elétrica referente às anomalias no rolamento [Hz].

A frequência f_c nada mais é, do que a frequência de falha que se pretende analisar, para falha na pista externa $f_c = BPFO$ para falha na pista interna $f_c = BPFI$. Através de estudos estatísticos foi mostrado que se os rolamentos de esferas tiverem entre 6 e 12 elementos rolantes, então suas frequências fundamentais das pistas interna e externa, podem ser aproximadas pelas Equações (2.6) e (2.7), ; NOUREDDINE *et al.*, 2016).

$$f_c = BPFO = 0.4N_b f_r \quad (2.6)$$

$$f_c = BPFI = 0.6N_b f_r \quad (2.7)$$

Onde: N_b é o número de elementos rolantes, e f_r é a frequência de rotação do eixo do motor em [Hz].

2.3.4. Detecção de falhas via análise termográfica

A detecção de falhas usando termografia, é relativamente recente, tendo suas aplicações iniciais voltadas para a detecção de falhas em equipamentos elétricos, como sistemas de proteção elétrico em quadros de comando, linhas de transmissão, etc.

Entretanto devido a sua praticidade, logo se estendeu para outras áreas, auxiliando no diagnóstico de falhas em caldeiras, danos celulares em estruturas de fibra de carbono em aeronaves e no diagnóstico de falhas em motores elétricos (OSORNIO-RIOS *et al.*, 2019; GIRDHAR e SCHEFFER, 2004).

Segundo LOPEZ-PEREZ e ANTONINO-DAVIU (2017) a análise termográfica é uma opção muito interessante, levando em consideração que a maioria das falhas do motor geralmente leva a aumentos de temperatura, sejam elas gerais ou localizadas em regiões específicas, que podem ser detectadas via análise de dados por infravermelho. No caso de motores de indução a técnica pode ser muito útil, especialmente para motores de grande porte, cujo custo pode facilmente chegar a 1-2 milhões de dólares e cujas falhas inesperadas podem gerar perdas de vários milhões de dólares.

A **Figura 2.13** apresenta uma imagem termográfica de um MIT operando com torque de 22 N.m, com uma falha simulada de 0,5 mm na pista externa do rolamento. Ao longo deste trabalho de tese, também foi construída uma base de dados contendo imagens termográficas. Essas imagens foram capturadas utilizando uma câmera térmica Fluke Ti300, abrangendo diferentes faixas de torque e condições de falha nos rolamentos. No entanto, a análise e o processamento desses sinais não foram o foco deste estudo, ficando como uma sugestão para investigações futuras.

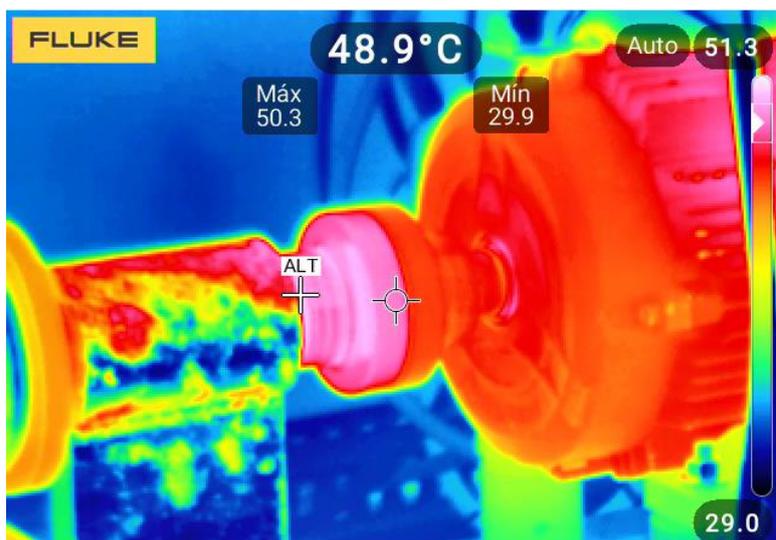


Figura 2.13 - Imagem termográfica de um MIT operando a 22 N.m com falha na pista externa com diâmetro de 0,5 mm.

CAPITULO III

3. TÉCNICAS DE PROCESSAMENTO DE SINAIS E ANÁLISE DO CAOS

3.1. TIPOS DE SINAIS E SUAS CLASSIFICAÇÕES

Sinais são funções de uma ou mais variáveis que representam fenômenos da natureza, podem representar diversas informações, como, por exemplo, voz, vibração de uma estrutura, comportamento do músculo cardíaco, etc.

3.1.1. Classificação dos sinais

Os sinais são classificados como analógicos, de tempo discreto, ou digital. Ainda podem ser caracterizados em estáticos e dinâmicos (FIGLIOLA e BEASLEY, 2020).

- ✓ **Sinal analógico:** O sinal analógico possui infinitos pontos em sua composição, descreve um sinal contínuo no tempo, **Figura 3.1**. Como as variáveis físicas tendem a ser contínuas na natureza, um sinal analógico tende a seguir o mesmo comportamento temporal dessas variáveis.

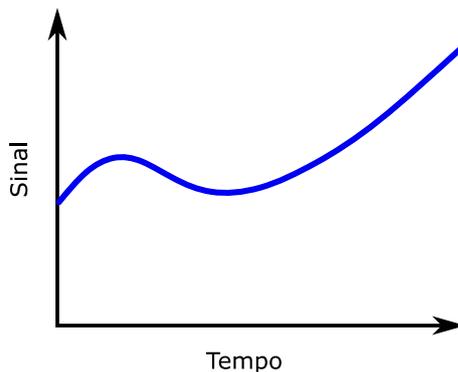


Figura 3.1- Representação sinal analógico (Fonte: (FIGLIOLA e BEASLEY, 2020))

- ✓ **Sinal digital:** O sinal digital apresenta duas características importantes. Primeira, um sinal digital existe em valores discretos no tempo, como um sinal de tempo discreto. Segunda, a magnitude de um sinal digital é discreta, determinada por um processo conhecido por quantização de cada ponto discreto no tempo. A produção de um sinal a partir de um sinal analógico é feita através de um conversor analógico digital (A/D).

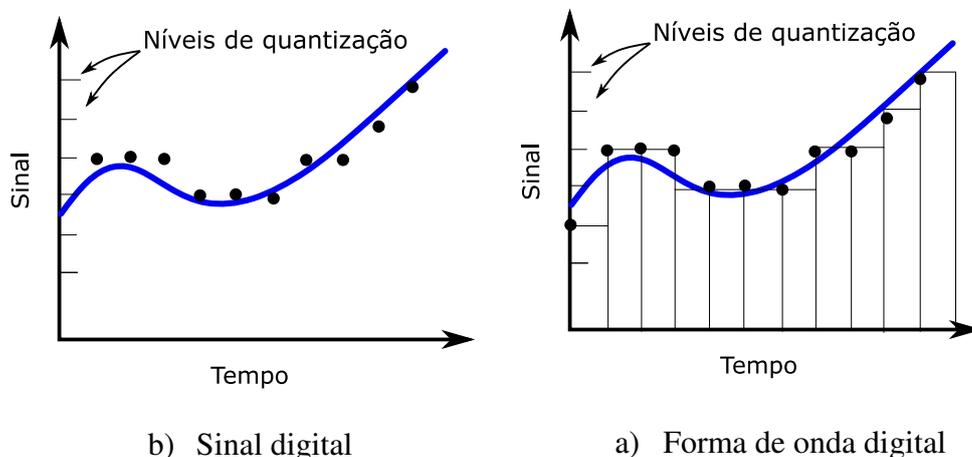


Figura 3.2- Representação e onda padrão de sinal digital (Fonte: (FIGLIOLA e BEASLEY, 2020))

Na **Figura 3.2** (a) os pontos destacados em preto representam a discretização do sinal e estão levemente afastados do sinal original que se pretende digitalizar. Durante o processo de discretização de sinais ocorrem não linearidades, que podem ser causadas por diversos motivos, sejam fatores ambientais ou ao próprio hardware de aquisição utilizado o que contribui para a injeção de ruídos no sinal digitalizado.

- ✓ **Sinal de tempo discreto:** O sinal de tempo discreto pode ser uma representação da forma digitalizada de um sinal analógico. Como o sinal analógico é contínuo e possui infinitos pontos em sua composição, representa-lo com fidelidade demandaria um alto curso computacional. Uma forma de fazer tal representação pode ser utilizando o conceito de discretização em amplitude e discretização no tempo, neste processo o sinal é fatiado, como pode ser visto na
- ✓ Figura 3.3.

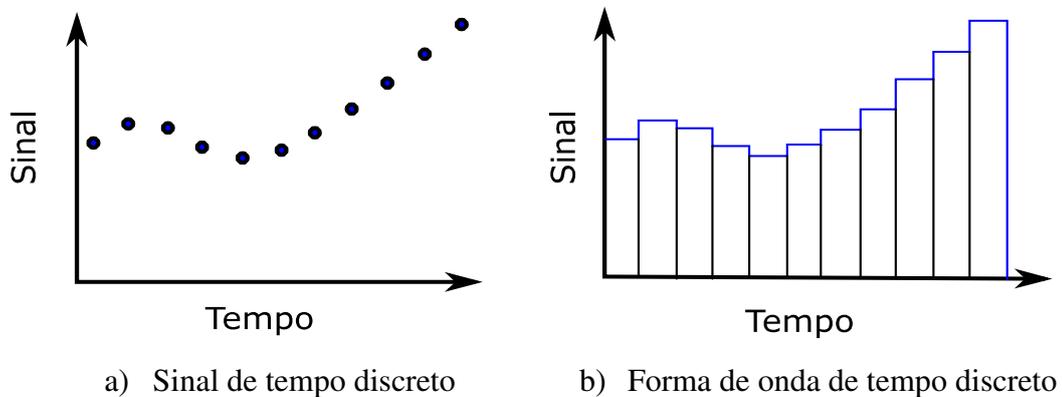


Figura 3.3-Sinal de tempo discreto (Fonte: (FIGLIOLA e BEASLEY, 2020))

3.1.2. Formas de ondas do sinal

Quanto às características estáticas e dinâmicas dos sinais, aqui representadas por $y(t)$ elas podem ser definidas como se segue:

- ✓ **Sinal estático:** É o tipo de sinal que é invariante com o tempo. Diâmetro de um eixo, por exemplo. Isso ocorre quando as variáveis físicas variam lentamente no tempo quando comparadas ao processo com o qual interagem, e na prática podem ser considerados como estáticos.
- ✓ **Sinal dinâmico:** É um sinal que depende do tempo e pode ser subdividido em:
 - a) **Determinístico:** É o sinal que varia no tempo de forma previsível, uma onda senoidal por exemplo.

- b) **Periódico estacionário:** É o sinal em que a variação da sua magnitude se repete em intervalos regulares de tempo. A trajetória de um pêndulo, por exemplo.
- c) **Periódico simples:** É o sinal que contém apenas uma componente de frequência.
- d) **Periódico complexo:** Contém múltiplas componentes de frequência e é representado como uma superposição de múltiplas formas de onda periódicas simples.
- ✓ **Sinais aperiódicos:** São sinais determinísticos que não se repetem em intervalos regulares, a exemplo as funções degrau, rampa e pulso.
- ✓ **Sinais não determinísticos:** Como o próprio nome sugere, é o sinal que, não tem um padrão perceptível e são geralmente analisados através de conceitos estocásticos.

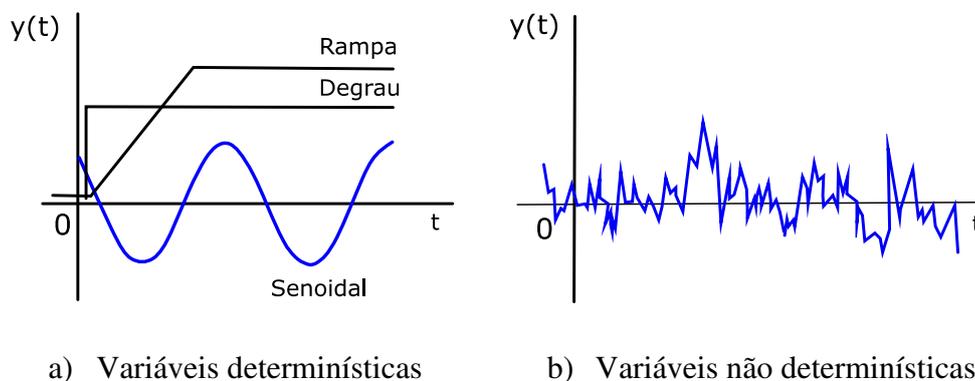


Figura 3.4- Exemplo de sinais dinâmicos.(Fonte: (FIGLIOLA e BEASLEY, 2020))

Na **Tabela 3.1** é apresentado um resumo com as principais formas de onda abordadas neste tópico e suas respectivas representações analíticas:

Tabela 3.1- Classificação das formas de onda (Fonte: (FIGLIOLA e BEASLEY, 2020))

I.	Estático	$y(t) = A_0$
II.	Dinâmico	
	Forma de onda periódica	

	Forma de onda periódica simples	$y(t) = A_0 + C \text{sen}(\omega t + \phi)$
	Forma de onda periódica complexa	$y(t) = A_0 + \sum_{n=1}^{\infty} C_n \text{sen}(n\omega t + \phi_n)$
	Forma de onda aperiódica	
	Degrau ^a	$y(t) = A_0 U(t) = A_0 \text{ para } t > 0$
	Rampa	$y(t) = Kt \text{ para } 0 < t < t_f$
	Pulso ^b	$y(t) = A_0 U(t) - A_0 U(t - t_1)$
III.	Forma de onda não determinística	Só pode ser aproximada usando informações estatísticas
^a $U(t)$ Representa a função degrau unitário, que é zero para $t < 0$ e 1 para $t \geq 1$ ^b t_1 Representa a largura de pulso		

3.1.3. Taxa de amostragem

Segundo FIGLIOLA e BEASLEY (2020) pode-se sintetizar o conceito de amostragem como a obtenção de uma boa representação, por meio de uma série discreta, do sinal analógico referente à amplitude e frequência de um dado sinal, dependendo do conteúdo da frequência desse sinal, do tamanho do incremento do tempo entre cada número discreto e do período total de amostragem da medição. Na **Figura 3.5** é possível verificar a representação de um sinal analógico e discreto variando com o tempo.

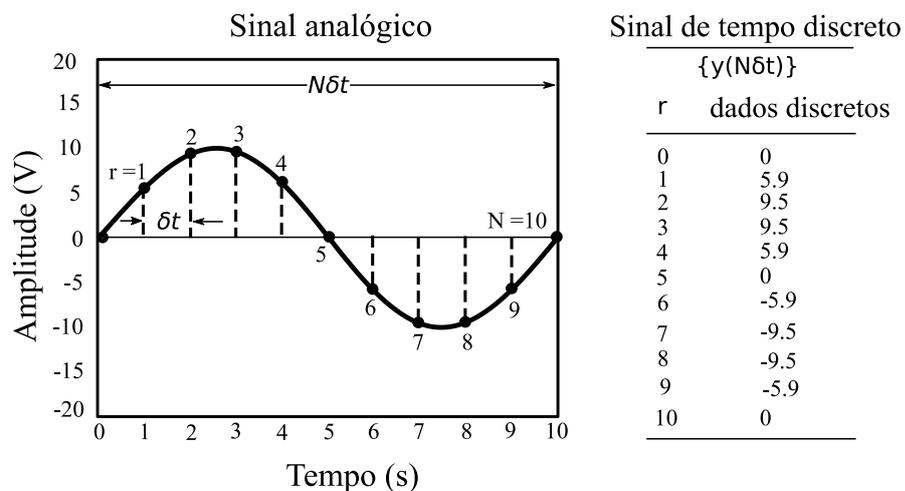


Figura 3.5- Amostragem de um sinal analógico (Fonte: (FLIGIOLA e BEASLEY (2020))).

Analisando o gráfico da **Figura 3.5** é o possível estabelecer o tempo total de amostragem, como sendo $N\delta t$, em que N é o número de pontos e δt é o tamanho do intervalo entre um ponto e outro da amostra.

A Taxa de amostragem consiste no incremento de tempo ou frequência de aquisição. O teorema da amostragem diz que: a taxa ou frequência de amostragem tem que ser, pelo menos, duas vezes maior que a mais alta frequência contida no sinal a ser capturado, aqui denotado por f_m . Quando isso não ocorre, podem surgir falsas frequências ou *aliasing* do sinal capturado ; LESNIKOV *et al.*, 2022). A Equação (3.1) representa o teorema da amostragem de Nyquist que também pode ser expressa em termos de incremento de tempo de amostragem.

$$f_s > 2f_m \therefore \delta t < \frac{1}{2f_m} \quad (3.1)$$

3.2. TRANSFORMADA RÁPIDA DE FOURIER

A transformada de Fourier foi um grande salto matemático que permitiu abrir novos horizontes na análise de sinais. Tem como principal vantagem a possibilidade de controle, permitindo analisar um sinal de um domínio no qual não se tem controle, no caso o tempo, para outro domínio que pode ser facilmente modificado, no caso a frequência. (MELLO, 2011). Na **Figura 3.6** é representada a mudança de domínios utilizando a transformada de Fourier e sua inversa.

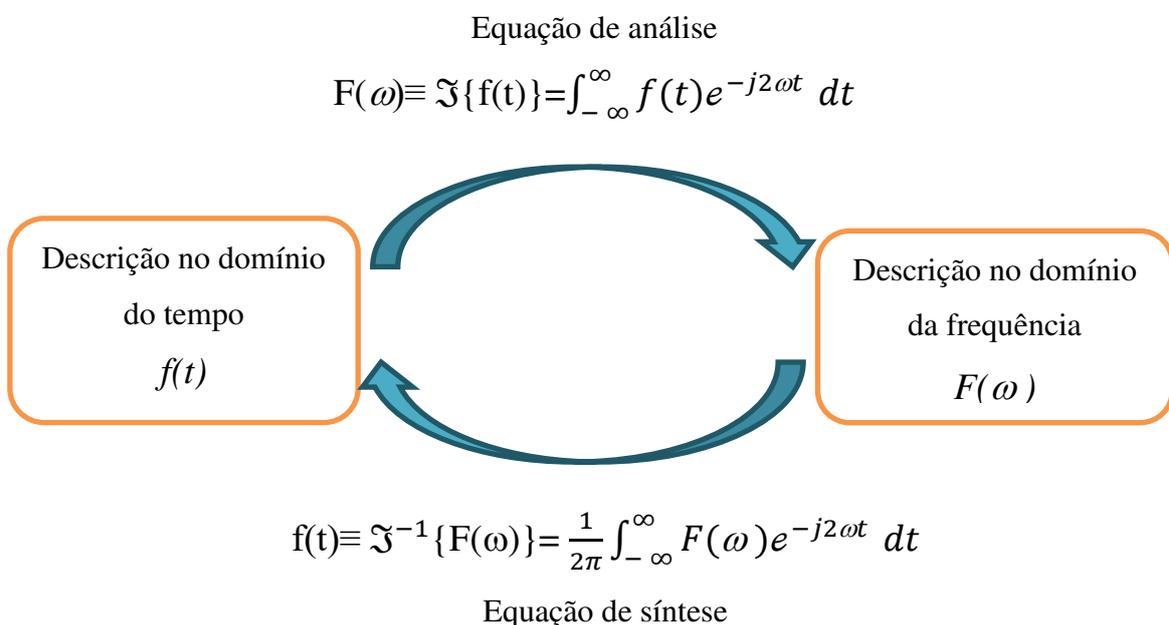


Figura 3.6-Representação da mudança de domínios utilizando a transformada de Fourier

Alternativas foram desenvolvidas com a finalidade de otimizar o tempo de processamento e análise de sinais dos mais variados tipos. Uma dessas soluções é aplicação da Transformada Discreta de Fourier (DFT). São utilizadas para analisar um sinal discreto, sendo possível a análise de sinais onde a periodicidade não é bem definida e nos casos onde não é possível se obter uma expressão analítica (o que ocorre na maioria das vezes) (MELLO, 2011; DINIZ *et al.*, 2014). Na **Figura 3.7** é ilustrado o processo de mudança de domínio usando a transformada discreta de Fourier.

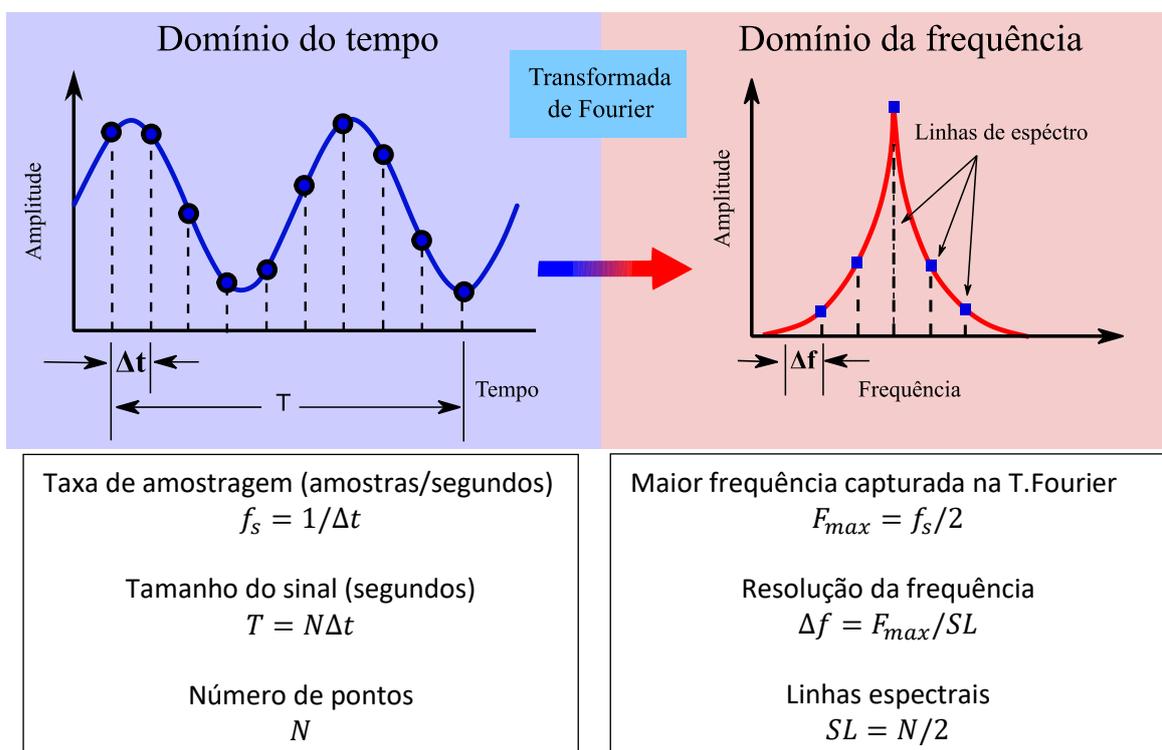


Figura 3.7- Transformada de Fourier digital (Fonte: Adaptado de (<https://community.sw.siemens.com/s/article/digital-signal-processing-sampling-rates-bandwidth-spectral-lines-and-more>))

A Transformada Discreta de Fourier aplicada a análise de sinais demandava muito custo computacional e calculá-la de forma analítica tornava o processo trabalhoso. Graças à contribuição em 1965 de J.W. Cooley da IBM com a colaboração de J.W. Tukey do *Bell Labs* foi dado um passo importante na otimização do cálculo da DFT, eles lançaram a base do que mais tarde viria a ser o algoritmo mais utilizado em processamento digital de sinais com uma infinidade de aplicações. Esse algoritmo ficou conhecido por (*Fast Fourier Transform*) ou Transformada Rápida de Fourier ou simplesmente FFT (COOLEY e TUKEY, 1965).

A FFT decompõe as operações utilizadas na DFT a fim de reduzir o custo computacional, transformando multiplicações em somas, por exemplo, além de explorar a periodicidade e simetria das funções trigonométricas calculando assim a transformada com aproximadamente $N \log_2 N$ operações enquanto na DFT são utilizadas N^2 operações, sendo assim, para $N=256$ amostras a FFT é 32 vezes mais rápida do que a DFT padrão o gráfico da **Figura 3.8** compara os dois métodos (CHAPRA e CANALE, 2011; COOLEY e TUKEY, 1965).

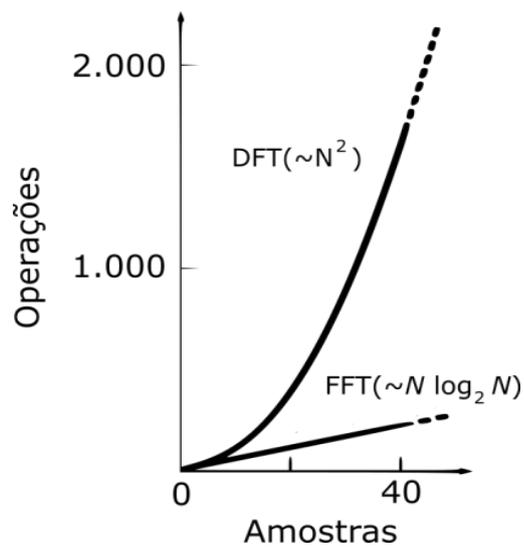


Figura 3.8- Comparação do número de operações entre a DFT padrão e a FFT (Fonte: (CHAPRA e CANALE, 2011. p.454.))

Na análise de falhas em MITs através da análise dos picos do espectro de potência é possível verificar características importantes do funcionamento do motor verificando inclusive a incidência de falha. Na **Figura 3.9** é representado o espectro do sinal da corrente de um motor de indução trifásico, atuando sem carga e sem falha no rolamento.

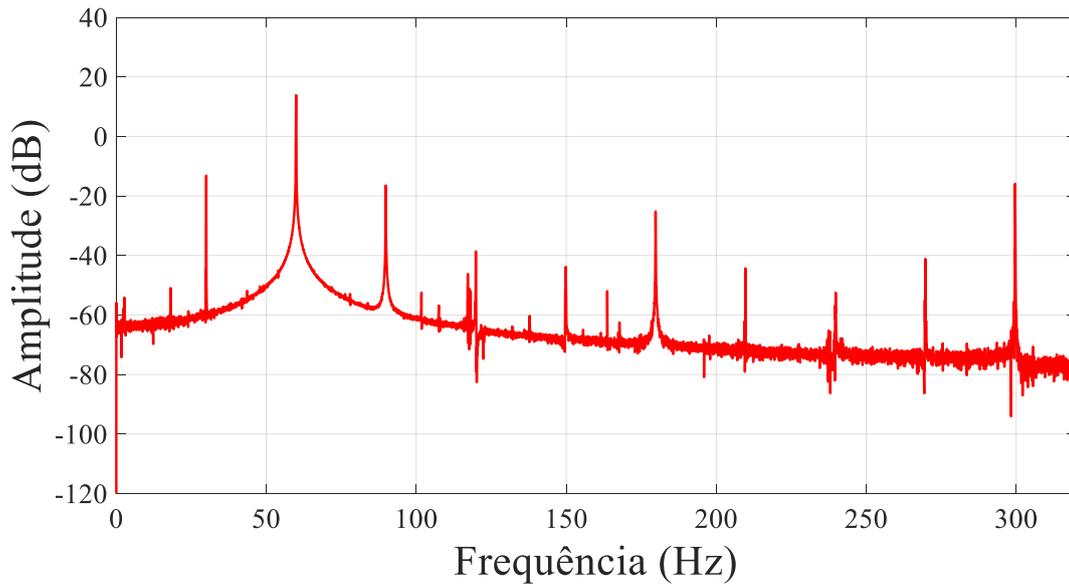


Figura 3.9- Espectro do sinal de corrente do motor de indução obtido por meio da FFT.

Embora a FFT tenha um excelente desempenho na análise de sinais estacionários, sua eficácia é limitada na análise de sinais transitórios. Isso acontece porque o algoritmo da Transformada Rápida de Fourier interpreta o sinal como um todo, sem permitir a seleção de trechos específicos para análise.

Foram desenvolvidas novas alternativas para trabalhar com sinais que exigem análises tanto no domínio do tempo quanto no domínio da frequência. Gabor em 1946 apresentou em seu trabalho, o que mais tarde ficou conhecida como Transformada de Fourier de Tempo Curto do inglês *Short Time Fourier Transform* (STFT), ou até mesmo transformada de Gabor, Equação (3.2). A ideia era que a Transformada de Fourier não atuaria em todo o sinal, ela atuaria em frações ou partes, a representação na **Figura 3. 10** exemplifica o processo. Sendo assim, o sinal passaria a ser visto em janelas e a transformada calculada em cada uma dessas janelas, a denotação matemática da STFT pode ser dada pela fórmula abaixo (GABOR, 1946).

$$STFT(\omega, b) = \int_{-\infty}^{\infty} f(t)g(t - b)e^{-j\omega t} dt \quad (3.2)$$

A transformada pode ser definida como a frequência angular ω em função da posição b no tempo. A STFT equivale à transformada de Fourier da função janelada

$f(t)g(t - b)$, onde a função janela $g(t)$ é concentrada em torno de $t = 0$, sendo o seu principal propósito isolar os valores da função em estudo $f(t)$, em torno de $t = b$ antes do cálculo da transformada de Fourier (DINIZ *et al.*, 2014).

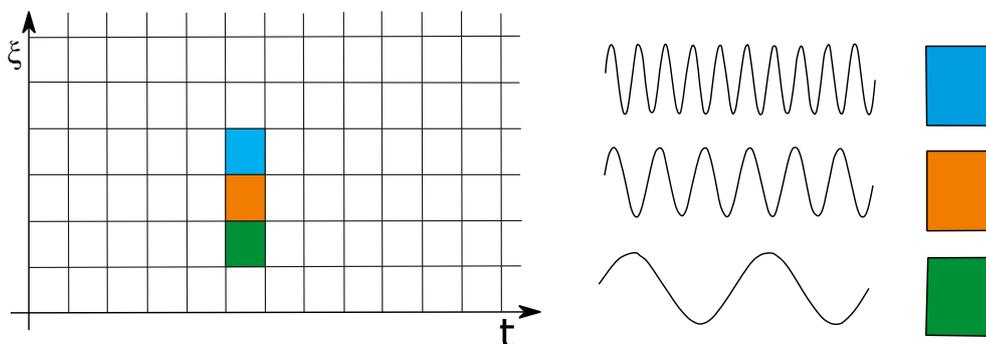


Figura 3. 10- Transformada Janelada de Fourier com certa localização, mas com janela constante (Fonte: (CASTILHO *et al.*, 2012)).

3.3. TÉCNICA DO ENVELOPE

A extração do envelope de um sinal pode ser feito a partir da transformada de Hilbert (BENDAT e PIERSOL, 2010). A transformada de Hilbert, desenvolvida pelo brilhante matemático alemão David Hilbert (1862-1943), resolve um problema típico de demodulação, por esse motivo a técnica também recebe o nome de “demodulação de amplitude” fornecendo a amplitude (envelope) e a frequência instantânea de um sinal medido. As funções instantâneas de amplitude e frequência são características complementares que podem ser usadas para medir e detectar características locais e globais do sinal da mesma forma que para assinaturas espectrais e estatísticas clássicas.

A transformada de Hilbert pode ser formulada pela Equação (3.3), de modo que, pode ser definida pela convolução (representada aqui pelo sinal $*$) entre $x(t)$ e a transformada de Hilbert do impulso, $-1/\pi t$, onde $x(t)$ é um sinal real (Sete & Noceti Filho, 2017).

$$h(t) = H[x(t)] = \hat{x}(t) = \frac{-1}{\pi t} * x(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (3.3)$$

Usando identidades de Fourier, pode-se mostrar que a Transformada de Fourier da Transformada de Hilbert de $x(t)$ é $h(t) \leftrightarrow H_f = -j \operatorname{sgn}(f) \cdot X(f)$, onde, $x(t) \leftrightarrow X(f)$ é um par de transformadas de Fourier:

$$\operatorname{sgn}(f) = \begin{cases} 1 & f > 0 \\ 0 & f = 0 \\ -1 & f < 0 \end{cases} \quad (3.4)$$

A transformada de Hilbert é valiosa para calcular atributos instantâneos de uma série temporal de um sinal, especialmente frequência e amplitude, antes que o sinal seja envolvido pelo rastreamento dos valores de pico sucessivos (ALICANDO *et al.*, 2021).

Uma aplicação prática da transformada de Hilbert relacionada à modulação/demodulação de amplitude é a ‘análise de envelope’ que é uma técnica bastante utilizada na engenharia de som e vibração. A análise de envelope pode ser usada para a detecção precoce na análise de falhas em máquinas rotativas. Por exemplo, falhas em rolamentos e falhas em rotores (SHIN e HAMMOND, 2008; KABUL e ÜNSAL, 2022).

Para fins de exemplificação, na **Figura 3.11** é possível observar um sinal $x(t)$ e seu respectivo envelope destacado em vermelho. O sinal gerado foi obtido através da função $f(x) = \operatorname{sen}(wt) * 20\operatorname{sen}(\pi t) + 4\cos(10\pi t)$, onde $w=2\pi f$, e t (número de segundos decorridos) foi utilizada uma frequência de amostragem de 1 KHz com a frequência máxima do sinal sendo de 20 Hz, foi adicionado a esse sinal um ruído branco com amplitude unitária, afim de testar o algoritmo na detecção da envoltória do sinal.

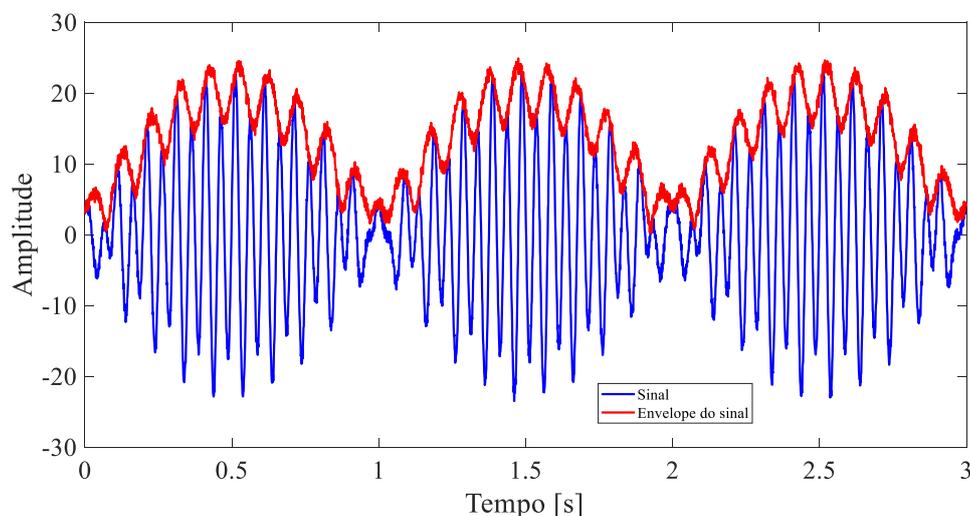


Figura 3.11-Representação da extração do envelope de um sinal

A análise de sinais de vibração mecânica e sonora por meio da técnica do envelope vem sendo utilizada para a detecção de falhas com elevado sucesso, tornando-se uma técnica consolidada no meio industrial. Na detecção de falhas os sinais de impacto nas frequências características de falha são moduladas pelas frequências ressonantes muito mais altas dos rolamentos o que resulta em um sinal semelhante ao apresentado na **Figura 3.12** (KIM *et al.*, 2020). Quando ocorre uma falha, a vibração se torna modulada em amplitude devido a mudanças periódicas nas forças, que pode ser provocado por impactos repetitivos devido a defeitos superficiais locais.

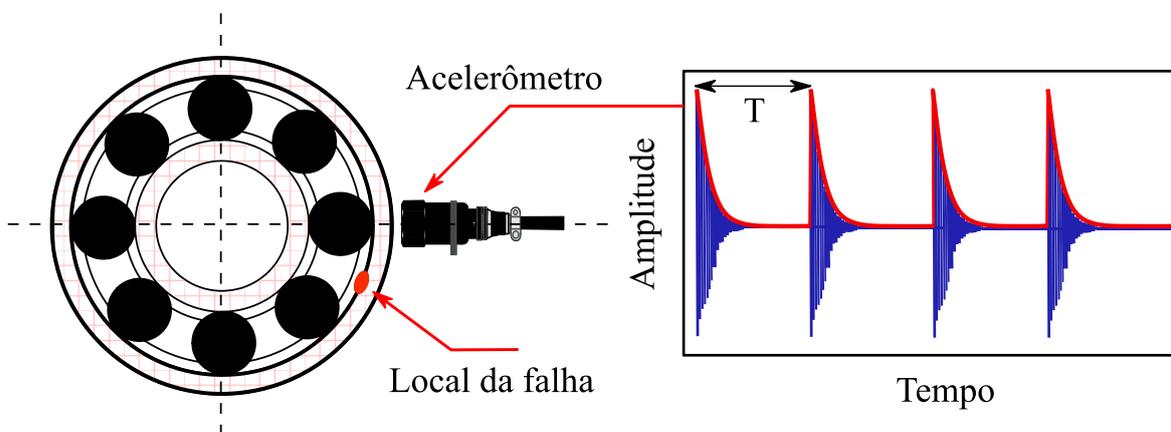


Figura 3.12- Falha na pista externa de um rolamento e o sinal de vibração com seu envoltório.

Os impactos provocados pela passagem das esferas do rolamento sobre a falha provocam impulsos de alta frequência cada vez que o defeito é atingido durante cada revolução. Para realizar a detecção das falhas em rolamentos utilizando o método do envelope algumas etapas devem ser seguidas: a primeira etapa é a aquisição do sinal no domínio do tempo; o segundo passo é transferir o sinal para o domínio da frequência; o terceiro passo é definir a região de interesse e remover todos os componentes fora da banda, de preferência a faixa de frequência selecionada deve estar relacionada apenas a falhas de rolamento e não a outras falhas da máquina; o quarto passo consiste em aplicar a transformada inversa de Fourier para retornar o sinal para o domínio do tempo; o passo seguinte é aplicar a Transformada de Hilbert para detectar o envelope do sinal; o sexto passo consiste em aplicar novamente a FFT e retornar o sinal para o domínio da frequência

com a finalidade de encontrar as frequências características de falha. Os passos abordados anteriormente podem ser observados na **Figura 3.13**.

O método do envelope apresenta uma excelente vantagem na detecção de falhas precoces em rolamentos, tendo em vista que as frequências de falha de rolamento que aparecem no espectro de demodulação é o primeiro indício de um possível falha. O método tem como diferencial a possibilidade de detectar essas frequências com falha antes que elas se tornem fortes o suficiente para serem detectadas em um espectro de uma FFT padrão.

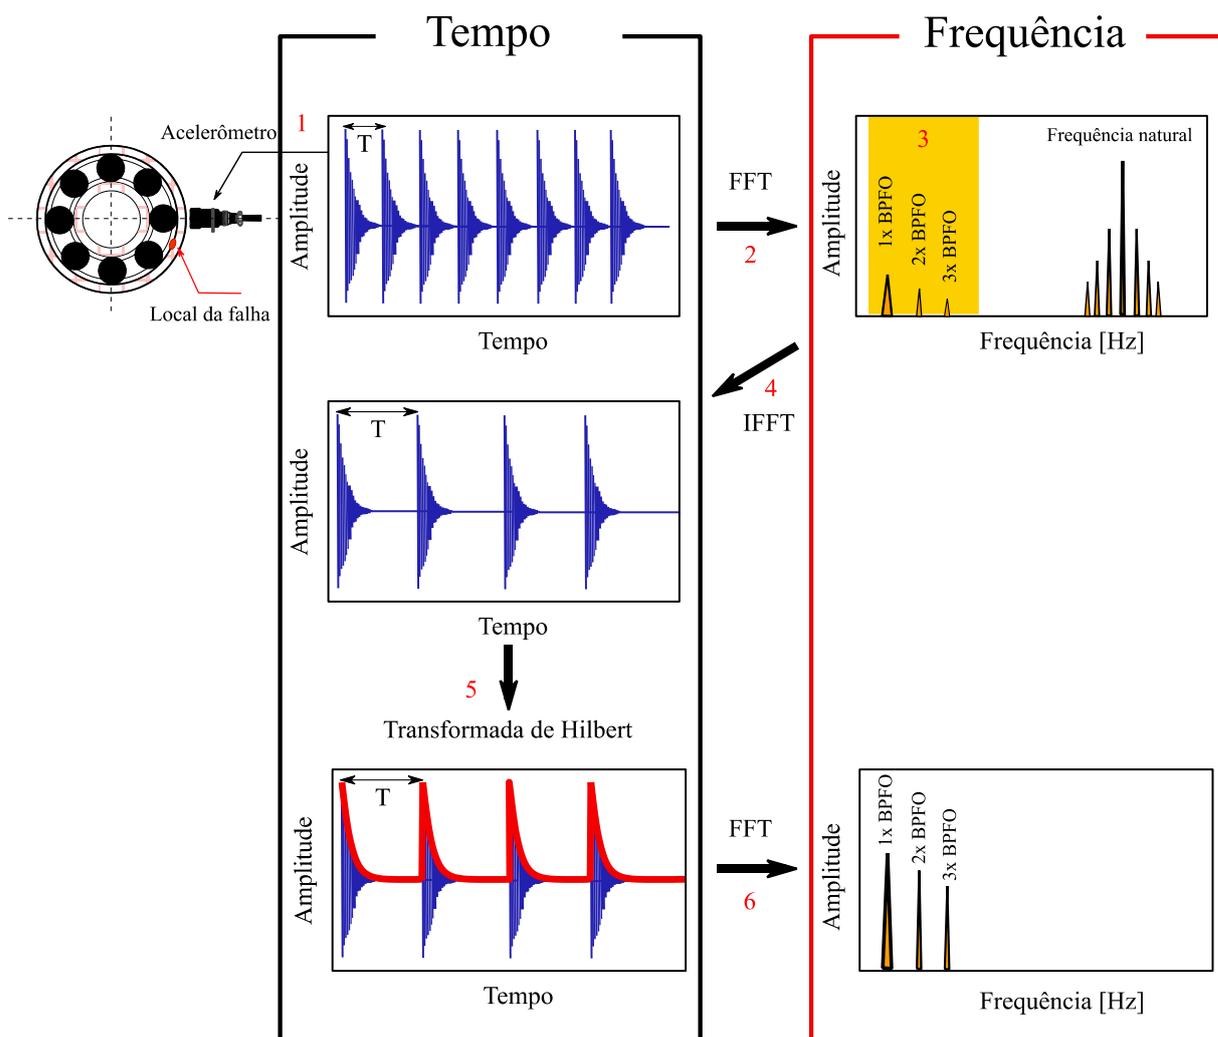


Figura 3.13-Representação das etapas necessárias para detectar as frequências de falha em um rolamento usando a técnica do envelope.

A análise de envelope é usada para a detecção precoce de falhas em máquinas. Por exemplo, uma falha na pista externa de um rolamento pode gerar uma série de sinais de

rajada* em intervalos regulares. Tais sinais de rajada decaem muito rapidamente e contêm energias relativamente pequenas, portanto, a análise de Fourier usual pode não revelar a frequência de repetição das rajadas. No entanto, pode ser possível detectar esse componente de frequência formando o sinal analítico e, em seguida, aplicando a análise de Fourier ao envelope do sinal (SHIN e HAMMOND, 2008).

3.4. REDES NEURAIS ARTIFICIAIS

O cérebro humano sempre foi uma fonte de inspiração, por ser complexo, compacto, e dotado de funções que permitem a criatividade e a engenhosidade humana. Segundo (HAYKIN, 2009), o cérebro é um computador altamente complexo, não-linear e paralelo, que tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos, por exemplo, reconhecimento de padrões, percepção e controle motor. Tais aspectos foram motivadores no estudo de Redes Neurais Artificiais (RNA).

MCCULLOCH e PITTS (1943) publicaram um dos primeiros trabalhos relacionado à neurocomputação. Os autores fizeram a modelagem do primeiro neurônio artificial inspirados em um neurônio biológico. Outra grande contribuição foi dada por (ROSENBLATT, 1958), que idealizou o conceito de *perceptron* ao desenvolver o primeiro neurocomputador, no qual o objetivo era identificar padrões geométricos através da percepção eletrônica de sinais, cujo desenvolvimento foi inspirado na retina.

Os neurônios biológicos se comunicam uns com os outros através de sinapses, que é um impulso elétrico gerado de um neurônio para outros. Os neurônios são compostos basicamente de três partes, a saber: dendritos, corpo celular e axônio. Os dendritos são constituídos, basicamente, por uma ramificação de pequenos prolongamentos e captam continuamente os estímulos que advêm de diversos outros neurônios atuando como um terminal de recepção. O corpo celular processa as informações recebidas pelos dendritos, sendo responsável por gerar um potencial de ativação. Esse potencial indica se o neurônio poderá ou não disparar um impulso elétrico ao longo de seu axônio. No corpo celular estão presentes as principais organelas citoplasmáticas (núcleo, mitocôndrias, lisossomos, etc).

* (Também conhecido por sinais transitórios). São sinais gerados com uma largura de banda relativamente alta em um curto período, a exemplo, o impacto provocado pela esfera do rolamento ao passar pela superfície de falha.

Já o axônio é responsável pela transmissão dos impulsos elétricos a outros neurônios conectores e é constituído por um único prolongamento, ao fim da sua terminação há uma formação de ramificações denominadas terminações sinápticas ou terminal de transmissão, (SILVA *et al.*, 2016).

Uma Rede neural artificial é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. Esses modelos computacionais permitem a aquisição e manutenção do conhecimento (baseado em informações) e, segundo SILVA *et al.* (2016) podem ser definidos como um conjunto de unidades de processamento, caracterizados por neurônios artificiais, que são interligadas por um grande número de interconexões (*sinapses artificiais*), representada por vetores, matrizes e pesos sinápticos. Na **Figura 3.14** é ilustrada a comparação entre um neurônio biológico e um neurônio artificial, é interessante notar a semelhança organizacional entre os dois modelos.

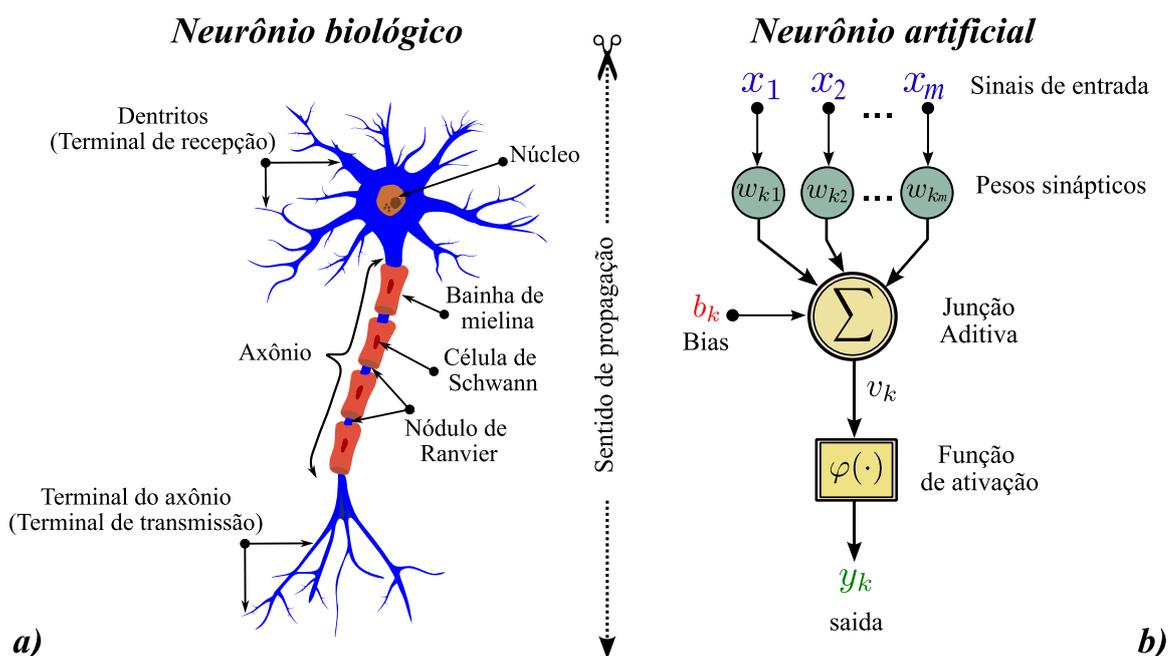


Figura 3.14- Ilustração de um (a) neurônio biológico comparado com (b) neurônio artificial.

Ainda segundo SILVA *et al.* (2016) o neurônio artificial pode ser fracionado em sete etapas fundamentais, sendo elas: sinais de entrada $\{x_1, x_2, \dots, x_m\}$, como o próprio nome sugere são os sinais advindos de dados ou variáveis de uma determinada aplicação; Os sinais de entrada são então multiplicados por pesos sinápticos $\{w_{k1}, w_{k2}, \dots, w_{km}\}$, os pesos são responsáveis por ponderar cada uma das entradas da rede; o combinador linear

ou junção aditivada representado por $\{\Sigma\}$ é encarregado de somar todos os sinais de entrada, os quais foram previamente ponderados pelos respectivos pesos sinápticos, com a finalidade de produzir um valor de potencial de ativação; O *bias* ou limiar de ativação $\{b_k\}$ é uma variável crucial que determina o ponto em que o potencial de ativação, produzido pelo combinador linear, resultará em um disparo de saída do neurônio. Quando o potencial de ativação ultrapassa esse limiar, o neurônio é ativado e gera uma resposta; o potencial de ativação $\{v_k\}$ o potencial de ativação é determinado pela diferença entre o valor produzido pelo combinador linear e o limiar de ativação. Se esse valor for positivo ($v_k \geq b_k$), o neurônio produz um potencial excitatório, caso contrário, o potencial é inibitório; a função de ativação, denotada por $\{\varphi(\cdot)\}$, tem o propósito de restringir a saída do neurônio a um intervalo de valores razoáveis, conforme determinado pela sua própria imagem funciona; a ultima etapa é representada por $\{y_k\}$, que corresponde a saída produzida pelo processo neuronal em função do conjunto de sinais de entrada.

O neurônio artificial k pode ser representado em termos matemáticos conforme a equação (3.5) e a equação (3.6).

$$u_k = \sum_{j=1}^m w_{kj}x_j + b_k \quad (3.5)$$

$$y_k = \varphi(u_k) \quad (3.6)$$

Embora o *perceptron* seja bom na solução de classes de problemas linearmente separáveis ele possui uma grande limitação na aplicação em classes de problemas não linearmente separáveis, como ficou demonstrado no trabalho de MINSKY e PAPERT (1969). No trabalho os autores demonstraram que o problema de classificação da função lógica X_{or} (ou exclusivo) não poderia ser solucionado utilizando apenas redes neurais artificiais *perceptron* ou *Adaline* (*Adaptive Linear Element*) de camada simples.

3.4.1. Redes *perceptron* de múltiplas camadas (PMC)

As redes neurais *perceptron* de múltiplas camadas ou (MLP-*Multilayer Perceptron*) foram uma evolução das redes neurais de camada simples, nessa nova arquitetura de rede, o problema de classificação da função lógica X_{or} , por exemplo, foi solucionado. Esse avanço deu-se em grande parte ao aumento do poder de processamento

computacional e a algoritmos de otimização que permitiram que os pesos sinápticos pudessem ser ajustados para neurônios com mais de uma camada. Essa nova abordagem ficou conhecida por *backpropagation* (algoritmo de retropropagação de erro) (RUMELHART *et al.*, 1986).

Na rede neural do tipo MLP o *backpropagation* é um algoritmo utilizado para treinar as redes neurais artificiais, e atua no ajuste dos pesos das conexões entre os neurônios de forma a minimizar o erro entre a saída prevista pela rede neural e a saída desejada para um determinado conjunto de dados de treinamento. O processo de retropropagação ocorre em duas fases principais: a primeira fase é a propagação direta ou avanço para frente (*forward*), nesta etapa os dados de entrada são passados camada por camada até a saída da rede neural. Durante esse processo, cada neurônio em uma camada recebe entradas das conexões ponderadas dos neurônios da camada anterior e ajustes através da função de ativação utilizada. A segunda fase é denominada propagação reversa (*backward*), nesta etapa o erro entre a saída prevista e a saída desejada é calculada utilizando uma função de perda, o erro é propagando de volta pela rede, camada por camada a partir da camada de saída até a camada de entrada, neste processo há o ajuste dos pesos das conexões por meio de algoritmos de otimização, como por exemplo, o gradiente descendente (HAYKIN, 2009). Na **Figura 3.15** é possível visualizar uma arquitetura típica de uma rede neural com arquitetura *perceptron* de múltiplas camadas.

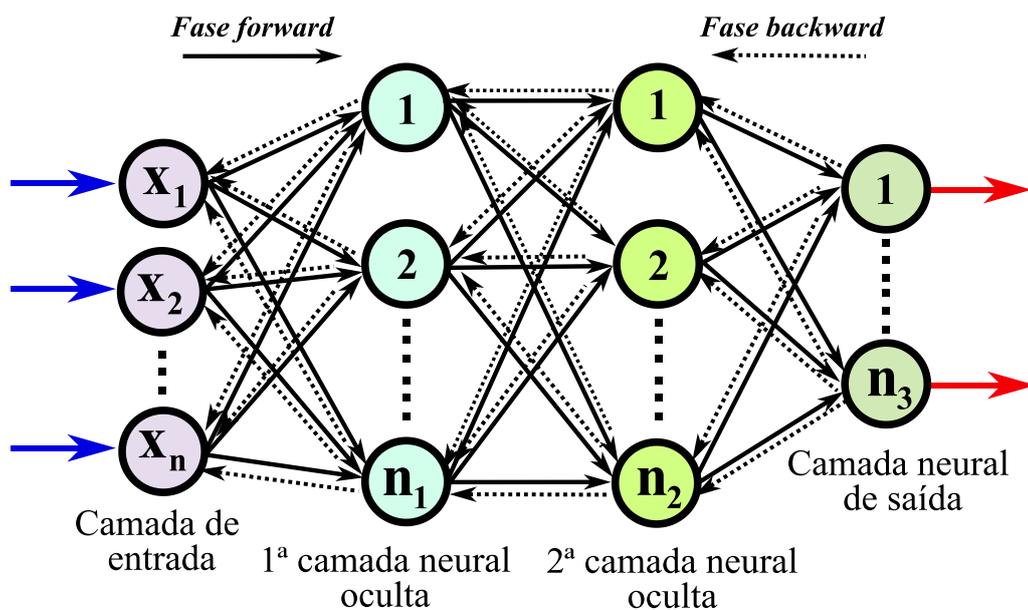


Figura 3.15-Representação da arquitetura de uma rede *perceptron* de múltiplas camadas com duas camadas ocultas (Fonte: adaptado de (SILVA *et al.*, 2016)).

De forma resumida, no *backpropagation* o processo de repetições sucessivas sequencial das etapas durante o processo de propagação direta e propagação reversa resulta no ajuste automático dos pesos sinápticos a cada interação, o que resulta em uma redução gradual da soma dos erros entre as saídas da rede e os valores desejados (SILVA *et al.*, 2016).

3.4.2. Funções de ativação

As funções de ativação desempenham um papel primordial nas redes neurais artificiais, são funções utilizadas para calcular a soma ponderada das entradas e dos desvios, que é utilizada para decidir se um neurónio pode ser ativado ou não. Manipula os dados apresentados através de um processamento gradiente, normalmente gradiente descendente, e depois produz uma saída para a rede neural, que contém os parâmetros dos dados (NWANKPA *et al.*, 2018).

As funções de ativação podem ser divididas em dois principais grupos: o primeiro grupo se refere às funções parcialmente diferenciáveis que são aquelas que possuem pontos cujas derivadas de primeira ordem são inexistentes, destaca-se neste grupo as funções: rampa simétrica, degrau e degrau bipolar. Já o segundo grupo, se refere às funções de ativação totalmente diferenciáveis, para estas funções a derivada de primeira ordem existe e são conhecidas em todos os pontos de seu domínio de definição, neste grupo, destacam-se as seguintes funções de ativação: função logística, função linear, gaussiana e a função tangente hiperbólica (SILVA *et al.*, 2016). A seguir são exemplificadas algumas funções de ativação.

Função de ativação sigmoide: cujo gráfico tem a forma de *s*, dentre todas as funções de ativação é de longe a mais utilizada na construção de redes neurais artificiais. A sigmoide é uma função de ativação não linear usada principalmente em redes neurais do tipo *feedforward*. O valor da função sigmoide varia de 0 a 1, sendo muito utilizada em aplicações probabilísticas (HOSSAIN, 2024).

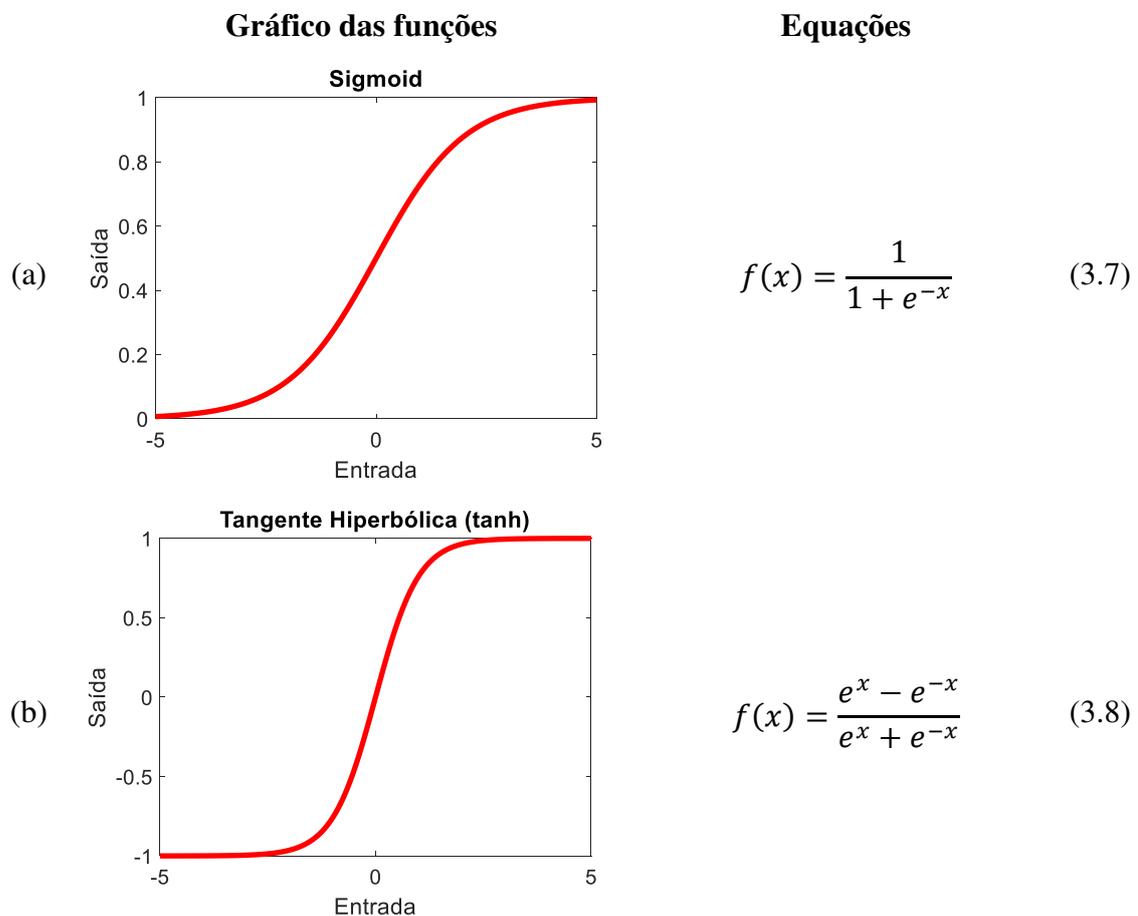
Função de ativação tangente hiperbólica: A função tangente hiperbólica (*tanh*) se assemelha a função de ativação sigmoide até certo ponto, entretanto, ao contrário da função sigmoide a função *tanh* varia de -1 a 1, tal medida é útil, para determinados problemas, tendo em vista que pode ser útil deixar o modelo decidir a direção a seguir e a quantidade de operação a ser efetuada durante o processo de treinamento, isso se deve em

parte a capacidade que a função tem de produzir uma saída centrada em zero, o que auxilia no processo de retropropagação (*backpropagation*).

Função de ativação ReLu: A função ReLu (*Rectified Linear Union*) é uma função linear que fornece uma saída igual a entrada, apenas quando a entrada é maior que zero e produz zero caso contrário. Na função os valores variam de 0 a $+\infty$, nunca operando na região negativa, tendo em vista que as função devem ser não negativas para uma saída não nula (NAIR e HINTON, 2010).

Função de ativação Leaky ReLu: Essa função introduz uma pequena inclinação negativa a função ReLu. Tal mecanismo é necessário para manter e sustentar as atualizações de pesos vivas durante todo o processo de propagação, evitando assim problemas de neurônios ‘mortos’ (MAAS *et al.*, 2013). As ‘famílias’ derivadas das funções ReLu, são vastas com características e melhorias peculiares de uma em relação a outra, para mais detalhes, por gentileza, consultar (NWANKPA *et al.*, 2018).

Na figura abaixo, são ilustradas as função de ativação sigmoide, tangente hiperbólica, ReLu e LeakReLu com suas respectivas equações.



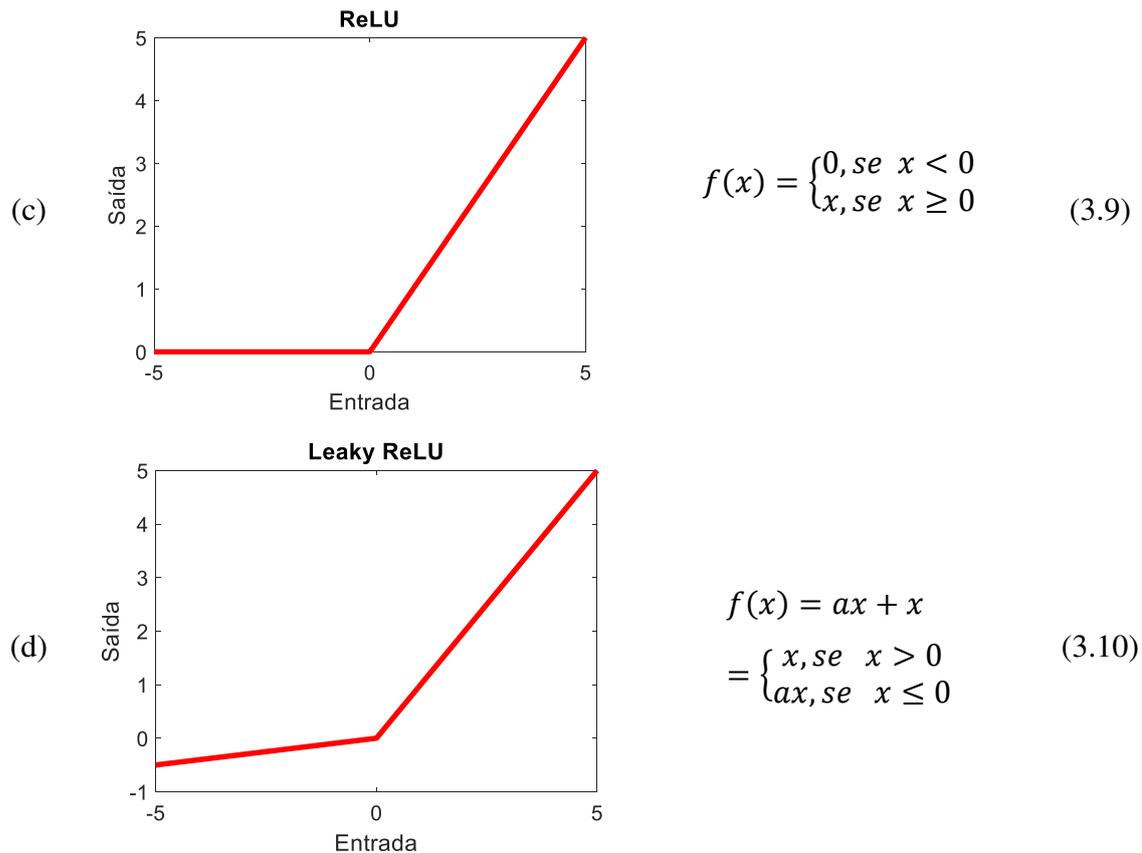


Figura 3.16- Diferentes Funções de ativação utilizadas em redes neurais a) sigmoide; b) tangente hiperbólica; c) ReLu e d) Leaky ReLu.

Vale ressaltar que as funções de ativação supracitadas acima, são geralmente utilizadas nas camadas ocultas. Para a camada de saída uma função bastante utilizada é a função *softmax*. Esta função é utilizada para calcular a distribuição de probabilidade a partir de um vetor de números reais, ela produz uma saída que é um intervalo de valores entre 0 e 1 com a soma da probabilidade igual a 1, sendo muito utilizada na interpretação de resultados como probabilidades. A equação

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad , \text{ para } i = 1, \dots, k \quad (3.11)$$

Diversas outras funções de ativação são encontradas na literatura, cada uma com suas particularidades e características, fica a critério do implementador da rede neural fazer testes e verificar qual delas se ajusta melhor na sua classe de problemas.

3.4.3. Funções de custo

A função de custo é utilizada para avaliar o desempenho do modelo em um determinado conjunto de dados. A função de custo também é responsável por calcular a diferença entre os valores de saída previstos e os valores reais. A função de custo se diferencia da função de perda, a função de perda, é calculada para um único ponto de dados após um único treino, já a função de custo é calculada para um determinado conjunto de dados após o treino da rede já estar concluído (HOSSAIN, 2024). A função de custo tem o objetivo de avaliar se as probabilidades previstas são boas ou ruins.

No problema que o implementador da rede neural pretende solucionar, seja um problema envolvendo regressão ou classificação, é primordial definir quais as melhores funções de custo a serem utilizadas. Para problemas que envolvem classificação, como é o caso deste trabalho, as funções de custo mais utilizadas são: o erro quadrático médio (*mean square error - MSE*) e a entropia cruzada, *cross-entropy*.

O erro quadrático médio (MSE) é calculado através da média da soma do quadrado da diferença (erro) entre o valor real e o valor previsto de todos os pontos de dados. O MSE é sensível a valores anômalos (HOSSAIN, 2024). O erro quadrático médio é dada pela Equação (3.36), onde k é o número total de pontos dados em uma amostra, y_i é a forma de saída do modelo da rede neural para o i -ésimo ponto de dados e \hat{y}_i é o valor real.

$$MSE = \frac{1}{k} \sum_{i=1}^k (y_i - \hat{y}_i)^2 \quad (3.12)$$

O conceito de entropia cruzada (*cross-entropy*) tem origem nos trabalhos de (SHANNON, 1948) que lançou as bases da teoria da informação e introduziu os conceitos da entropia de Shannon, de forma simplista, a entropia indica a quantidade de incerteza de um evento. A entropia cruzada é amplamente utilizada na aprendizagem automática para problemas de classificação.

A entropia cruzada binária ou (*log loss*), geralmente é utilizada em problemas com duas classes (onde a saída é um rótulo binário 0 ou 1), é indicada para problemas com classes desequilibradas. Nesse cenário, a entropia cruzada binária pode ser expressa pela Equação (3.13), onde y representa os rótulos reais (0 ou 1); \hat{y} representa as saídas previstas pela rede neural (probabilidade entre 0 e 1); k é o número total de exemplos de

treinamento; y_i e \hat{y}_i são os rótulos e previsões respectivamente para o exemplo i , (HOSSAIN, 2024).

$$L = -\frac{1}{k} \sum_{i=1}^k [y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)] \quad (3.13)$$

O termo logaritmo utilizado para calcular a entropia cruzada binária, tem a função de penalizar as previsões erradas, melhorando a precisão do modelo. Em termos gerais, se o problema envolver mais de duas classes ou múltiplas classes, uma generalização pode ser utilizada com base na entropia cruzada binária, através de alguns arranjos algébricos é possível formular a Equação (3.14), e obter a entropia cruzada multiclasse. Em que k representa o número de amostras, n representa o número de classes, y_{ij} é a saída verdadeira para i -ésima amostra para e j -ésima classe, já \hat{y}_{ij} é a saída prevista para i -ésima amostra para e j -ésima classe.

$$L = -\frac{1}{k} \sum_{i=1}^k \sum_{j=1}^n y_{ij} \log(\hat{y}_{ij}) \quad (3.14)$$

Geralmente as funções de custo devem passar por um processo de otimização, com o objetivo de ajustar os parâmetros do modelo ao minimizar a entropia cruzada. Vários otimizadores podem ser encontrados na literatura, com especial destaque para o gradiente descendente estocástico (*Stochastic Gradient Descent*), ADAM (*Adaptive moment Estimation*), Levenberg-Marquardt e Gradiente Descendente com *Momentum* (WANG e REN, 2023).

3.4.4. Algoritmos de otimização

Os problemas que envolvem otimização, podem ser definidos como uma classe de problemas que visam à solução ótima sob um conjunto de determinadas condições. A maioria dos algoritmos de redes neurais artificiais envolve algum tipo de otimização. A otimização refere-se à tarefa de minimizar ou maximizar alguma função objetivo (GOODFELLOW *et al.*, 2016).

3.4.4.1. Gradiente descendente estocástico

O gradiente descendente talvez seja um dos algoritmos de otimização mais populares. O algoritmo gradiente descendente juntamente com o *backpropagation*, é bastante útil na construção de modelos de redes neurais. O Gradiente descendente atua na otimização da função objetivo, tentando encontrar os mínimos de uma função diferenciável, movendo-se em repetidamente ao longo da direção da descida mais íngreme determinada pelo gradiente negativo, conforme pode ser observado na **Figura 3.17**, abaixo. (HOSSAIN, 2024).

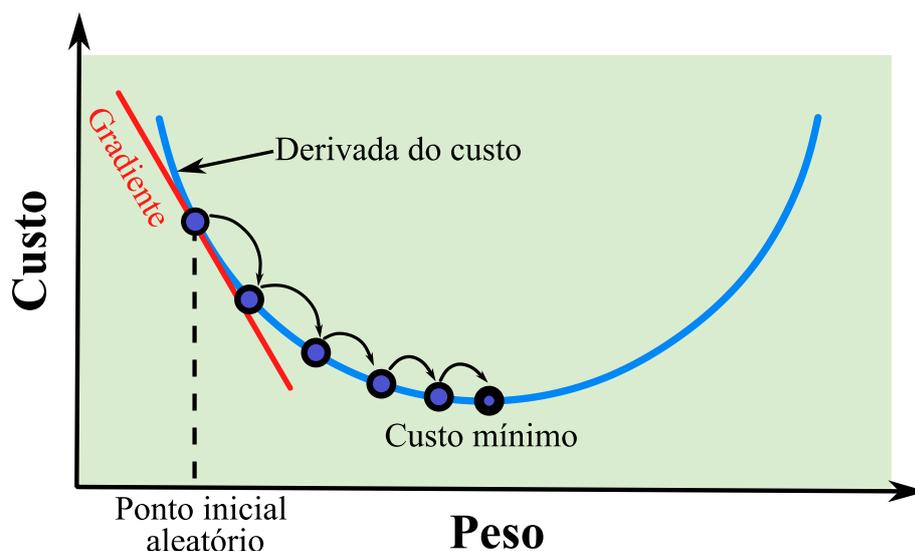


Figura 3.17- Gradiente descendente e custo mínimo (Fonte: Adaptado de (HOSSAIN, 2024)).

Na figura acima, o objetivo é encontrar o ponto mínimo que maximize a função custo (encontrar o ponto ótimo), no processo, inicialmente é escolhido um ponto de partida aleatório. A partir desse ponto de partida, calcula-se a derivada (ou a inclinação) e, em seguida, utiliza-se a reta tangente (linha em vermelho) para observar a inclinação do declive. A inclinação da reta tangente tem como função, informar a atualização dos parâmetros, mais especificamente, os pesos e as tendências. A inclinação inicial será alta, mas à medida que novos parâmetros são gerados, ela diminuirá gradualmente até atingir o ponto mais baixo da curva chamado de ponto de convergência. Assim sendo, o objetivo da descida do gradiente é minimizar a função de custo, através da diminuição do erro entre o valor real e o valor previsto.

O gradiente descende não é eficiente o suficiente ao lidar com um grande volume de dados, em virtude disso, foi criada uma extensão do método, o SGD (*Stochastic Gradient Descent*). A principal vantagem do gradiente descendente estocástico é sua eficiência

computacional, especialmente quando é necessário lidar com um volume de dados muito grande. O gradiente descendente exige o cálculo do gradiente para todos os exemplos de entrada antes de atualizar os pesos, já o gradiente descendente estocástico exige apenas o cálculo do gradiente para um único exemplo de entrada (EKMAN, 2022). A desvantagem do SGD é que ele está propenso a ruídos e anomalias no conjunto de dados, uma vez que apenas considera uma parte aleatória do conjunto de dados de cada vez (HOSSAIN, 2024). A Equação (3.15) apresenta o otimizador SGD.

$$w_{i+1} = w_i - \alpha \nabla_{w_i} J(x^i y^i; w_i) \quad (3.15)$$

Onde w é o parâmetro de peso, i é o índice de iteração, α é a taxa de aprendizagem, J é a função de custo, x é a partição do conjunto de dados aleatoriamente baralhada numa única observação e y são os dados rotulados.

3.4.4.2. *Gradiente descendente com momentum*

Outra abordagem que é uma extensão do gradiente descendente é o gradiente descendente com *momentum*. Segundo SILVA *et al.* (2016) diversas variações do método *backpropagation* têm sido desenvolvidas com o intuito de tornar o processo de convergência mais eficiente. Entre os métodos propostos destacam-se: o método de inserção do termo *momentum*, o *resilient-propagation* e o *Levenberg-Marquardt*.

Ainda de acordo com os autores supracitados, a inserção do termo *momentum*, se configura com uma das variações mais simples de ser efetuada no algoritmo *backpropagation*, tendo em vista que basta inserir um único parâmetro objetivando ponderar o quão as matrizes sinápticas foram alteradas entre duas alterações anteriores e sucessivas. A inserção do *momentum* permite calcular um novo gradiente a cada iteração, o novo gradiente é combinado com o gradiente da iteração anterior (EKMAN, 2022). O termo *momentum* pode ser expresso pela Equação (3.16).

$$TM = \alpha [W_{ji}^k(t) - W_{ji}^k(t-1)] \quad (3.16)$$

Na equação, o termo α é definido como a taxa de *momentum*, seu valor está entre 0 e 1. A equação formal para o gradiente descendente com *momentum*, para uma classe de neurônios pertencentes a k-ésima camada, pode ser definida pela Equação (3.17).

$$W_{ji}^k(t+1) = W_{ji}^k(t) + \alpha \cdot [W_{ji}^k(t) - W_{ji}^k(t-1)] + \eta \cdot \delta_j^k \cdot Y_i^{k-1} \quad (3.17)$$

Para o valor da taxa de *momentum* igual a 0, a expressão se torna equivalente a expressão do *backpropagation* convencional. Entretanto, se o valor for diferente de zero, o termo *momentum* passa a ser relevante, de modo que tal contribuição afetará o positivamente o processo de convergência (SILVA *et al.*, 2016).

A **Figura 3.18** exemplifica a contribuição do termo *momentum* (TM) e do termo de aprendizagem (TA) no gradiente descendente, buscando encontrar o ponto ótimo $W_{\text{ótimo}}$ da função do erro quadrático.

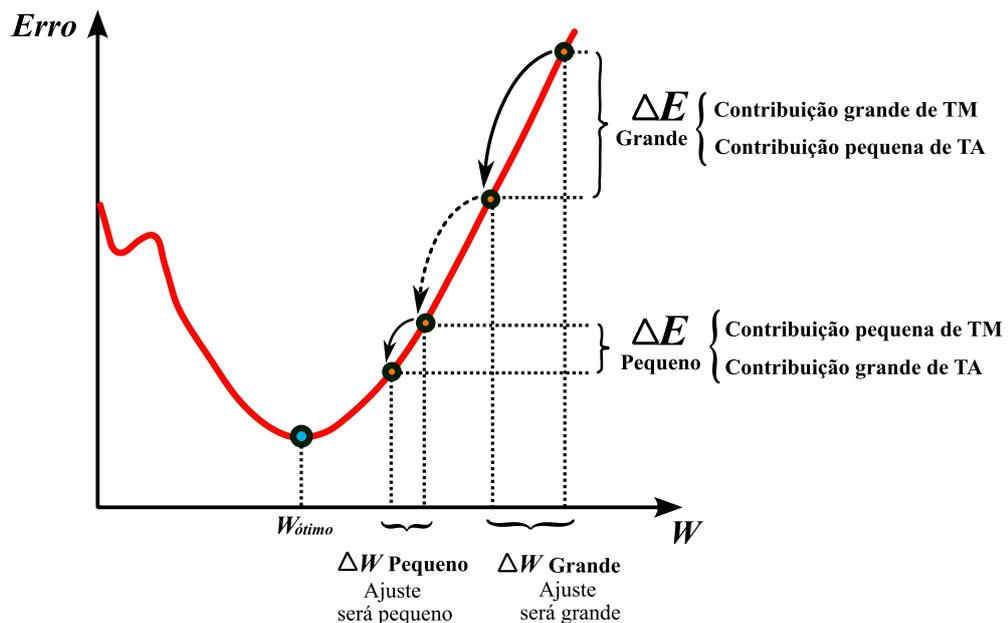


Figura 3.18-Representação gráfica treinamento do gradiente descendente com momentum (Fonte: Adaptado de (SILVA *et al.*, 2016)).

Verifica-se que para uma variação grande do erro (ΔE_{Grande}) a contribuição do termo *momentum* é grande, já a contribuição do termo de aprendizagem é pequena, por outro lado, para uma variação pequena do erro ($\Delta E_{\text{Pequeno}}$), a contribuição do termo *momentum* é pequena, já a contribuição do termo de aprendizagem é grande. Quando a solução está distante do mínimo de erro, grandes mudanças nos pesos ocorrem, e o termo de *momentum* é significativo. Quando a solução está próxima do mínimo, as mudanças nos pesos são

pequenas e o termo de momentum contribui pouco. Nesse ponto, os ajustes nos pesos são principalmente influenciados pelo termo de aprendizagem, como ocorre também no *backpropagation* convencional (SILVA *et al.*, 2016).

3.4.4.3. ADAM (*Adaptative Moment estimation*)

O algoritmo de otimização ADAM (*Adaptative Moment Estimation*), proposto por (KINGMA, BA, 2014), é uma extensão modificada do algoritmo gradiente descendente. O ADAM foi concebido para manter as vantagens dos algoritmos de gradiente adaptativo e RMSprop (algoritmo de propagação da raiz quadrada média). O ADAM utiliza correção de enviesamento e estimativas do primeiro e segundo momentos do gradiente para ajustar a taxa de aprendizagem para cada peso da rede neural (HOSSAIN, 2024).

Segundo KINGMA e BA (2014), o algoritmo ADAM é simples de implementar, além de ser computacionalmente eficiente, tem poucos requisitos de memória, é invariante ao redimensionamento diagonal dos gradientes e é adequado para problemas grandes em termos de dados e/ou parâmetros.

Segundo WANG e REN (2023) o ADAM é basicamente um RMSprop com termo de *momentum*, que ajusta dinamicamente a taxa de aprendizagem de cada parâmetro usando a estimativa de momento de primeira ordem m_t e a estimativa de momento de segunda ordem v_t do gradiente. A fórmula de atualização de m_t e v_t é dada pelas Equações (3.18) e (3.19), em que: $g_t = \nabla_t f_t(\theta)$.

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3.18)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3.19)$$

As estimativas de *momento* de primeira e segunda ordem com correção de viés são dadas por:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.20)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.21)$$

Finalmente, o parâmetro pode ser atualizado através de \hat{v}_t e \hat{m}_t :

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t \quad (3.22)$$

Onde: η representa o tamanho do passo para a otimização; β_1 é a taxa de decaimento do momento; β_2 representa a taxa de decaimento para gradientes quadrados e ϵ é um termo de suavização para evitar divisões por zero.

Na **Figura 3.19** a eficácia do Adam e comparado com outros métodos estocásticos de primeira ordem em redes neurais multicamadas treinadas com ruído de *dropout*. Na figura é possível verificar que o Adam obteve melhor convergência do que os outros métodos.

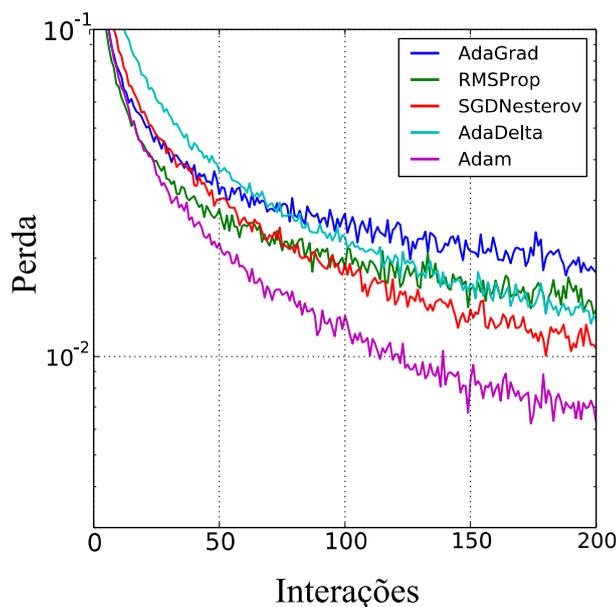


Figura 3.19-Comparação do Adam com outros algoritmos de otimização em uma rede neural multicamadas (Fonte: Adaptado de (KINGMA e BA, 2014)).

3.4.4.4. Algoritmo de Levenberg-Marquardt

Dentre os algoritmos de otimização utilizados na aplicação em redes neurais, destaca-se também o método de Levenberg-Marquardt (LM), o método consistem

basicamente na combinação entre dois métodos de minimização o método de Gauss-Newton e o método do gradiente descendente. Segundo SILVA *et al.* (2016) o algoritmo de LM é um método gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não-lineares, que pode ser incorporado ao algoritmo *backpropagation* a fim de potencializar a eficiência do processo de treinamento.

Ainda segundo os autores supracitados, o algoritmo *backpropagation* ajusta os pesos da rede neural em direção oposta ao gradiente da função de erro quadrático. No entanto, ele tende a convergir lentamente na prática, exigindo muito poder computacional. Dentro outros métodos existentes, uma das técnicas mais comuns para solucionar este problema é o algoritmo de Levenberg-Marquardt. A expressão iterativa do método LM, pode ser observada na Equação (3.24).

Para garantir que a matriz Hessiana aproximada $J^T J$ é invertível, o algoritmo de Levenberg-Marquardt introduz outra aproximação, à matriz Hessiana definida pela Equação (3.23).

$$H \approx J^T J + \mu I \quad (3.23)$$

$$w_{k+1} = w_k - [J_k^T J_k + \mu I]^{-1} \cdot J_k e_k \quad (3.24)$$

Em que w_k é o vetor de parâmetros na k-ésima interação; J_k é a matriz jacobiana na k-ésima interação; e_k é o vetor de erro na k-ésima interação; μ é o parâmetro de regulação e I é a matriz identidade. Essa equação representa a atualização dos parâmetros w_k na direção que minimiza o erro e_k , considerando tanto a direção do gradiente quanto a curvatura local da função de custo, controlada pelo parâmetro de regularização μ .

Embora seja um método robusto e amplamente utilizado em problemas envolvendo otimização, o método de Levenberg-Marquardt (LM) apresenta algumas desvantagens, como por exemplo: Sensibilidade à escolha de parâmetros; Possibilidade de Convergência para mínimos locais; Sensibilidade a ruído e *outliers*. Já as principais vantagens são: Eficiência em problemas não lineares; Convergência rápida; Adaptação à curvatura local e Regularização Incorporada (O LM incorpora um termo de regularização que ajuda a controlar a magnitude dos parâmetros do modelo, prevenindo *overfitting* e melhorando a generalização). O algoritmo de LM é notavelmente eficiente e fortemente recomendado para o treinamento de redes neurais (YU e WILAMOWSKI, 2011).

3.4.4.5. PSO (*Particle Swarm Optimization*)

O conceito de PSO (*Particle Swarm Optimization*) foi inicialmente introduzido por KENNEDY e EBERHART (1995) e trata-se de um método de otimização estocástica baseada em algoritmos evolutivos. O algoritmo de otimização de enxame de partículas baseia-se na imitação de um comportamento de grupo genérico simplificado de espécies como pássaros, abelhas e peixes, à medida que tendem a se mover de um local para outro (ZOLGHADR-ASLI, 2023).

Segundo WANG e REN (2023) O algoritmo de otimização por enxame de partículas tem as vantagens de convergência rápida, poucos parâmetros e fácil implementação (para problemas de otimização de alta dimensão, a otimização por enxame de partículas converge para a solução ótima mais rápido que o algoritmo genético). O PSO é uma excelente alternativa ao treinamento de pesos de redes neurais artificiais sendo também amplamente utilizado em diversos problemas que envolvem otimização.

O PSO funciona basicamente a partir de duas equações: a equação da atualização de velocidade e a equação de atualização de posição, tais atualizações ocorrem durante cada etapa de interação, até a convergência para o valor ótimo. A formulação para essas equações podem ser observadas na equação (3.49) e (3.26), respectivamente.

$$v_i^{t+1} = \underbrace{wv_i^t}_{\text{Inércia}} + \underbrace{c_1 U_1^t (P_{b1}^t - P_i^t)}_{\text{Influência pessoal}} + \underbrace{c_2 U_2^t (g_{b1}^t - P_i^t)}_{\text{Influência social}} \quad (3.25)$$

$$P_i^{t+1} = P_i^t + v_i^{t+1} \quad (3.26)$$

Em que:

- v_i^{t+1} É a velocidade da partícula na dimensão i na próxima interação $t+1$;
- w É o peso inercial que controla a inércia da partícula;
- v_i^t É a velocidade atual da partícula na interação atual;
- c_1 e c_2 São coeficientes de aprendizagem que controlam a influência do melhor local (P_{b1}^t) e do melhor global (g_{b1}^t), respectivamente;
- U_1^t e U_2^t São números aleatórios uniformemente distribuídos no intervalo $[0,1]$;

- P_{b1}^t É a melhor posição histórica da partícula;
 g_{b1}^t É a melhor posição global;
 P_i^t É a posição atual da partícula i na interação t ;
 P_i^{t+1} É a nova posição da partícula i na próxima interação $t+1$;
 v_i^{t+1} É a velocidade da partícula na próxima interação $t+1$.

Na equação 3.25 os três termos em destaque descrevem as regras básicas seguidas pelas partículas no algoritmo PSO. O primeiro termo, chamado de inércia, atua como uma memória da direção de ‘voo’ anterior, evitando mudanças abruptas na direção da partícula. O segundo termo representa a componente cognitiva, que reflete a distância e direção entre a posição atual da partícula e sua melhor posição histórica baseada na influência pessoal da partícula. O terceiro termo é conhecido como componente social, quantificando a distância e direção entre a posição atual da partícula e a melhor solução global histórica (WANG e REN, 2023).

Na **Figura 3.20** é demonstrado através de uma simples analogia como o algoritmo PSO funciona. Imagine um grupo de pássaros voando em busca de um local para descansar durante a noite. Eles estão voando em uma região onde há várias árvores, mas apenas uma delas é ideal para suas necessidades (árvore alta e de copa larga). Cada pássaro no grupo representa uma partícula no algoritmo PSO. Cada pássaro tem sua própria posição atual no espaço, que corresponde à sua posição de voo no ambiente. Além disso, cada pássaro tem conhecimento da melhor posição (árvore) que encontrou até o momento, bem como da melhor posição global encontrada por qualquer um dos pássaros no grupo. Com o tempo, os pássaros convergem para a árvore ideal, aproveitando tanto a experiência individual quanto a coletiva do grupo. Assim como as partículas no PSO convergem para a solução ótima de um problema de otimização. Neste caso os pássaros seriam as partículas e a árvore ideal (ótima) seria o ótimo global.

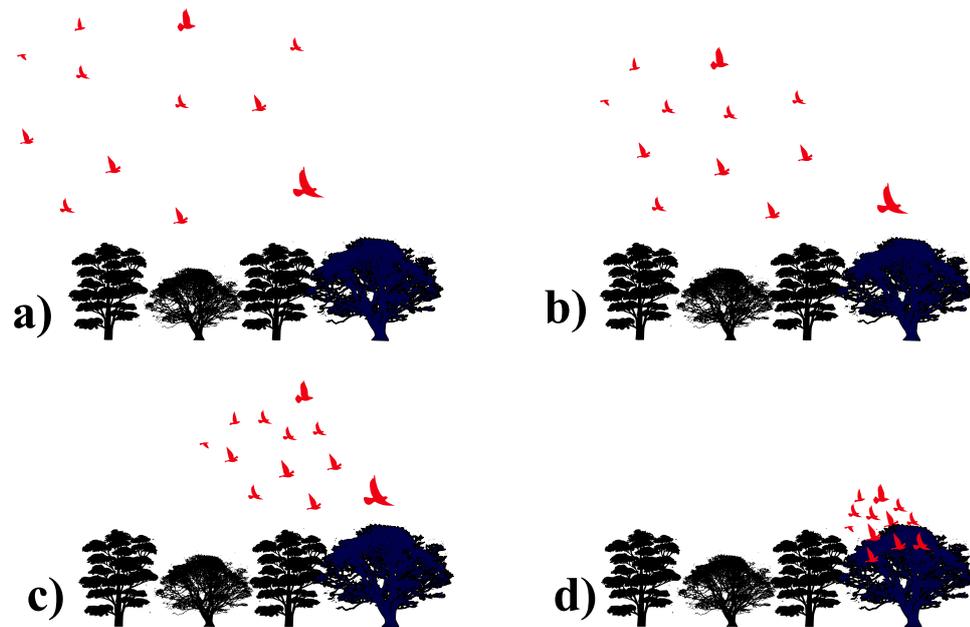


Figura 3.20 - Analogia ao PSO usando o exemplo de uma revoada de pássaros procurando a árvore ideal para repousar durante à noite.

O algoritmo de Otimização por Enxame de Partículas (PSO) é amplamente reconhecido como um dos mais respeitados na área da otimização. Sua estrutura computacional, que é ao mesmo tempo abstrata e direta, foi fundamental para impulsionar os avanços na computação paralela, além de ser utilizado em uma variedade de aplicações e áreas, com especial destaque para os algoritmos de redes neurais artificiais (ZOLGHADR-ASLI, 2023).

3.4.5. Overfitting e underfitting

Ao trabalhar com um conjunto de dados e fazer o treinamento de determinado modelo de redes neurais, busca-se encontrar o melhor ajuste. Entretanto um equilíbrio deve ser encontrado para evitar que o modelo fique superajustado (*overfit*) ou subajustado (*underfit*). Vale ressaltar que o melhor ajuste depende do modelo utilizado e do conjunto de dados que se está trabalhando.

Overfitting: Quando um modelo se ajusta em excesso a um conjunto de dados, ele aprende não apenas os padrões dos dados, mas também os ruídos e erros presentes neles. Isso resulta em um desempenho ruim quando o modelo é aplicado a novos dados, pois ele não consegue generalizar bem. O *overfitting* é identificado quando a precisão do modelo nos dados de treinamento é significativamente maior do que nos dados de teste. Isso ocorre quando o modelo tem um viés baixo e uma variância elevada.

Underfitting: Quando um modelo não consegue aprender o suficiente com os dados, chamamos isso de underfitting. É simples identificar um modelo underfit: sua precisão de treinamento é fraca. Para evitar underfitting, o modelo precisa ser treinado por mais tempo ou o número de características deve ser aumentado. Um modelo é inadequado quando tem um viés elevado e uma variância baixa.

Na **Figura 3.21** são exemplificados os casos de *underfitting*, *optimal fitting* (ajuste ideal) e *overfitting*, para problemas que envolvem regressão, classificação e aprendizado profundo.

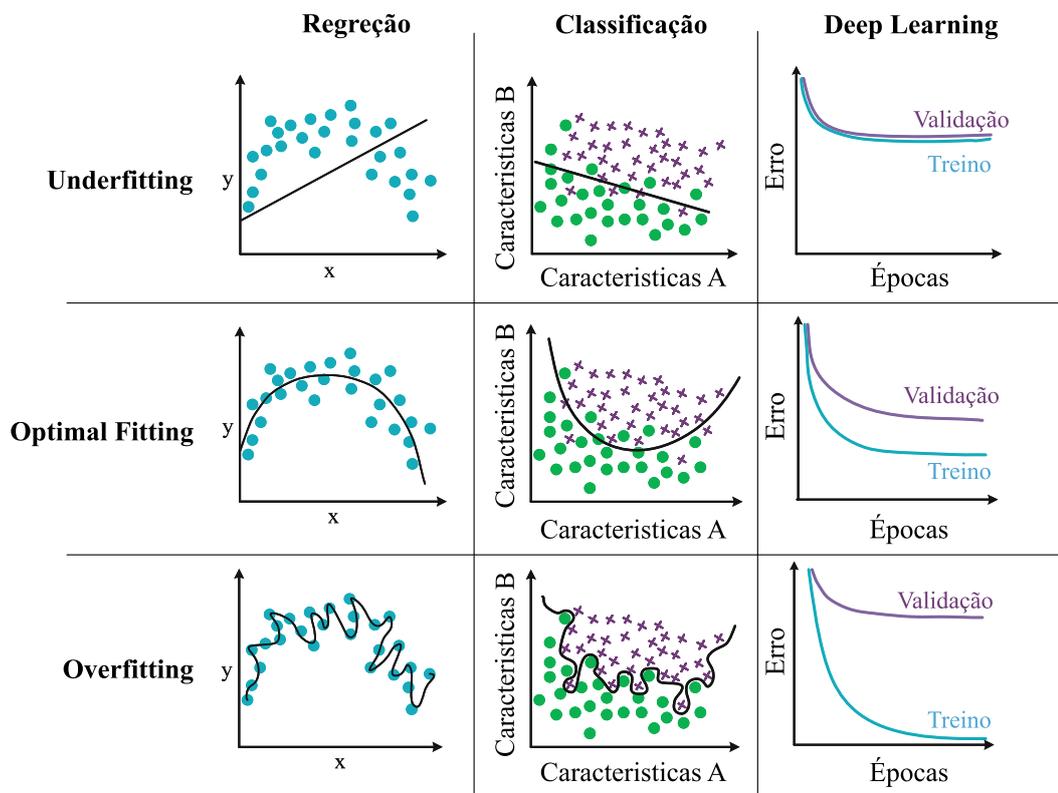


Figura 3.21-O efeito do *overfitting* e do *underfitting* nos dados de treinamento (Fonte: Adaptado de (HOSSAIN, 2024)).

Segundo HOSSAIN (2024) para evitar *overfitting*, várias medidas preventivas podem ser adotadas. Uma maneira é interromper o treinamento antecipado para evitar que o modelo aprenda características triviais dos dados. A validação cruzada é outra forma eficaz de prevenir *overfitting*. Além disso, treinar o modelo com um conjunto de dados maior reduz a probabilidade de *overfitting*. Técnicas de regularização e agrupamento também são úteis para evitar que o modelo se ajuste em excesso aos dados.

3.4.6. Matriz de confusão

Uma ferramenta importante no momento de analisar o desempenho das redes neurais artificiais de classificação é a matriz de confusão. Ela compara os valores previstos com os valores reais, possibilitando encontrar métricas importantes, como acurácia, precisão, *recall*, *F1 score*, termos que são abordados no decorrer deste tópico.

Na **Figura 3.22** é apresentado um modelo básico de uma matriz de confusão. O modelo gera uma matriz que permite comparar os resultados da classe real com a classe predita. A matriz é organizada em uma tabela onde cada linha representa as instâncias das classes reais (ou verdadeiras) e cada coluna representa as instâncias das classes previstas pelo modelo (HOSSAIN, 2024).

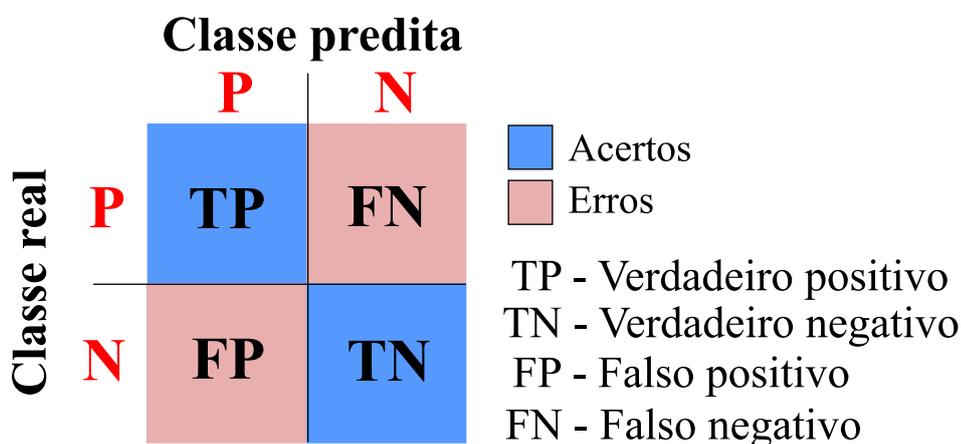


Figura 3.22- Representação de uma matriz de confusão

Os elementos da matriz de confusão são:

- TP (True Positive ou Verdadeiro Positivo): Indica o número de instâncias corretamente previstas como positivas;
- TN (True Negative ou Verdadeiro Negativo): Indica o número de instâncias corretamente previstas como negativas;
- FP (False Positive ou Falso Positivo): Indica o número de instâncias incorretamente previstas como positivas, quando na verdade são negativas;
- FN (False Negative ou Falso Negativo): Indica o número de instâncias incorretamente previstas como negativas, quando na verdade são positivas.

Através da matriz de confusão é possível calcular várias métricas importantes que indicam o desempenho do modelo, tais como:

Acurácia: Proporção de todas as previsões corretas, e pode ser calculada como:

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.27)$$

Precisão (Precision): Proporção de instâncias preditas como positivas que são realmente positivas, calculada como:

$$Precisão = \frac{TP}{TP + FP} \quad (3.28)$$

Revocação (Recall) ou Sensibilidade: Proporção de instâncias positivas corretamente identificadas pelo modelo, calculada como:

$$Recall = \frac{TP}{TP + FN} \quad (3.29)$$

F1 Score: Média harmônica da precisão e do *recall*, calculada como:

$$F1\ Score = 2x \frac{Precisão \times Recall}{Precisão + Recall} \quad (3.30)$$

A matriz de confusão é uma ferramenta fundamental para a avaliação de modelos de classificação. Ela permite uma análise detalhada do desempenho do modelo. Utilizando as métricas derivadas da matriz de confusão, é possível tomar decisões sobre ajustes e melhorias no modelo (HOSSAIN, 2024).

3.5. ALGUNS CONCEITOS SOBRE O CAOS

No imaginário popular a palavra caos está associada a bagunça, tumulto, desordem (o trânsito está um caos, caos econômico, caos climático, caos social) ou outra palavra que remete sempre ao imaginário de que, algo está fora do lugar, de modo que é difícil encontrar um padrão. Entretanto, nas últimas décadas cientistas, matemáticos, físicos e engenheiros vêm se esforçando com o objetivo de encontrar ordem no caos, bem como o limiar entre caos determinístico e aleatoriedade.

No presente tópico serão abordados conceitos sobre o ‘caos’, mostrando o seu histórico e trabalhos que lançaram a base da teoria do caos com suas aplicações nas mais diversas áreas do conhecimento, serão abordados também os aspectos teóricos e práticos da técnica SAC-DM (*Signal Analysis based on Chaos Using Density of Maxima*) um

desdobramento da teoria do caos, utilizada neste trabalho para diagnosticar falhas em rolamento de motores de indução trifásicos a partir do sinal da corrente de armadura.

3.5.1. Breve Histórico sobre o caos

As origens da teoria do caos como conhecemos hoje, do ponto de vista matemático e científico teve uma longa evolução e descobertas, passando pelos fundamentos filosóficos e mitológicos dos gregos antigos, dentre eles Hesíodo até sua primeira formulação, elaborada pelo matemático francês Henri Poincaré na década de 1890 (mesmo que abordada de uma terminologia diferente da usada atualmente), que descrevia a possibilidade de movimento caótico em seu artigo sobre estabilidade do sistema solar (POINCARÉ, 1899).

A matemática Russa, Sonia Kovalevskaia, comprovou que o movimento de um pião pesado e assimétrico é geralmente caótico, sendo regular somente em valores especiais do momento de inércia. Os resultados sobre esse trabalho bem como os resultados de Henri Poincaré ficaram hibernando durante algum tempo.

Trabalhos importantes também foram desenvolvidos pelo cientista americano George Birkhoff e seu colega alemão Eberhard Hopf sobre mecânica estatística e teoria ergódica. Na década de 1960 os cientistas, Andrey Kolmogorov, Vladimir Arnold e o alemão Jürgen Moser elaboraram a declaração que desde então recebeu o nome de suas iniciais, o teorema KAM, responsável por formular a condição de fraco movimento caótico em sistemas conservativos (TÉL e GRUIZ, 2006).

Com o surgimento do computador foi possível investigar mais detalhes do caos. Edward Lorenz, meteorologista americano em 1963 lançou as bases para a compreensão do caos a partir de simulações computacionais, a máquina usada por Lorenz era uma Royal McBee, composto por um emaranhado de cabos e tubos de vácuo que ocupava uma parte desajeitada do escritório e fazia um barulho surpreendente e irritante e quebrava a cada semana (GLEICK, 1989).

Lorenz estudou um modelo simplificado de rolos de convecção na atmosfera para obter informações sobre a notória imprevisibilidade do clima. Lorenz descobriu que as soluções de suas equações nunca chegavam ao equilíbrio ou a um estado periódico, em vez disso, elas continuavam a oscilar de maneira irregular e aperiódica (STROGATZ, 2018).

Caso ele iniciasse a simulação a partir de duas condições iniciais ligeiramente diferentes os resultados finais se tornariam totalmente diferentes, confirmando que o sistema era imprevisível, isso implicava que pequenos erros na medição da atmosfera seriam amplificados rapidamente, levando a conclusão que o modelo era fortemente afetado pelas condições iniciais.

LORENZ (1963) em seu trabalho “*Deterministic Non periodic flow*” introduziu as famosas equações de Lorenz, mostrando que pequenas diferenças nas condições iniciais levam a grandes desvios na evolução temporal simulada numericamente. O sistema de Lorenz trata-se de um exemplo clássico de sistema autônomo que apresenta um atrator estranho, conforme Equação (3.31). O sistema é composto por três equações diferenciais ordinárias de primeira ordem (FIEDLER-FERRARA e DO PRADO, 1994).

$$\begin{cases} \dot{x} = -\sigma(x - y) \\ \dot{y} = rx - y - xy \\ \dot{z} = xy - bz \end{cases} \quad (3.31)$$

O parâmetro σ é a razão entre a viscosidade cinemática e o coeficiente de difusão térmica, número de Prandtl's. Já o parâmetro r representa o número de Rayleigh.

Em sua palestra em 1972 cujo tema era: “*Previsibilidade: o bater de asas de uma borboleta no Brasil desencadeia um tornado no Texas?*”, Lorenz acabou mexendo com o imaginário das pessoas ao sugerir que pequenas oscilações poderiam desencadear efeitos imprevisíveis. Graças a Lorenz e a popularidade do livro *Chaos: Making a New Science* escrito pelo escritor norte americano James Gleick o termo “efeito borboleta” se popularizou (TÉL e GRUIZ, 2006). Embora o modelo proposto por Lorenz mostrasse que pequenas oscilações acarretaria previsões embaraçosas ele também mostrou que havia estrutura no caos - quando plotado em três dimensões, as soluções para suas equações caíram em um conjunto de pontos em forma de borboleta, **Figura 3.23**. Lorenz argumentou que esse conjunto tinha que ser “um complexo infinito de superfícies”, hoje nós o consideraríamos um exemplo de fractal (STROGATZ, 2018).

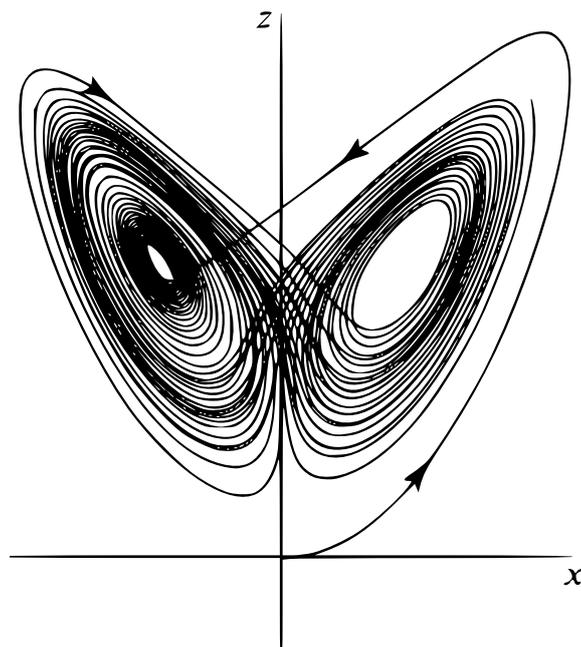


Figura 3.23- Atrator de Lorenz (Fonte:(STROGATZ, 2018))

O termo ‘caos’ foi introduzido pelos matemáticos norte-americanos James Yorke e Tien-Yein Li, em seu artigo publicado em 1975, cujo título era “*Period three implies chaos*” com estudo sobre a dinâmica de aparência aleatória de sistemas determinísticos simples (LI *et al.*, 1975).

Mitchell Feigenbaum foi outro brilhante físico norte americano que ajudou o termo caos a se popularizar. Em 1978 ele provou a independência do sistema, ou seja, a chamada universalidade, de uma das possíveis rotas para o caos. O estudo dessa rota de duplicação periódica para o caos deu origem a uma nova constante universal chamada constante de Feigenbaum. Ele mostrou que para todos os sistemas 1D não lineares, que seguem a rota de duplicação de período para o caos, a razão dos valores sucessivos dos parâmetros é sempre uma constante, independente dos detalhes reais das equações (UPADHYAY e IYENGAR, 2013).

A constante de Feigenbaum como ficou conhecida passou a ser uma constante universal de valor $\delta = 4.6692016091029 \dots$ essa constante relaciona os intervalos entre bifurcações consecutivas, para mais detalhes verificar (FEIGENBAUM, 1978; FEIGENBAUM, 1979).

Outro grande passo na compressão do mundo fantástico da imprevisibilidade retratada e estudada na teoria do caos foi a elaboração da teoria fractal. Embora o caos tenha roubado os holofotes na década de 1970 outro grande desenvolvimento da dinâmica

foi a codificação e a população dos fractais graças ao matemático Polonês-Franco-Americano Benoît Mandebroud que reuniu um compilado de trabalhos em seu livro “*The Fractal Geometry of Nature*” em 1982. Mandebroud foi o responsável por cunhar o termo fractal e elaborar o conceito de dimensão fractal, graças a ele é possível compreender os caos através de representações gráficas, os atratores estranho de Lorenz, por exemplo, podem se classificados como um conjunto fractal.

Segundo STROGATZ (2018) fractais são formas geométricas complexas com estrutura fina em escalas arbitrariamente pequenas. Geralmente eles têm algum grau de auto-semelhança. Em outras palavras, se ampliarmos uma pequena parte de um fractal, veremos características que lembram o todo. Na **Figura 3.24** é possível verificar a representação de duas das inúmeras geometrias fractais existentes.

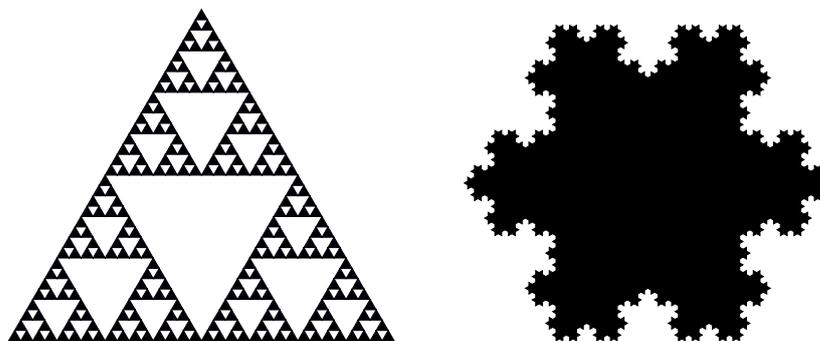


Figura 3.24- Representação de fractais, á esquerda o triângulo de Sierpinski e a direita o fractal floco de neve de Koch.

Muitos cientistas, matemáticas e pesquisadores de diversas áreas do conhecimento ajudaram a melhorar a compreensão dos conceitos que regem o comportamento caótico. Segundo (TÉL e GRUIZ, 2006) na investigação das propriedades estatísticas do caos, um papel importante foi desempenhado por, entre outros, B. Chirikov, M. Berry, L. Bunimovich, J. P. Eckmann, H. Fujisaka, P.Grassberger, C. Grebogi, M. Hénon, P. Holmes, L. Kadanoff, E. Ott, O. Röessler, D. Ruelle, Y. Sinai, e S. Smale. Ainda, de acordo com o autor supracitado a possibilidade de ocorrência do caos estabeleceu uma nova maneira de pensar, tornando-se um elo entre diferentes disciplinas amplamente diferentes, como meteorologia, acústica, nanotecnologia, biológica, ecologia, medicina e diversas outras áreas do conhecimento. Alguns desses pioneiros foram, entre outros, H. Aref, P. Cvitanović, J. Gollub, A. Libchaber, R. May, C. Nicolis, H. Swinney, Y. Ueda e J.

Wisdom. Na **Tabela 3.2** é mostrado um breve histórico com os principais nomes que contribuíram no campo da dinâmica não linear.

Tabela 3.2 - Breve histórico sobre a evolução da dinâmica e os principais cientistas que contribuíram para a compreensão do caos. Fonte: (Traduzido de (STROGATZ, 2018, p.5)).

Dinâmica-Breve Histórico		
1666	Newton	Invenção do cálculo, explicação de movimento planetário.
1700s		Florescimento do cálculo e da mecânica clássica.
1800s		Estudos analíticos do movimento planetário.
1890s	Poincaré	Abordagem geométrica, pesadelos do caos.
1920-1950		Osciladores não lineares em física e engenharia, invenção do rádio, radar, laser.
1920-1960	Birkhoff	Comportamento complexo na mecânica hamiltoniana.
	Kolmogorov	
	Arnol'd	
	Moser	
1963	Lorenz	Atrator estranho em modelo simples de convecção.
1970s	Ruelle&Takens	Turbulência e caos.
	May	Caos no mapa logístico.
	Feigenbaum	Universalidade e renormalização, conexão entre o caos e as transições de fase.
		Estudos experimentais do caos.
	Winfree	Osciladores não lineares em biologia.
	Mandelbrot	Fractais.
1980s		Interesse generalizado em caos, fractais, osciladores e suas aplicações.

3.5.2. Pêndulo duplo

Dentre os sistemas clássicos de estudo sobre a teoria do caos o pêndulo duplo é um dos exemplos de melhor representação dos sistemas dinâmicos não lineares. O pêndulo

duplo, como o próprio nome sugere, consiste em dois pêndulos sendo um deles acoplado a extremidade do outro, conforme pode se observado na **Figura 3.25**.

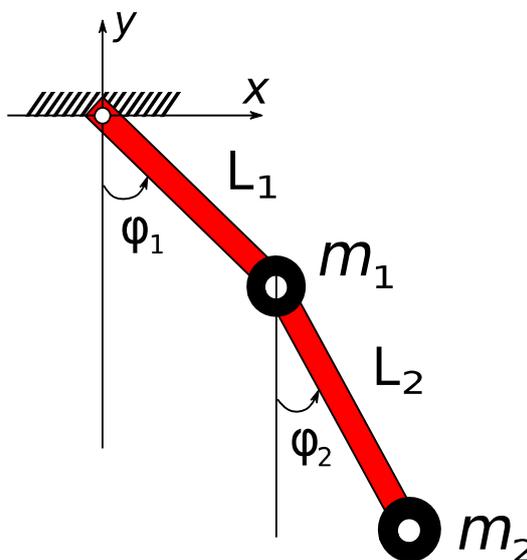


Figura 3.25- Modelo simplificado de um Pêndulo duplo e suas coordenadas generalizadas

Os ângulos φ_1 e φ_2 correspondem aos ângulos formados entre as barras de comprimentos (L_1 e L_2 com massas m_1 e m_2 respectivamente) em relação ao eixo das ordenadas no plano cartesiano.

O pêndulo duplo apresenta forte sensibilidade às condições iniciais seu movimento é regido por um conjunto fechado de equações diferenciais ordinárias. Algumas formulações podem ser utilizadas a fim de modelar o seu comportamento desde a formulação de Newton, passando pela formulação de Lagrange até a formulação de Hamilton.

O pêndulo duplo pode ser modelado por quatro equações diferenciais acopladas representadas por quatro coordenadas generalizadas. Segundo STROGATZ (2018) em um sistema que é determinado por mais de três variáveis e é modelada por equações não lineares é possível verificar a presença do caos. Em se tratando do pêndulo duplo é possível verificar que o sistema possui quatro equações, podendo, de tal forma, ser considerado como um sistema caótico (BASTOS, 2017).

Por meio das equações de movimento do pêndulo duplo é possível fazer simulações via análise numérica, sendo o método preferencial o método de Hunge-Kutta (CHAPRA e CANALE, 2011). Para efeito de exemplificação foi utilizado neste trabalho o software *Working Model 2D* (software utilizado no ensino de física e mecanismos) onde foi possível

simular o lançamento do pêndulo de forma virtual. A mínima variação do ângulo de lançamento torna a trajetória do mesmo totalmente imprevisível, funcionando neste caso como vetor para emular a sensibilidade às condições iniciais que ocorrem no pêndulo real de forma natural, seja pelo atrito nas juntas ou pela variação do deslocamento de ar que ocorre durante o lançamento.

Na **Figura 3.26** é possível verificar as disposições dos componentes do pêndulo duplo bem como os eixos de coordenadas que foram utilizados como referência para a simulação. O eixo y foi utilizado como referência para os lançamentos, com o pêndulo totalmente esticado na posição vertical com o intuito de utilizar a energia potencial como gatilho. As posições de lançamento em relação ao eixo y foram de 0° e 0.1° respectivamente.

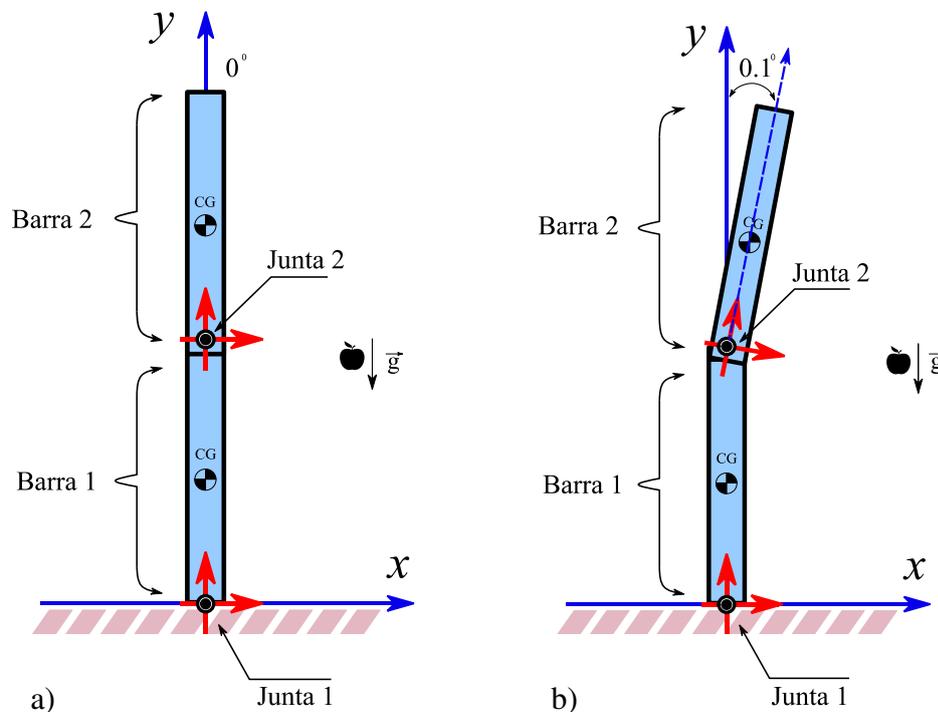


Figura 3.26- Pêndulo duplo e seus componentes na posição de lançamento para: a) 0° e b) 0.1° .

O primeiro lançamento do pêndulo partiu da posição totalmente esticada de modo que o ângulo formado em relação ao eixo das ordenadas fosse de 0° , já no segundo lançamento o ângulo foi de 0.1° . Na **Figura 3.27** podem-se verificar as trajetórias para ambos os lançamentos e o rastreamento de suas coordenadas ao decorrer do tempo, de tal forma que é possível visualizar que as duas trajetórias apesar de semelhantes nos primeiros instantes do lançamento tendem a apresentar comportamentos divergentes uma da outra, caracterizando, de tal forma, sua sensibilidade às condições iniciais.

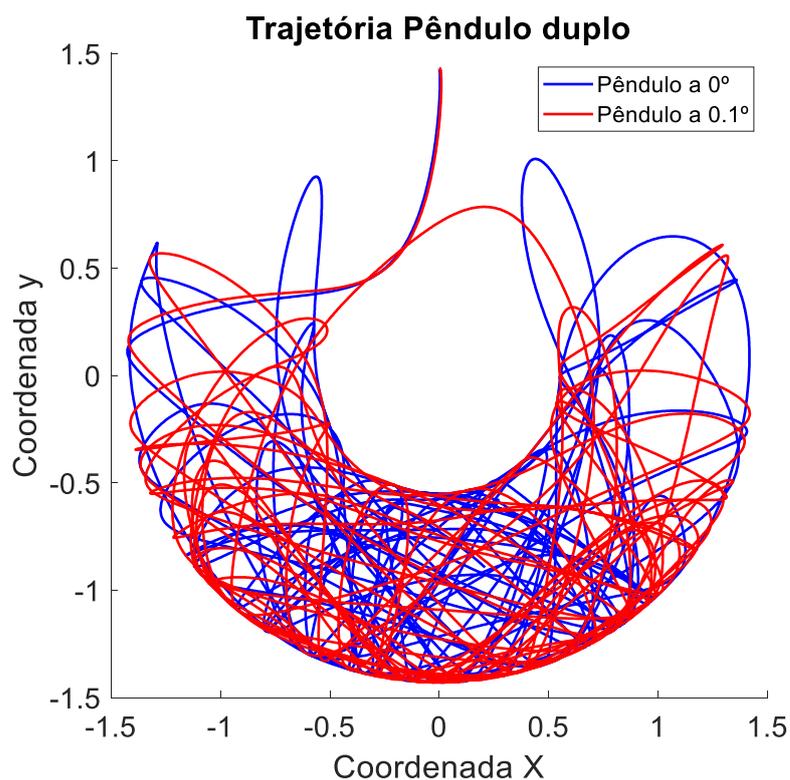


Figura 3.27- Trajetória da segunda barra do pêndulo duplo para lançamentos de 0° e 0.1° .

A simulação consistiu na análise do movimento da segunda barra do pêndulo duplo utilizando o seu centro de gravidade como referência. Na **Figura 3.28** é possível analisar a velocidade da barra 2, em ambos os lançamentos até o instante de 6 segundos as trajetórias do sinal de velocidade são quase idênticas, mas logo em seguida apresentam um comportamento divergente.

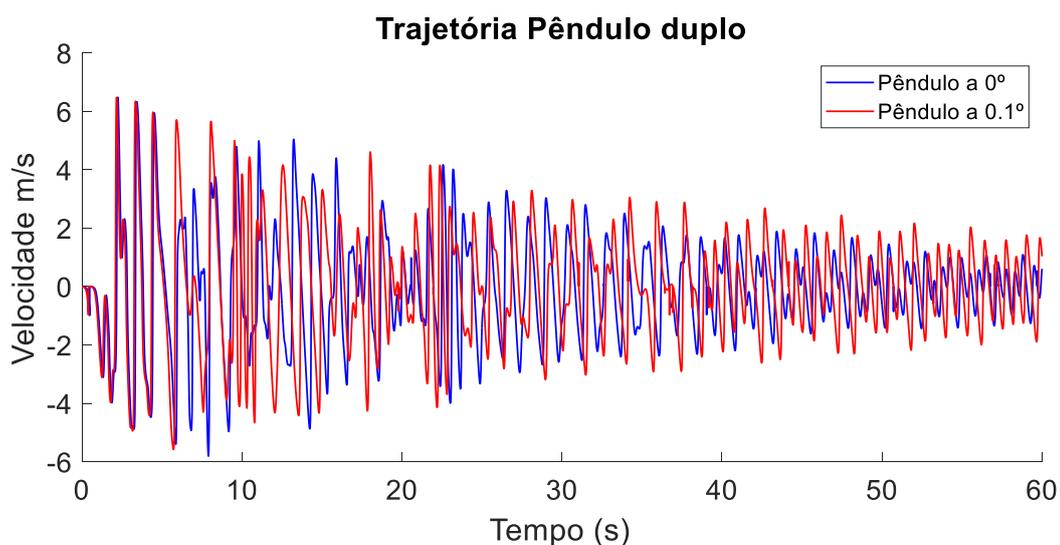


Figura 3.28- Gráfico da variação da velocidade em um pêndulo duplo ao decorrer do tempo.

3.6. TESTES PARA O DETERMINISMO

No estudo da dinâmica associada a séries temporais experimentais algumas das dificuldades encontradas residem no fato de que, em boa parte das vezes não é possível definir as equações de movimento que as regem, de tal forma que uma das preocupações do experimentador ao medir um sinal temporal discreto é tentar determinar que tipo de sistema dinâmico o produziu.

Segundo FIEDLER-FERRARA e DO PRADO (1994), o caos determinístico é essencialmente devido à DCI (dependência sensitiva às condições iniciais), essa dependência, quando existe, resulta das não linearidades presentes nos sistemas, as quais amplificam exponencialmente pequenas diferenças nas condições iniciais.

Ainda segundo o autor mesmo que de maneira qualitativa é possível apresentar algumas características do comportamento caótico determinístico sendo eles: Imprevisibilidade, espectro contínuo de frequência, invariância de escala e estacionaridade.

No estudo de séries temporais experimentais uma etapa importante é a caracterização da série, para isso é necessário que os dados passem por um teste de determinismo. O teste de determinismo tenta determinar se os dados em análise são do tipo estocástico ou determinístico. Processos estocásticos geralmente possuem um elevado número de graus de liberdade, e regularmente são tratados pelo uso de distribuição de probabilidades (OSORIO, 2015).

Os métodos tradicionais de análise de sinais experimentais como a análise do espectro de potências e da função de autocorrelação podem identificar os processos regulares, a exemplo de sinais periódicos, multi-periódicos, quase periódicos e caóticos. Na **Figura 3. 29** é possível visualizar a aplicação do método utilizando autocorrelação para determinar o comportamento de diferentes tipos de sinais. Observando a Figura vale atentar para o item (d) que representa o comportamento de um sinal caótico, neste caso, o sinal tende a zero, isso ocorre porque a semelhança de um sinal consigo mesmo diminui com o tempo e acaba por desaparecer completamente (FIEDLER-FERRARA e DO PRADO, 1994).

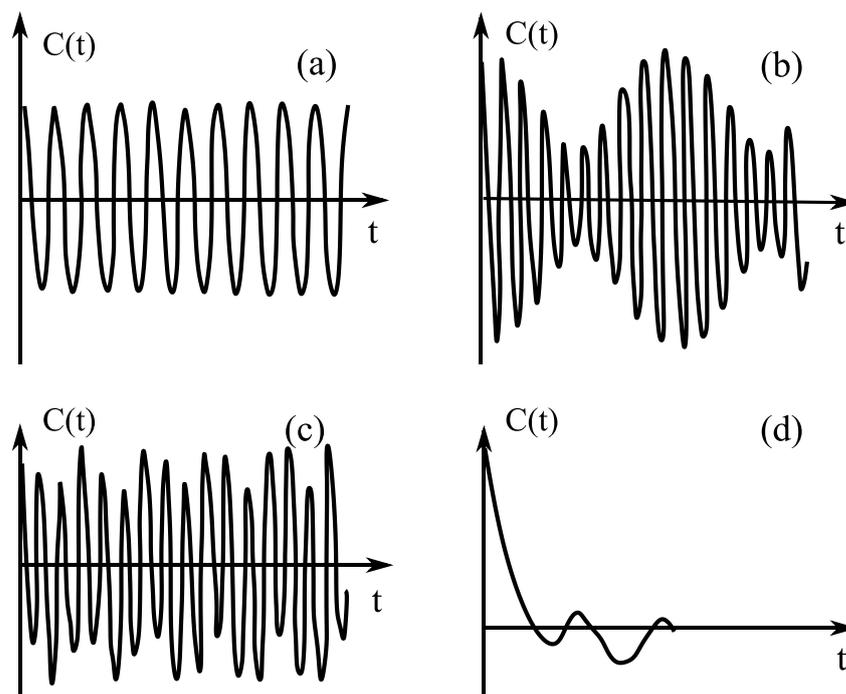


Figura 3. 29- Função de autocorrelação. a) Sinal periódico $x(t) = \cos t$; b) sinal quase-periódico $x(t) = \cos 3t + \cos \pi t$; c) sinal quase-periódico $x(t) = \cos t + 2\cos \pi t$; d) sinal caótico. (Fonte: Adaptado de (FIEDLER-FERRARA e DO PRADO, 1994. p.293))

3.6.1. Teste da árvore de símbolos

O teste da árvore de símbolos consiste basicamente em transformar uma série temporal x_i em uma série simbólica S_i . A princípio Lempel e Ziv em 1976, propuseram o método de reconstruir a sequência simbólica de séries temporais finitas como medida da complexidade de uma série temporal. Em 1989 os pesquisadores Crutchfield e Young talharam o conceito de árvore de símbolos (YANG e ZHAO, 1998),.

No método abordado por YANG e ZHAO (1998), os autores usaram técnicas simbólicas para detectar determinismo em uma série temporal, utilizando séries temporais caóticas simuladas como o mapa de Henon e o mapa logístico; séries estocásticas como o ruído branco e sinais biológicos de eletromiografia (EMG).

A primeira etapa para aplicar o teste da árvore de símbolos é converter a série temporal em uma sequência de símbolos, passando-a por uma função limiar, dada pelas Equações (3.52) e (3.54).

$$\{x_i\} \rightarrow \{S_i\} \quad i = 1, 2 \dots N \quad (3.32)$$

Em que $S_i \in (0,1)$, logo a construção simbólica será

$$\begin{aligned} \text{if } x_i < \text{mediana}(\{X_i\}), S_i &\equiv 0 \\ \text{if } x_i > \text{mediana}(\{X_i\}), S_i &\equiv 1 \end{aligned} \quad (3.33)$$

A partir da sequência de símbolos formada $\{S_i\}$ é possível construir a árvore de símbolos como pode ser observado na **Figura 3.30**.

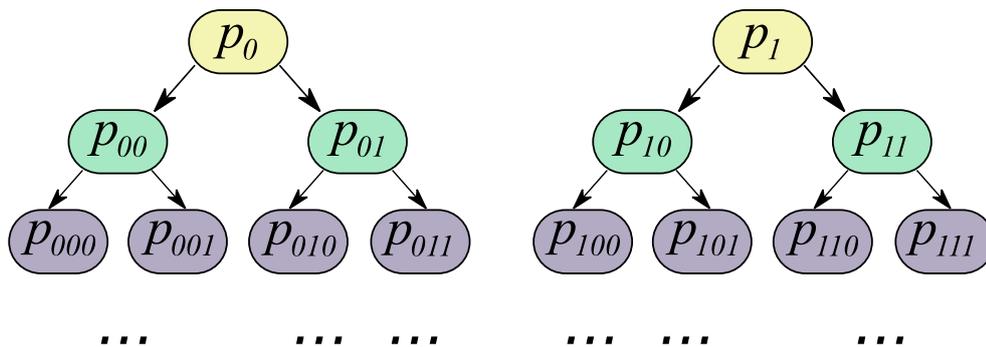


Figura 3.30- Representação da árvore de símbolos. (Fonte: Adaptado de (YANG e ZHAO, 1998))

O teste da árvore de símbolos usa uma simbolização binária da série temporal que está sob análise, onde cada linha corresponde a um determinado nível, de cima para baixo, os níveis são definidos por L , podem ser $L=1, L=2, L=3$, etc. Os níveis significam que cada linha tem 2^L números do tipo de probabilidade. Para um $L=3$, por exemplo, a sequência seria formada por 8 palavras possíveis, montando a tabela verdade, a sequência seria (000,001,010,011,100,101,110,111).

O passo posterior para implementar o teste da árvore de símbolos é particionar a série simbólica de comprimento N em subconjuntos disjuntos de comprimento l em seguida escolhe-se qual o nível L deseja-se utilizar. Para cada partição de comprimento l haverá $l - (L-1)$ “palavras”, de modo que o segundo elemento de uma palavra é o primeiro elemento da próxima, após este processo recomenda-se converter a sequência para a base decimal, o que ajuda a acelerar o computo do teste do espectro de símbolos (KULP e SMITH, 2011). Na **Figura 3.31** é exemplificado o processo de transformação de uma série temporal em uma série simbólica no teste da árvore de símbolos.

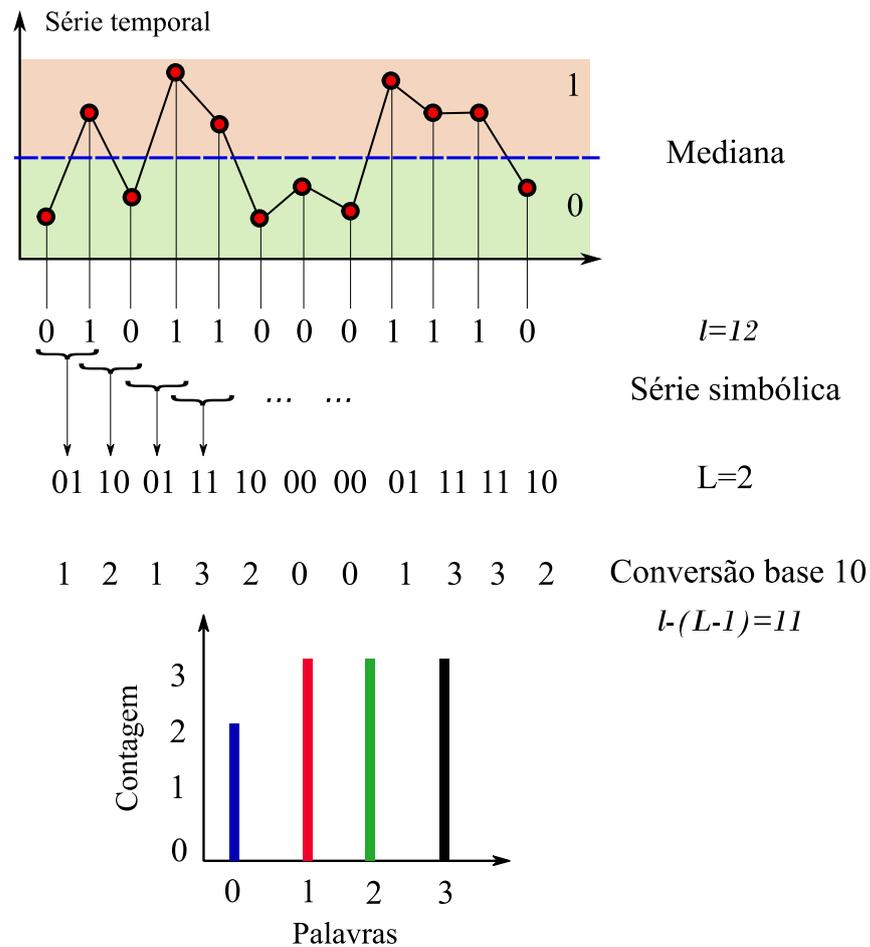


Figura 3.31- Representação do processo de transformação de uma série temporal em uma série simbólica no teste da árvore de símbolos.

Através da formação do gráfico dos espectros de símbolos é possível verificar se a série em análise é determinística ou estocástica. Segundo KULP e SMITH (2011), o número de 20 espectros tendem a ser suficientes para determinar se os espectros são semelhantes ou não, já no que concerne a partição, se o número escolhido for muito grande o comprimento da partição pode ser muito curto para produzir um espectro confiável. Após a etapa de escolha do comprimento l da partição pode-se escolher L , que basicamente determina o número de palavras diferentes no espectro.

Utilizando o mapa logístico Equação (3.34) é possível testar se a série em análise é periódica, caótica ou aleatória. O mapa logístico é um exemplo clássico na iniciação de estudos do caos, foi proposto inicialmente para observar o comportamento populacional em insetos e suas flutuações, para mais detalhes verificar (MAY, 1976).

$$x_{n+1} = rx_n(1 - x_n) \quad (3.34)$$

Na **Figura 3.32** é possível verificar o resultado das simulação de séries usando o mapa logístico e um ruído branco, foi utilizando $N=50000$ pontos, com o comprimento $l=1000$ e um nível $L=6$. No item a) foi utilizado os parâmetros $r= 3,55$ e $x_0 = 0,95$, já para o item b) $r= 3,95$ e $x_0 = 0,95$. Por fim, foi feita a simulação do sinal de um ruído branco, item (c).

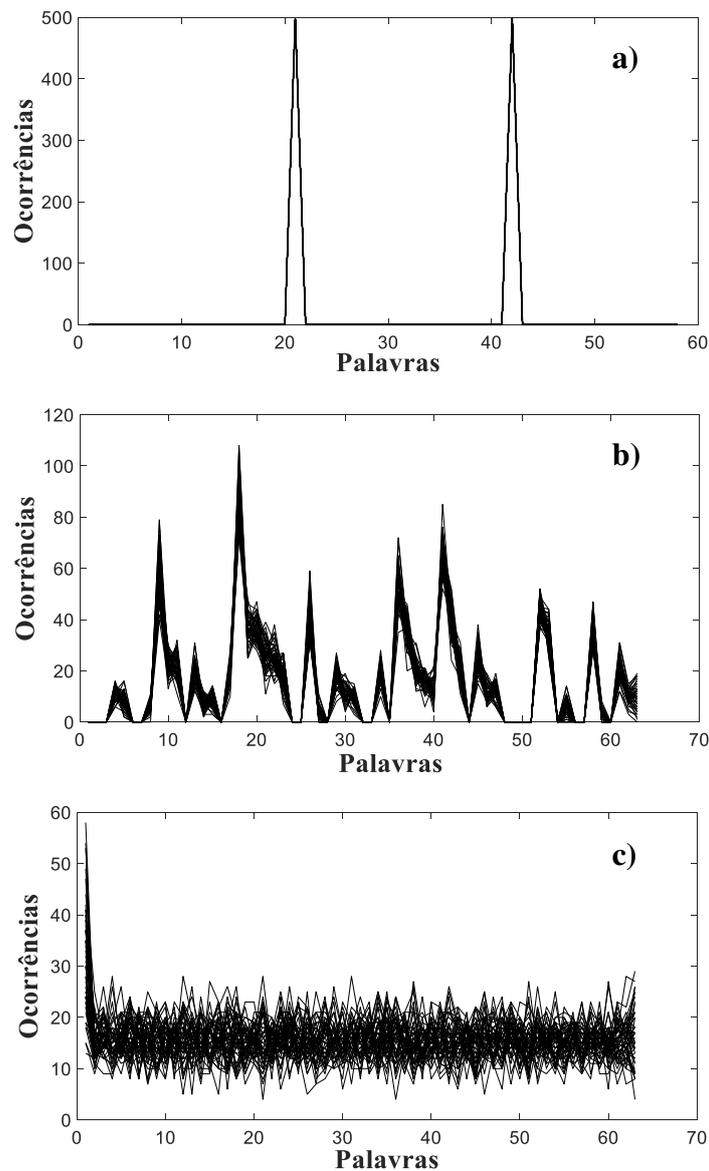


Figura 3.32- Teste da árvore de símbolos, espectro da árvore de símbolos para uma série:
a) periódica; b) caótica; c) aleatória.

Os padrões formados nas figuras acima são fortes indícios para indicar a presença ou ausência de caos na série, bem como da aleatoriedade. Na **Figura 3.32** item **a)** cada espectro de símbolo é plotado um sobre o outro, neste caso 50 espectros foram utilizados percebe-se a formação de uma imagem semelhante que serve como indicativo para definir a série como determinística, no item **b)** percebe-se outro tipo de padrão formado, embora com espectros ligeiramente dispersos uns dos outros, a semelhança entre os espectros serve para determinar a série também como determinística, já na ultima figura item **c)** não é possível verificar a formação de padrão com os espectros totalmente dispersos, sem a formação de imagens semelhantes, indicando tratar-se de um série estocástica.

3.6.2. Método do Teste 0-1 para detecção de Caos

O teste 0-1 consiste basicamente em identificar o caos em séries determinísticas, inicialmente foi proposto por GOTTWALD e MELBOURNE (2004). Segundo os autores o novo método, em contraste com o método usual de calcular o expoente máximo de Lyapunov, pode ser aplicado diretamente aos dados da série temporal e não requer reconstrução do espaço de fase, além disso, no método do teste 0-1 as dimensões do sistema dinâmico e a forma das equações subjacentes são irrelevantes.

As entradas do método é qualquer sistema dinâmico de série determinística, e a saída é expressa por 0-1, a saída gerada será 1 quando a série for considerada caótica e 0 quando a série for considerada periódica ou quase periódica (SKIADAS e SKIADAS, 2016).

Segundo GOTTWALD e MELBOURNE (2009) a implementação teórica do teste 0-1, segundo suas revisões, pode ser seguida da seguinte forma: considere uma série temporal $\phi(j)$, para $j = 1, \dots, N$, segue-se para as etapas do computo das variáveis $p_c(n)$ e $q_c(n)$, pelas Equação (3.35).

$$\begin{aligned} p_c(n) &= \sum_{j=1}^n \phi(j) \cos jc \\ q_c(n) &= \sum_{j=1}^n \phi(j) \sin jc \end{aligned} \tag{3.35}$$

Onde $n = 1, 2, \dots, N$, $\phi(j)$ é um observável construído a partir de um série temporal $c \in (0, \pi)$ é escolhido aleatoriamente. Já as variáveis $p_c(n)$ e $q_c(n)$ são definidas como “variáveis de conversão”, é o comportamento dessas variáveis de translação (difusivas ou não difusivas) que determinam se o comportamento da dinâmica do sistema é regular ou caótica (KULP e SMITH, 2011).

Ainda segundo os autores anteriormente citados, para determinar o comportamento das variáveis de translação ($p_c(n)$ e $q_c(n)$), para vários valores de $c \in (0, \pi)$, o teste usa o deslocamento quadrado médio através da Equação (3.36) listada abaixo.

$$M_c(n) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{j=1}^N [p_c(j+n) - p_c(j)]^2 + [q_c(j+n) - q_c(j)]^2 \quad (3.36)$$

A equação acima requer que $n \ll N$ seja verdadeira, calcula-se o deslocamento quadrado médio usando a definição acima, diretamente. Já o limite é assegurado pelo cálculo de $M_c(n)$ apenas para a $n \leq n_{corte}$, onde $n_{corte} \ll N$. Na prática valores de $n_{corte} = N/10$ é suficiente para produzir bons resultados (GOTTWALD e MELBOURNE, 2009).

O teste para o caos é baseado na taxa de crescimento de $M_c(n)$ em função de n . Logo, para cada valor de $c \in (0, \pi)$, $M_c(n)$ assume a forma da Equação (3.37), com melhores propriedades de convergência.

$$M_c(n) = V(c)n + V_{osc}(c, n) + e(c, n) \quad (3.37)$$

Onde $e(c, n)/n$ é o termo referente ao erro ($e(c, n)/n \rightarrow 0$ quando $n \rightarrow \infty$) é:

$$V_{osc}(c, n) = (E\phi)^2 \frac{1 - \cos nc}{1 - \cos c} \quad (3.38)$$

O valor da expectativa $E\phi$ da série temporal e dada por:

$$E\phi = \lim_{n \rightarrow \infty} \frac{1}{N} \sum_{j=1}^N \phi(j) \quad (3.39)$$

O termo ϕ corresponde ao valor esperado da série temporal. Portanto, ignorando o termo de erro $M_c(n)$ tem a forma de um cosseno com inclinação dada por V_c (KULP e SMITH, 2011). O variável V_c é constante para um determinado valor de c . Para encontrar a inclinação, subtrai-se o termo V_{osc} do termo $M_c(n)$, com o intuito de criar um deslocamento quadrado médio modificado, definido pela Equação (3.40) (SKIADAS e SKIADAS, 2016).

$$D_c(n) = M_c(n) - V_{osc}(c, n) \quad (3.40)$$

O cálculo da taxa de crescimento assintótica K_c do deslocamento quadrado médio modificado $D_c(n)$. GOTTWALD e MELBOURNE (2009) apresentam dois métodos diferentes para o cálculo do K_c nomeados de método de regressão e o método de correlação, de modo que a taxa de crescimento assintótico é definido pelo coeficiente correlação dos vetores, $\xi = (1, 2, \dots, n_{cut})$ e $\Delta = (D_c(1), D_c(2), \dots, D_c(n_{corte}))$. De forma a dar prosseguimento ao teste, será utilizado o método da correlação.

O método é descrito em termos de D_c , mas poderia ser utilizado o termo $M_c(n)$. Dados os vetores x, y de comprimento q , a definição de covariância e variância pode ser definida por:

$$\begin{aligned} cov(x, y) &= \frac{1}{q} \sum_{j=1}^q (x(j) - \bar{x})(y(j) - \bar{y}) \\ \bar{x} &= \frac{1}{q} \sum_{j=1}^q x(j) \\ var(x) &= cov(x, x) \end{aligned} \quad (3.41)$$

Logo, definindo o coeficiente de correlação k_c :

$$k_c = corr(\xi, \Delta) = \frac{cov(\xi, \Delta)}{\sqrt{var(\xi)var(\Delta)}} \in [-1, 1] \quad (3.42)$$

Segundo GOTTWALD e MELBOURNE (2009) obtém-se que $k_c = 0$ para dinâmica regular e $k_c = 1$ para dinâmica caótica. Em termos práticos, o método de correlação supera em muito o método de regressão.

Para fins de comparação foi utilizado o mapa logístico a fim de comprovar a eficácia do teste 0-1 para o caos. Para verificar a natureza periódica da série temporal foi utilizada a configuração $r = 3,55$ e $x_0 = 0,95$ para as variáveis do mapa logístico com 50.000 pontos, o resultado pode ser observado na **Figura 3.33 a)**. Como esperado, de acordo com a formulação apresentada no presente item o valor dos dados agrupados em “0” foi verificado, comprovado que a série é periódica. Já na **Figura 3.33 b)** os valores do mapa logístico foram alterados para a configuração $r = 3,95$ e $x_0 = 0,95$, para simular uma série temporal caótica, novamente foi possível comprovar de acordo com a formulação apresentada, que os dados ficaram agrupados em torno de “1”, indicando tratar-se de uma série caótica.

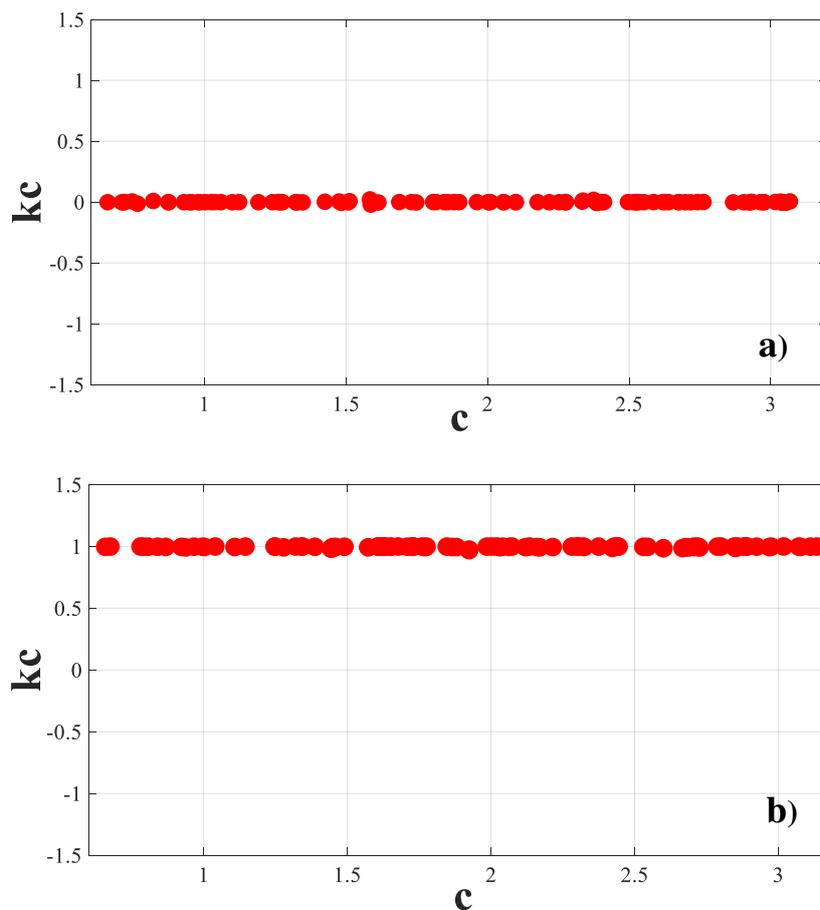


Figura 3.33-Teste 0-1 para o caos usando o mapa logístico resultados para a) uma série com dinâmica regular b) uma série com dinâmica caótica.

3.6.3. Método do comprimento de correlação

Para analisar comportamento caótico, CCC utiliza correlação probabilística, onde o coeficiente de correlação inicial de um sinal se apresenta como quantificador do comportamento caótico do sistema. Isso se deve ao fato de sistemas caóticos apresentarem uma autocorrelação ao longo do tempo, diferente de sistemas aleatórios cujas funções de autocorrelação não converge MEDEIROS (2018). Ainda de acordo com os autores o método foi utilizado como alternativa a métodos tradicionais de análise de sinais como a FFT, por exemplo.

Expressando matematicamente podemos Considerando um sinal $\{X_t\}$ que representa um processo estacionário com média μ e variância σ^2 , onde a covariância $Cov(X_t, X_s)$ é em relação ao intervalo de tempo $|t - s|$. Buscando ilustrar a aplicação do método utilizando função de autocorrelação, o sinal $\{X_t\}$ foi disposto em forma de uma matriz M. Nesta, o tempo é representado por $t = 1, 2, \dots, s$, sendo s o tempo total; e $k = 1, 2, 3, \dots$. Representa a quantidade de amostras ao longo das unidades de tempo. Assim é possível verificar que a matriz M se apresenta conforme descrito na Equação (3.43).

$$M = \begin{bmatrix} X_{t,1} & X_{t,2} & \dots & X_{t,k} \\ X_{t+1,1} & X_{t+1,2} & \dots & X_{t+1,k} \\ \vdots & \vdots & \ddots & \vdots \\ X_{t+s,1} & X_{t+s,2} & \dots & X_{t+s,k} \end{bmatrix} \quad (3.43)$$

Pode-se utilizar a função de autocorrelação definida por WEI (2006) como:

$$\gamma_k = \frac{Cov(X_t, X_{t+k})}{\sqrt{Var(X_t)}\sqrt{Var(X_{t+k})}}, k = 1, 2, 3, \dots, k \quad (3.44)$$

Onde γ_k representa o coeficiente de correlação das amostras coletadas em cada unidade de tempo. Submetendo a matriz M à Equação (3.44) será obtida uma matriz denominada matriz de autocorrelação cujos elementos são coeficientes de correlação calculados.

Como primeiro passo para calcular o Coeficiente de Comprimento de Correlação (*Correlation Length Coefficient* - CLC) ainda se faz necessário calcular a Função Parcial

de autocorrelação. Para isso, é calculado \hat{X}_{t+k} como a melhor estimativa linear em termos de quadrado médio de X_{t+k} :

$$\hat{X}_{t+k} = \alpha_1 X_{t+k-1} + \alpha_2 X_{t+k-2} + \dots + \alpha_{k-1} X_{t+1} \quad (3.45)$$

Onde: α_i ($1 \leq i \leq k-1$) é o coeficiente de regressão linear médio quadrático. Então a condição de correlação $\text{Corr}(X_t, X_{t+k} | X_{t+1}, \dots, X_{t+k-1})$ é chamada de função parcial de autocorrelação, descrita como P_k , (Medeiros, 2018).

$$P_k = \begin{bmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_{k-1} \end{bmatrix} = \begin{bmatrix} 1 & \gamma_1 & \dots & \gamma_{k-2} \\ \gamma_1 & 1 & \dots & \gamma_{k-3} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{k-2} & \gamma_{k-3} & \dots & 1 \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_{k-1} \end{bmatrix} \quad (3.46)$$

O processo resulta nos coeficientes presentes em (P_k) demonstrado em forma de vetor pela representação da **Figura 3.34** para um sinal decorrente de um MIT com um segundo de aquisição.

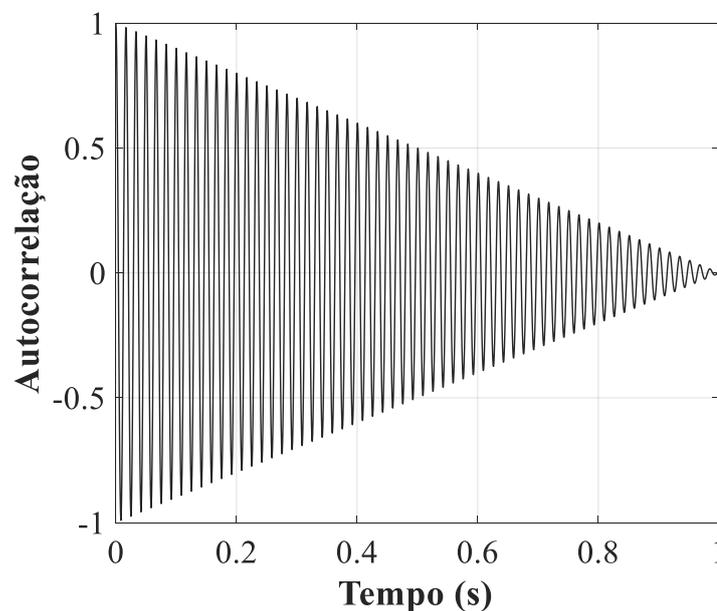


Figura 3.34-Função parcial de autocorrelação para o sinal de corrente de um MIT

Ainda segundo MEDEIROS (2018), a amplitude decrescente dos valores de autocorrelação ao longo do tempo é o que caracteriza o comportamento como caótico para um sistema periódico. De acordo com BAZEIA *et al.* (2017) de posse do resultado da

Equação (3.46) se dá a continuidade do cálculo do CCC aplicando a Distância de Hamming. Para determinar (τ) para um momento t do sistema, a distância a meia altura é calculada à partir do vetor resultante P_k . Considerando dois pontos denominados A e B, onde A = $P_k(1)$ e o ponto B tem seu valor de Y igual a $Y = 0.5$, o valor X_B ; em relação a X_A , vai determinar τ como mostra a Equação (3.47). Este valor é chamado de Coeficiente de Comprimento de Correlação na (τ) .

$$\tau = X_B - X_A \quad (3.47)$$

Na **Figura 3.35** é possível visualizar o coeficiente de comprimento de correlação $\tau \approx 49$ extraído da função parcial de autocorrelação verifica-se que no eixo Y o valor corresponde a media altura 0.5.

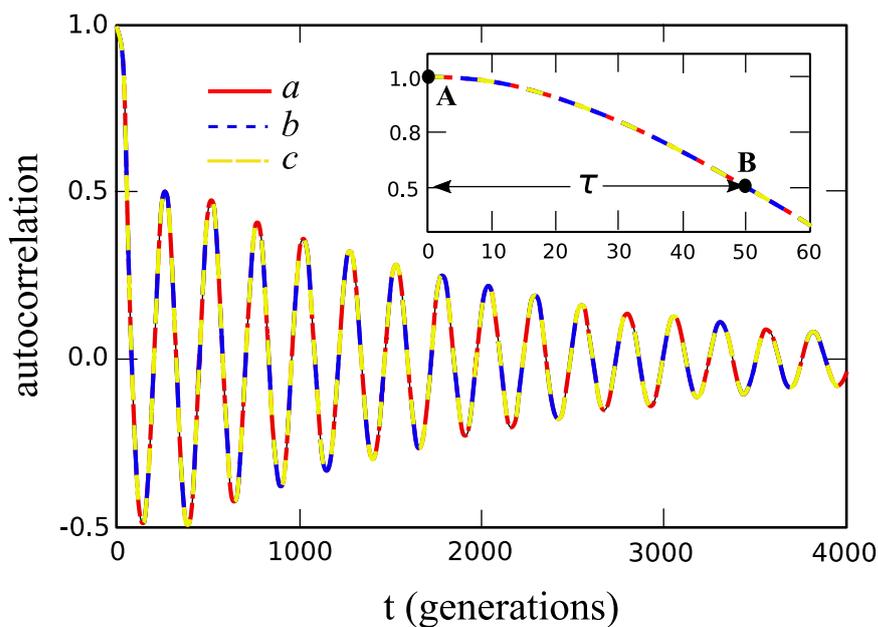


Figura 3.35-Coeficiente de comprimento de correlação (Fonte: Adaptado de (Bazeia *et al.*, 2017)).

O valor obtido de τ é utilizado como uma medida quantitativa no processo de identificação de comportamento caótico para sistemas periódicos BAZEIA *et al.*, (2017). Tal abordagem se mostrou eficaz em trabalhos desenvolvidos por (MEDEIROS, 2018; VÉRAS, 2019; DA SILVA, 2021).

3.6.4. Análise de sinal baseado no caos usando densidade de máximos

Em seu estudo sobre identificação do caos em sistemas biológicos complexos BAZEIA *et al.* (2017), conseguiu demonstrar a presença do caos através de simulações estocásticas amplamente utilizadas para estudar a biodiversidade na natureza. Como principal resultado do estudo, foi possível demonstrar como uma única e simples realização experimental que conta a densidade de máximos associados à evolução caótica da espécie serve para inferir seu comprimento de correlação. Essa abordagem foi empregada em problemas complexos distintos, tal como um conjunto de equações diferenciais, usadas para modelar a diversidade natural e artificial de sistemas caóticos, como também, na análise no nível da água do oceano.

O comportamento de equilíbrio cíclico é a questão central do presente trabalho, assim sendo, esse princípio é aplicado a fim de identificar o comportamento caótico do sinal de corrente de um motor de indução trifásico, com a finalidade de diagnosticar falhas em rolamentos, utilizando para isso uma única amostra em uma evolução temporal curta, como é assegurado pelo princípio da máxima entropia, que é o princípio da termodinâmica que mede a desordem das partículas de um sistema físico, e de extensões da teoria do caos (BAZEIA *et al.*, 2017).

Seguindo a metodologia descrita em BAZEIA *et al.* (2017) e partindo do princípio de que há uma relação de caráter quantitativo entre o comprimento de correlação e a densidade de máximos de um sinal, é possível analisar uma pequena porção do sinal de corrente, definida aqui por $q(t)$ e caracterizar seu comportamento caótico.

Analisando os dados referentes a uma pequena amostra de um sinal (corrente) $q(t)$, é possível caracterizar o comportamento caótico em um MIT (DE DEUS *et al.*, 2020). A oscilação desse sinal no tempo fornecerá um máximo local no intervalo $[t, t + \delta t]$, para um δt suficientemente pequeno, portanto, é possível denotar que, $q'_i(t) > 0$ e $q'_i(t + \delta t) < 0$ onde essas relações simbolizam a derivada primeira do sinal no tempo, tal que $-q''_i(t) \delta t > q'_i(t) > 0$. A probabilidade conjunta $P(q'_i, q''_i)$ pode ser usada para calcular a densidade de máximos média representada como $\langle \rho_i \rangle$; por meio da seguinte relação, sendo esta: a probabilidade de encontrar um máximo dentro do intervalo $[t, t + \delta t]$ é proporcional à integral que engloba a região descrita acima, de modo que Equação (3.48).

$$\begin{aligned}
\langle \rho_i \rangle &\equiv \frac{1}{\delta t} \int_{-\infty}^0 d q_i'' \int_0^{-q_i'' \delta t} d q_i' P(q_i', q_i'') \\
&= \int_{-\infty}^0 d q_i'' q_i'' P(0, q_i'')
\end{aligned} \tag{3.48}$$

O fato das propriedades estatísticas do número médio de picos ser invariantes perante as translações no tempo indica que ambos q_i' e q_i'' tem valores médios tendendo a zero. Ademais, as propriedades de $P(q_i', q_i'')$ podem ser alcançadas através do menor instante de q_i' e q_i'' , e as variâncias de $P(q_i', q_i'')$ são diretamente relacionadas a função de correlação como pode ser observado na Equação (3.49).

$$C_i(\delta t) = \langle q_i(t + \delta t) q_i(t) \rangle \tag{3.49}$$

Assim sendo, vários instantes podem ser obtidos, em particular:

$$\langle q_i'^2 \rangle = - \left. \frac{d^2 C_i(\delta t)}{d(\delta t)^2} \right|_{\delta t=0} ; \langle q_i''^2 \rangle = \left. \frac{d^4 C_i(\delta t)}{d(\delta t)^4} \right|_{\delta t=0} \tag{3.50}$$

A distribuição de probabilidade conjunta pode ser construída pelo princípio da máxima entropia, tanto para q_i , quanto para suas derivadas apresentadas nas equações anteriores. Após implementação dos cálculos algébricos, a integração em $q(t)$ leva a $P(q_i', q_i'')$ que resulta na Equação (3.51).

$$P(0, q_i'') = \frac{1}{2\pi} \frac{1}{\sqrt{\langle q_i'^2 \rangle \langle q_i''^2 \rangle}} \exp\left(-\frac{1}{2} \frac{q_i''^2}{\langle q_i''^2 \rangle}\right) \tag{3.51}$$

As expressões definidas acima podem ser utilizadas para escrever a densidade dos máximos em termos da função de autocorrelação. A Equação (3.52) é aplicada à análise de amostras de sinais não periódicas, em que $\langle \rho_i \rangle$ é teórico e C_i é calculado através das derivadas segunda e quarta (Equação (3.50)) da função de autocorrelação em zero, representadas respectivamente neste trabalho por $\frac{d^2 C_i}{dt^2}(0)$ e $\frac{d^4 C_i}{dt^4}(0)$, conforme apresentado

em BAZEIA *et al.* (2017), MEDEIROS *et al.* (2018), VERAS (2019) e DE DEUS *et al.* (2020).

$$\langle \rho_i \rangle = \frac{1}{2\pi} \sqrt{\frac{\langle q_i''^2 \rangle}{\langle q_i'^2 \rangle}} = \frac{1}{2\pi} \sqrt{\frac{\frac{d^4 C_i}{dt^4}(0)}{-\frac{d^2 C_i}{dt^2}(0)}} \quad (3.52)$$

Em sua pesquisa, DE DEUS (2020) através da concordância entre os valores ρ_i , denominado teórico, com valores calculados pela densidade de máximos de uma amostra do sinal de corrente do MIT conseguiu caracterizar o comportamento do sinal da corrente elétrica do motor de indução como sendo caótico.

BAZEIA *et al.* (2017) implementou, a fim de verificar sua validade, um procedimento para criar um conjunto de eventos para obter a função de correlação, esta por sua vez, é utilizada para calcular o coeficiente do comprimento de correlação. Ainda segundo Bazeia, o coeficiente τ é extraído da função de autocorrelação como sendo a largura a meia altura, então usando a função de ajuste, $C(t) = \cos(kt)$, sendo $k\tau = \pi/3$, logo, através da Equação (3.52), chega-se a Equação (3.53).

$$\langle \rho \rangle = \frac{k}{2\pi} \quad (3.53)$$

A variável k representa a função quadrada da Equação (3.52). Após a reorganização algébrica dos termos na Equação (3.53), com a inclusão da relação $k\tau = \pi/3$, é possível chegar a Equação (3.54), de tal forma que é possível perceber a relação entre τ que é o (coeficiente de comprimento de autocorrelação) e o ρ que é o coeficiente que representa a densidade dos máximos, sendo um valor obtido de forma experimental.

$$\tau = \frac{1}{6\langle \rho \rangle} \quad (3.54)$$

Através da análise do sinal em um intervalo curto de tempo, pode-se estimar o coeficiente de autocorrelação, baseado na média da densidade de máximos adquirida a partir do sinal de corrente aquisitionado (LUCENA-JUNIOR *et al.*, 2020; DE DEUS *et al.*, 2020). Assim sendo, o SAC-DM (*Signal Analysis based on Chaos Using Density of*

Maxima), pode ser caracterizado como sendo a relação entre a quantidade total de picos contido em um intervalo dividido pelo tempo do intervalo em análise, como pode ser observado na Equação (3.55). Para fins de melhor compreensão, será adotado o termo SAC-DM, para designar o valor ρ experimental.

$$SAC - DM = \frac{\text{Total de picos no intervalo}}{\text{tempo do intervalo}} = \frac{\sum \text{picos}}{\Delta t} \quad (3.55)$$

Observando a **Figura 3.36** é possível visualizar a curva de evolução de uma função $x(t)$ para um sistema determinístico modelado por equações diferenciais de primeira ordem e ao lado direito sua função de autocorrelação (BAZEIA *et al.*, 2017).

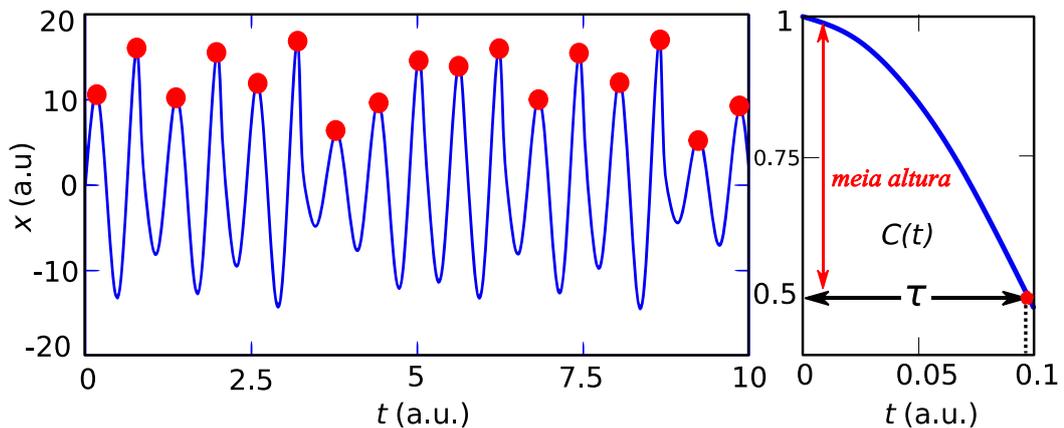


Figura 3.36-Curva de uma função $x(t)$ de um sistema modelado por equações diferenciais de primeira ordem e a direita sua função de autocorrelação. (Fonte: Adaptado de (BAZEIA *et al.*, 2017)).

O SAC-DM pode ser calculado através do valor da soma de todos os picos no intervalo entre 0-10, dividido por este mesmo intervalo:

$$SAC - DM = \frac{\sum \text{picos}}{\Delta t} = \frac{17}{10} = 1.7$$

Aplicando a Equação (3.54), é possível encontrar o valor teórico do coeficiente de comprimento de autocorrelação (τ), segue-se por:

$$\tau = \frac{1}{6\langle\rho\rangle} = \frac{1}{6 * 1.7} = 0.098$$

Observando o gráfico à direita da **Figura 3.36**, é possível perceber que o valor de τ vale aproximadamente 0.098 no eixo x, ao interceptar a curva da função de autocorrelação verifica-se a concordância com o valor de meia altura equivalente a 0.5 no eixo y.

A técnica desenvolvida por BAZEIA *et al.* (2017) é de uso muito prático, pois permite inferir o comprimento de correlação com uma única e simples avaliação à evolução temporal da variável caótica em consideração, seja ela de origem natural ou artificial, portanto é de ampla aplicabilidade.

No presente trabalho será abordado um caso prático da aplicação do SAC-DM para diagnosticar falhas mecânicas em um MIT utilizando a análise do sinal da corrente de armadura do motor. A falha em específico trata-se de defeitos em rolamentos. Um dos aspectos relevantes do SAC-DM é a possibilidade de trabalhar no domínio do tempo ao contrário da grande maioria das técnicas de diagnóstico de falhas atuais que trabalham com à análise do sinal no domínio da frequência.

CAPITULO IV

4. MATERIAIS E MÉTODOS

Neste capítulo será abordada a metodologia empregada na coleta dos dados bem como a descrição dos principais instrumentos utilizados na aquisição dos sinais. A bancada de torque controlável utilizada neste trabalho de tese é modular, o que permite a aplicação de uma ampla faixa de torques e velocidades. O torque aplicado ao eixo do MIT é controlado através da variação da corrente de armadura do gerador CC. O motor de indução trifásico pode ser acionado por partida direta ou pelo inversor de frequência, este último possibilita um maior controle da velocidade do eixo do motor. Tais características permitem simular uma ampla configuração de falhas no motor de indução em análise, desde falhas elétricas, mecânicas ou ambas (em simultâneo). A instrumentação da bancada é composta por uma série de ferramentas, como sensores e conversores, e cada item será abordado ao decorrer deste capítulo. Tais ferramentas são indispensáveis à aquisição dos sinais de vibração (mecânica e sonora), sinais elétricos (tensão e corrente), velocidade e torque. Os dados coletados são submetidos às técnicas e métodos descritos no Capítulo 3 e 4, a fim de validar os resultados que são apresentados no capítulo 5.

4.1. BANCADA DE TORQUE CONTROLÁVEL

A bancada de torque controlável utilizada neste trabalho foi desenvolvida pelo Grupo de Pesquisa em Instrumentação e Controle em Estudo de Energia e Meio Ambiente (GPICEEMA) da Universidade Federal da Paraíba (UFPB). A bancada é modular o que permite uma troca rápida de componentes e a adição de acessórios como sensores e outros instrumentos. O motor de indução trifásico em análise pode ser acionado de duas formas, por partida direta ou através do uso do inversor de frequência, este último permite o

controle da velocidade através da modulação da frequência, possibilitando testes para diversos valores de velocidade.

O torque aplicado no eixo do MIT é proveniente da resistência ao movimento rotacional provocado pelo gerador CC que funciona como uma espécie de freio eletromagnético, mais detalhes serão abordados no item 4.1.2 que trata do gerador CC e seu acionamento. Valores diversos de carga dinâmica podem ser imposta ao motor em análise, podendo variar desde torques próximo a zero até torques superiores ao valor nominal, especificados de acordo com a placa de identificação do motor.

A representação global da bancada de torque controlável pode ser observada na **Figura 4.1**, onde são representados seus diversos equipamentos, desde a parte de instrumentação (sistemas de aquisição e sensores) até a parte de acionamento do motor de indução trifásico (painel de controle) e do gerador CC (variador de tensão e filtros).

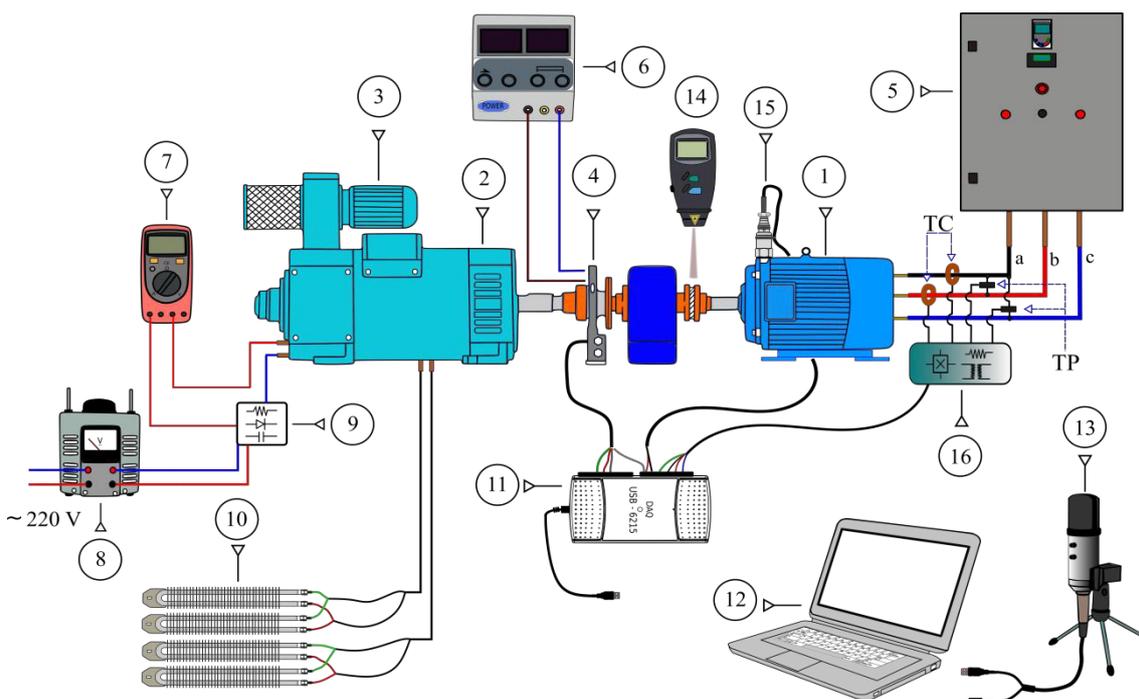


Figura 4.1- Representação da bancada de torque controlável e seus acessórios.

- | | |
|-------------------------|---------------------------------------|
| 1- MIT | 9 - Ponte retificadora |
| 2- Motor CC | 10- Resistências elétricas |
| 3- Exaustor gerador CC | 11- Dispositivo de aquisição de dados |
| 4- Torquímetro | 12- Notebook |
| 5- Quadro de comando | 13- Microfone |
| 6- Fonte de alimentação | 14- Tacômetro óptico |
| 7- Multímetro | 15- Acelerômetro |
| 8- Regulador de tensão | 16- Sensores de tensão e corrente |

A bancada pode ser dividida em algumas partes, sendo as principais: motor de indução trifásico e seu acionamento, gerador de carga e seu acionamento e os sistemas de instrumentação (aquisição e sensores). A simulação das falhas ocorrerá no rolamento dianteiro do MIT, justamente por ser o que sofre maior carregamento, além do fato de ter uma melhor localização para posicionamento dos sensores. As condições de falhas simuladas foram realizadas utilizando partida direta, tendo como parâmetro o torque aplicado ao eixo do motor.

A **Figura 4.2** representa os principais componentes que compõem a bancada. Pode-se destacar: (1) motor de indução trifásico, objeto de estudo do trabalho; (2) mancal para apoio com dois rolamentos e elementos de acoplamento; (3) transdutor de torque; (4) motor de corrente contínua com exaustor acoplado; (5) transdutor de velocidade; (6) variador de tensão responsável pelo controle do torque. Cada elemento será melhor detalhando ao decorrer deste capítulo.

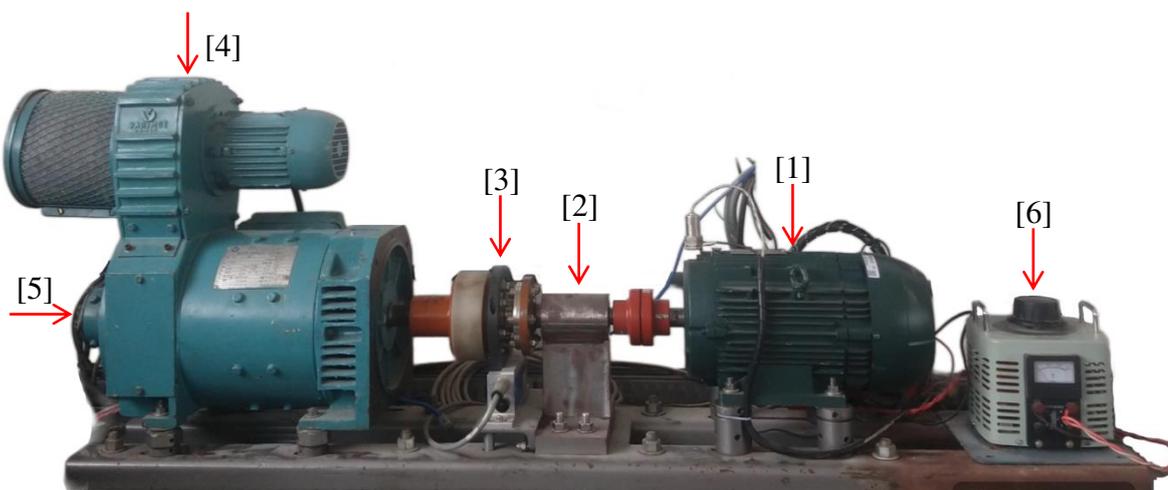


Figura 4.2- Bancada de torque controlável e seus principais componentes

Abancada pode ser utilizada para realizar diversos experimentos, seja análise de falhas, levantamento de parâmetros elétricos ou mecânicos do MIT, caracterização da eficiência energética, dentre outros. O motor de indução trifásico foi projetado para atuar sob carga, sendo a carga ideal próxima ao seu valor nominal especificado em catálogo ou na placa de identificação que vem fixado na carcaça do mesmo. Estima-se que aproximadamente 40% dos motores operam abaixo de 50% da sua capacidade nominal e por isso o projeto e a seleção destes equipamentos deve ser muito criteriosa e assertiva (Weg, 2023).

Na bancada, o responsável por simular a carga imposta ao motor de indução trifásico é o motor CC, ele atua como um freio eletromagnético, aplicando força contrária ao movimento de rotação do MIT. O efeito de frenagem eletromagnética dar-se através da aplicação de corrente contínua no seu estator. O acionamento do motor CC ocorre de forma controlada, o processo conta com um regulador de tensão AC e um conversor que converte a tensão alternada para tensão contínua. Ao variar a tensão no estator do gerador cc é possível aumentar ou diminuir o torque no eixo do MIT.

O torque no MIT não deve ultrapassar muito o valor nominal, o que pode danificar eixos e mancais, além de prejudicar a própria integridade do motor. Para fins de limitação e para preservar a integridade dos componentes da bancada, o monitoramento da corrente é realizado durante todo o período de coleta dos dados. O monitoramento da corrente é feito através de um multímetro que está ligado a um dos terminais de saída da ponte retificadora, o valor de corrente não deve ultrapassar o valor de 1A.

4.1.1. Acionamento do motor de indução

O motor de indução trifásico utilizado nos experimentos foi um motor Hercules do tipo IR3 e carcaça IEC100. O motor opera com uma frequência de alimentação de 60 Hz, possui uma potência nominal de 3 kW – (3,7 hp/ 5 cv), possui um fator de serviço de 1,25, com um rendimento nominal de 89.5 %, a tensão de alimentação pode ser de 380 Vca em configuração Y ou 480 Vca em configuração Δ . O motor possui 4 polos e sua velocidade síncrona é próxima de 1800 rpm. Sob condições nominais a rotação do motor é de 1750 rpm conforme dados do fabricante. O rolamento dianteiro é o modelo 6206-ZZ e o traseiro 6205-ZZ, nos experimentos de análise de falha foi utilizado o rolamento dianteiro. O motor pode ser acionado de duas formas: através do inversor de frequência (o que garante uma ampla faixa de velocidades) ou pela partida direta.

A carcaça do tipo IEC100 do MIT não possui pontos para fixação de acelerômetros, o que inicialmente se tornou um problema. Uma alternativa seria perfurar a tampa da carcaça para fabricação de uma rosca, entretanto poderia danificar a integridade física do motor. Para contornar este problema foi projetada uma peça de adaptação. Na **Figura 4.3 a)** é possível visualizar o modelo do motor empregado na bancada e em **b)** a adaptação feita para fixação do acelerômetro.

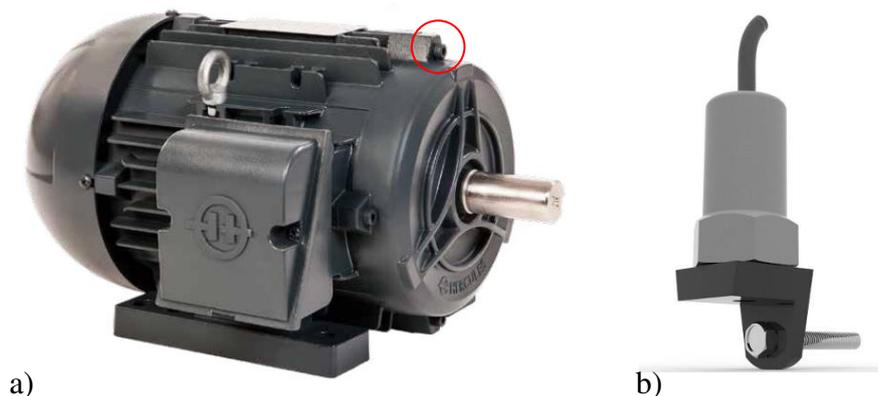


Figura 4.3- a) Motor de indução trifásico HERCULES IEC100 IR3 de 5 cv e 4 pólos b) adaptador utilizado para fixar o acelerômetro.

O inversor de frequência utilizado na bancada é o modelo CWF 700 da WEG, podendo ser utilizado para controlar a velocidade em motores de até 30 cv envolvendo correntes próximas a 80 A, sendo possível também fazer o controle da velocidade usando o controle escalar ou o controle vetorial que pode ser programado como sensorless (sem necessidade de encoder). A **Figura 4.4** mostra a representação do modelo do inversor de frequência que é utilizado na bancada de torque controlável.



Figura 4.4- Modelo do Inversor de frequência, WEG CFW 700 utilizado na bancada.

O quadro de comandos da bancada é responsável por alocar parte dos sensores, principalmente os sensores de tensão e corrente, e parte do sistema de aquisição. É composto ainda pela parte de controle e de potência responsável por acionar o MIT, conta também com um contactor responsável pelo acionamento do exaustor do motor CC.

Uma adaptação foi realizada para que a Interface Humano Máquina (IHM) ficasse na parte externa do painel, visando dar mais agilidade na hora da partida do MIT, bem como facilitar a inserção de parâmetros. A parte externa do quadro de comandos é composta por: [1] IHM, [2] por um mostrador display do voltímetro, [3] uma botoeira para desligar o sistema em caso de irregularidades, [4] um sinalizador luminoso para indicar partida direta, [5] um sinalizador luminoso para indicar partida pelo inversor, [6] e a chave seletora para escolher entre partida direta e partida pelo inversor. Na parte interna do quadro de comandos o sistema consta com canaletas para passagem dos fios de potência e controle [7], contactores, disjuntores e sistemas de proteção para acionamento do circuito elétrico [8], placa de aquisição de dados DAQ USB-6215 [9], inversor de frequência [10], sensores de tensão e corrente para medição da potência de entrada [11]. Na **Figura 4.5** é representado o quadro de comandos e seus principais componentes.

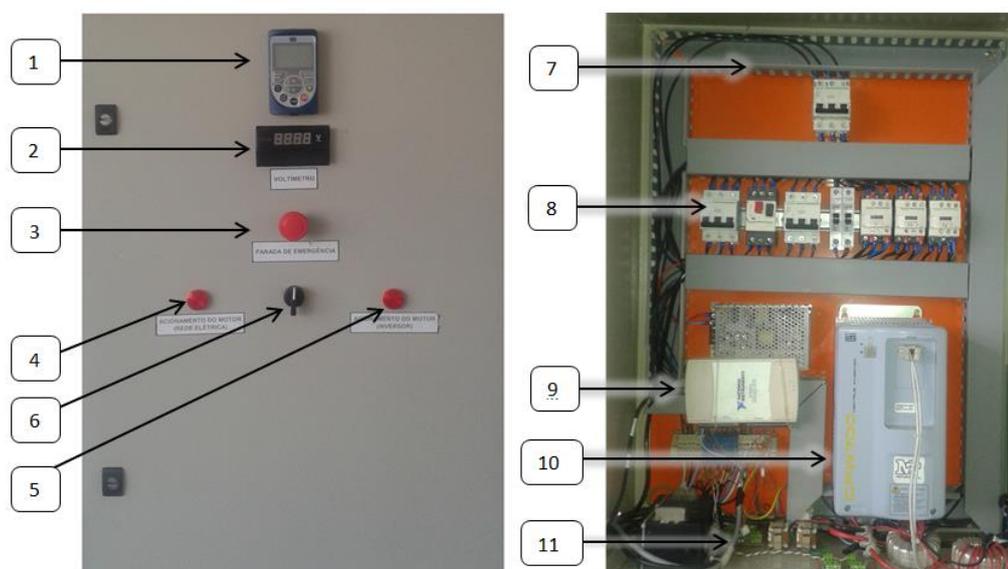


Figura 4.5-Quadro de comando da bancada de torque controlável, a esquerda parte externa e a direita a parte interna.

4.1.2. Motor CC e seu acionamento

O motor elétrico de corrente contínua pode operar em dois estágios, como motor ou como gerador. Como motor gera energia mecânica a partir da energia elétrica, já como gerador faz o processo contrário gerando energia elétrica através da energia mecânica por meio de movimento rotacional. O motor CC utilizado na bancada é do fabricante VARIMOT tipo de carcaça 132 classe S, possui uma potência de 7,5 CV e velocidade de

1800 rpm. Neste trabalho o motor CC foi utilizado para operar como aplicador de carga por frenagem eletromagnética. Durante este processo ocorre aquecimento do estator, ocasionando aquecimento dos componentes internos. Para ajudar na dissipação da energia térmica gerada é utilizado um motor de indução, que funciona como ventilação forçada, soprando ar para dentro do motor CC, vide **Figura 4.6**.

A frenagem eletromagnética que provoca o torque é controlada através da tensão de armadura aplicada, o controle da tensão de armadura é feito através de um regulador de tensão e um circuito retificador que serão abordados mais adiante.

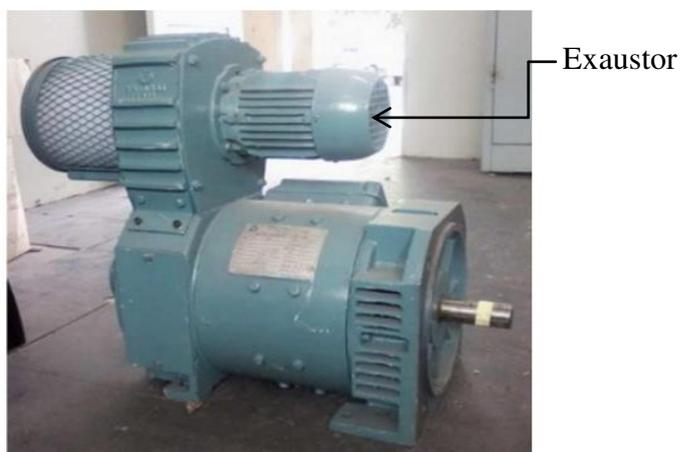


Figura 4.6- motor de corrente contínua VARIMOT 132S (Fonte:(LYRA, 2014))

4.1.3. Circuito Elétrico de Frenagem Eletromagnética do Motor CC

Este sistema é constituído, basicamente por três elementos **Figura 4.7**, sendo eles: regulador de tensão conhecido também como variac, retificador de tensão e multímetro. O regulador de tensão está conectado na rede elétrica monofásica de 220 V corrente alternada, pode ser compreendido como uma espécie de autotransformador, neste caso monofásico. A saída do regulador pode receber níveis de tensão ajustável, este ajuste ocorre de modo manual, ao girar uma espécie de *knob*, neste processo ocorre a variação do número de bobinas do enrolamento secundário. O autotransformador, diferentemente dos transformadores convencionais, possui apenas um enrolamento (ADISSI, 2015).

O modelo utilizado na bancada de torque controlável é do tipo monofásico da fabricante JNG cujo modelo é o TDGC2-2, possui alimentação de 220V/ (50 ou 60 Hz), já a saída pode variar entre 0 e 250 V, a potência é de 2 kVA e corrente máxima de 8 A. Ao

ajustar o regulador de tensão, de modo que a corrente flua através do secundário ocorre a excitação do campo do motor CC, deste modo, é possível obter uma ampla faixa de torque sobre o eixo do motor de indução trifásico.



Figura 4.7-Sistema de acionamento do motor CC: [1] regulador de tensão; [2] ponte retificadora; [3] multímetro.

Arelado à saída do regulador de tensão é conectada uma ponte retificadora, com a finalidade de converter a corrente alternada (CA) em corrente contínua (CC), para que o motor CC funcione de acordo com suas especificações. A ponte retificadora consiste de uma ponte de diodos com filtro capacitivo. A excitação do campo do motor CC feita após a retificação permite imprimir e controlar a carga imposta ao eixo do MIT. É importante salientar que a corrente de campo do motor CC não deve ultrapassar em demasia o valor nominal de 1A. Para realizar este monitoramento utiliza-se um multímetro da marca ICEL referência MD-1700, devidamente ajustado para função de amperímetro. Na **Figura 4.8** é possível visualizar o esquema elétrico do sistema de acionamento do motor cc.

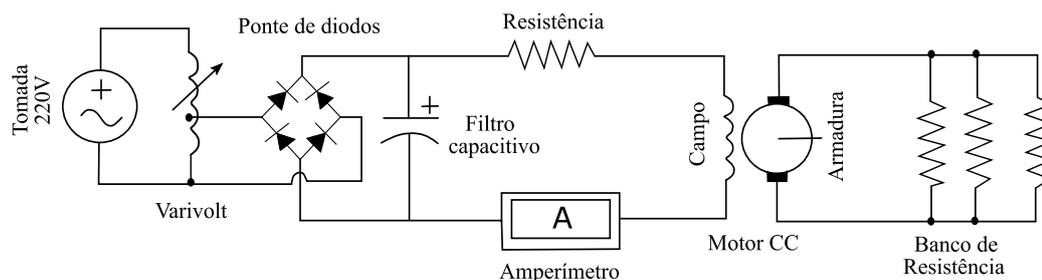


Figura 4.8-circuito elétrico de acionamento do motor cc (Fonte: (ADISSI, 2015))

Quando um motor de corrente contínua recebe movimento rotacional no seu eixo, passa a se comportar como gerador, convertendo a energia mecânica proveniente de força mecânica externa em energia elétrica. Embora o motor CC da bancada atue como freio eletromagnético aplicando carga ao eixo do MIT o movimento rotacional (proveniente do MIT) acaba provocando interações eletromagnéticas entre o estator e o rotor, e conseqüentemente acaba ocorrendo à geração de energia elétrica. Parte da energia elétrica gerada durante os testes é dissipada pelo conjunto de resistências, como pode ser observado na **Figura 4.9**. Ao todo são quatro resistores de $24\ \Omega$ e potência de 2000 W, ligados em paralelo à armadura do motor CC. Durante um período prolongado de testes com torque próximo do valor nominal o conjunto de resistores superaquece devido o efeito Joule. Para evitar danos e o derretimento de materiais plásticos (cabos condutores) que possam estar por perto, utiliza-se um exaustor como fonte de resfriamento.



Figura 4.9- Resistores elétricos de $24\ \Omega$ e 2000 W aletados conectados à armadura (Fonte: (ADISSI, 2015)).

4.1.4. Sistemas de medição

Os sensores para a aquisição dos sinais elétricos de tensão e de corrente foram escolhidos com base na sua confiabilidade, custo e simplicidade na instalação. O sensor de corrente escolhido foi o ACS712, é um sensor de efeito Hall fabricado pela Allegro, e pode ser empregado na medição de corrente contínua e alternada de até 30A com altas frequências, a desvantagem é que um sensor do tipo invasivo. Outro sensor de corrente, do tipo não invasivo foi testado, o modelo é o CST-013 de 30A. Para os sensores de tensão, foram utilizados dois transformadores de potência da marca Tecnotrafo, com relação de transformação de 380 Vrms no primário para 3 Vrms no secundário. Os três tipos de sensores são ilustrados na **Figura 4.10**, abaixo.



a) ACS712

b) CST-013

c) TP

Figura 4.10-Sensores de corrente e tensão, a) Sensor de corrente por efeito Hall, b) Sensor de corrente não invasivo, c) Transformador de potência

O transdutor de torque utilizado é o modelo HBM T40B da fabricante HBM possui precisão de 0,1 N.m em fundo de escala, com capacidade de operar em torque nominal de até ± 200 N.m e rotações de até 20.000 rpm.

O torquímetro **Figura 4.11** possui dois canais de saídas, um deles com sinal na forma analógica apresentando um sinal modulado em tensão, numa faixa de ± 10 V variando linearmente, diretamente proporcional ao torque e sentidos de aplicação do torque indicados pelo sinal – ou + que depende do sentido de rotação do motor. A outra saída possui um sinal de torque modulado em frequência, onde a frequência varia também diretamente proporcional ao torque aplicado, na faixa de 30 kHz a 90 kHz, sendo o valor de 60 kHz equivalente à condição de ausência de torque ou torque zero, ou seja, para valores inferiores a 60 kHz o torque aplicado está num sentido enquanto para valores maiores de 60 kHz o sentido de aplicação do torque é oposto. Devido a maior precisão comprovada pelo fabricante foi utilizada na aquisição de dados a modulação por frequência.

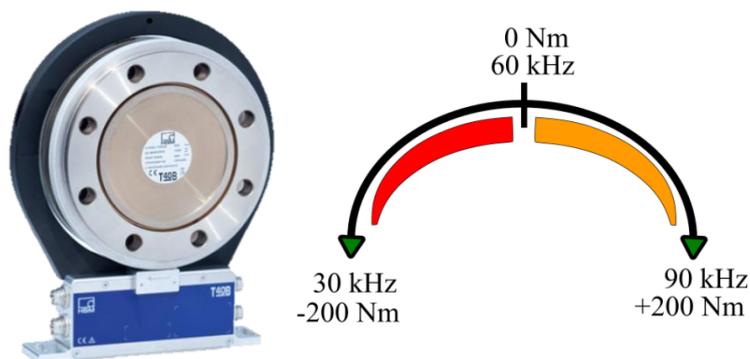


Figura 4.11- Torquímetro HBM-T40B-200 a esquerda; escala no modo de frequência a direita.

A velocidade de rotação no eixo do MIT foi medida utilizando um tacômetro óptico da Minipa modelo MDT-2238B e pode ser operado de duas maneiras: por contato e por foto detecção (usando laser). Por ser mais prático optou-se por utilizar o modo óptico, neste modo é possível medir numa faixa entre 2,5 a 100000 rpm, com uma distância de detecção entre 50 a 500 mm, possui uma resolução de 1 rpm (acima de 1000 rpm no modo óptico) e uma precisão de (0,05% Leitura + 1 Dígito) a alimentação do equipamento é feita através de 4 baterias AA com tensão de 1,5 V.



Figura 4.12-Tacômetro digital modelo MDT-2238B e seu modo de operação a direta.

Os sinais de vibração foram captados por meio do acelerômetro industrial modelo HS-1001000202 da fabricante *Hansford Sensors*. Possui uma sensibilidade de $100 \text{ mV/g} \pm 10\%$ e resposta em frequência de $2 \text{ Hz a } 10 \text{ kHz} \pm 5\%$. Na **Figura 4.13** (a) está ilustrado o acelerômetro utilizado; (b) O esquemático elétrico do circuito de acionamento do acelerômetro e (c) a montagem da placa eletrônica de acionamento.

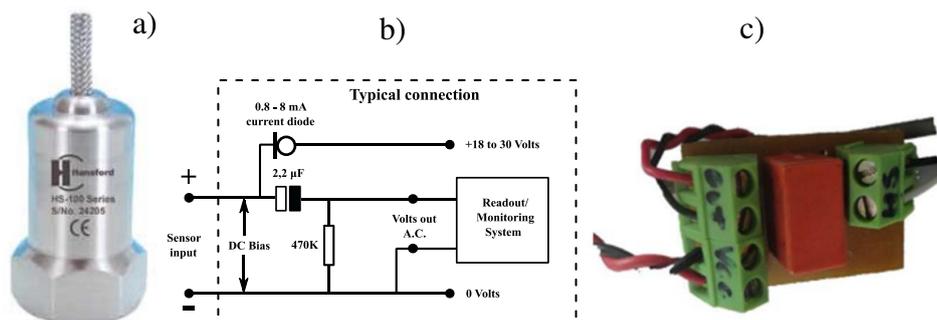


Figura 4.13-a) Acelerômetro; b) Circuito elétrico de acionamento do acelerômetro; b) Placa eletrônica de acionamento do acelerômetro.

O sensor de vibração utilizado foi escolhido por ser de fácil operação, ter boa sensibilidade e uma boa resposta em frequência. A curva característica da resposta em frequência apresenta uma boa faixa de estabilidade como pode ser observado na **Figura 4.14**.

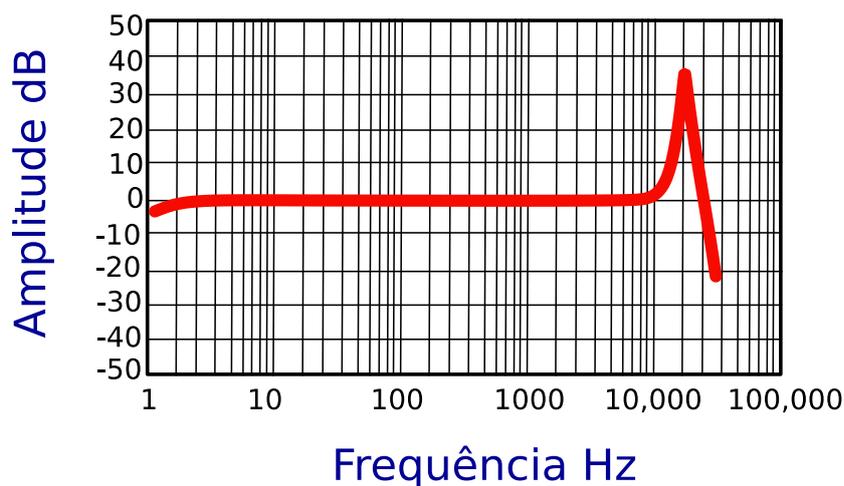


Figura 4.14-Resposta de frequência acelerômetro HS-1001000202

Os sinais de vibração sonora foram captados por meio de um microfone modelo BM100FX GT648 da fabricante Lorben, **Figura 4.15**. É do tipo condensador e possui uma resposta de frequência que varia entre 20 Hz a 20 kHz, com nível de pressão sonora de 120 dB S.P.L e sensibilidade de 25 mV/Pa. A sua escolha foi motivada pela boa resposta de frequência, custo benefício e por ter uma alimentação externa via USB, o que torna o conector do tipo P2 menos suscetível a ruídos durante a aquisição do sinal.



Figura 4.15- Microfone utilizado na aquisição do sinal de áudio.

O dispositivo de aquisição de dados (DAQ) utilizado é o NI USB-6215 **Figura 4.16** da *National Instruments*, possui 16 bits de resolução e uma taxa máxima de 250.000 amostras por segundo. O DAQ foi utilizado para obtenção de sinais do sistema elétrico (tensão e corrente) e mecânico (aceleração, áudio e torque). Como interface de aquisição utilizou-se o *software* Labview também da *National Instruments*. Todos os dados coletados foram salvos em planilhas, fundamentalmente em arquivos com extensão .lvm e .wav. Tais extensões permite que os dados sejam acessados facilmente por softwares como excel, Matlab, Minitab, dentre outros softwares voltado para análise de dados e processamento digital de sinais.



Figura 4.16-Dispositivo de aquisição de dados NI USB- 6215.

4.2. PREPARAÇÃO DAS FALHAS SIMULADAS NO ROLAMENTO

O motor de indução trifásico possui dois pontos de apoio, um rolamento traseiro e outro dianteiro. Esses rolamentos desempenham um papel fundamental ao garantir a distância correta entre o estator e o rotor, mantendo assim um entreferro ajustado. Além disso, eles ajudam a reduzir o atrito durante o movimento rotacional do motor quando é acionado, permitindo que o rotor gire livremente.

As falhas simuladas neste trabalho foram feitas no rolamento dianteiro do MIT, devido a facilidade de acesso no momento de desmontar e montar o motor para efetuar a troca do rolamento. Outra característica é que, na parte dianteira do MIT é o melhor local para posicionar o acelerômetro e outros instrumentos de medição, além de ser o ponto de apoio que o rolamento está submetido a mais esforços.

O rolamento recomendado pela placa de identificação do MIT é o modelo 6206-ZZ da fabricante SKF, trata-se de um rolamento rígido de esferas com dupla blindagem. As características geométricas do rolamento foram obtidas através do site do fabricante que disponibiliza manuais e modelos CAD. Na Tabela 4.1 é possível visualizar as principais variáveis utilizadas para o cálculo das frequências de falhas, estas, no que lhe concerne, foram apresentadas no item 2.3.

Tabela 4.1-Principais dados da geometria do rolamento referência 6206-ZZ

Variáveis	Valor	Unidade
d	9,525	mm
D	46,00	mm
n	9	Nº de elementos rolantes
θ	0°	graus

Na **Figura 4.17** é ilustrado o rolamento e as principais variáveis envolvidas no computo para encontrar as frequências características de falha.

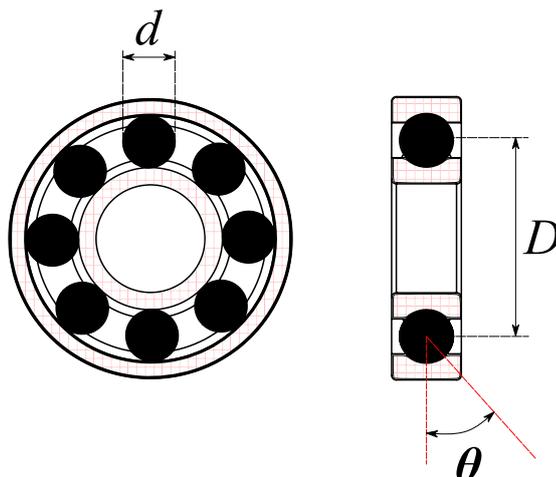


Figura 4.17-Representação de um rolamento de esferas e as dimensões utilizadas para o cálculo das frequências de falha.

O modelo de rolamento utilizado tem dupla blindagem, uma das etapas iniciais foi a remoção dessas blindagens de modo a melhorar o acesso as pistas externa e interna do rolamento. Buscando maior precisão e controle no processo de fabricação das amostras, optou-se por simular as falhas através da remoção de material por eletroerosão. Neste processo foram utilizados 3 diâmetros distintos de eletrodo capilar, um com 0,5 mm, outro com 1 mm e outro com 1,5 mm. Na **Figura 4.18** é possível visualizar o processo de fabricação de uma das falhas. A máquina utilizada foi uma *ELETROCUT NOVICK*, modelo AD200, com posicionamento programável em coordenadas XYZ, diâmetro do eletrodo variando entre $\emptyset 0,3$ e $\emptyset 3$ mm com o dielétrico a água.



Figura 4.18- Processo de fabricação de uma falha simulada usando eletroerosão.

Para melhorar a precisão dos furos e permitir um maior controle sobre o processo, foi projetada uma peça mecânica que tem por objetivo auxiliar a inserção do eletrodo no local da falha desejado. Após a modelagem e verificação dos ângulos corretos que o eletrodo iria percorrer a peça foi impressa em 3D, **Figura 4.19**, e utilizada posteriormente como guia para realizar a simulação das falhas nos rolamentos através do processo de eletroerosão.

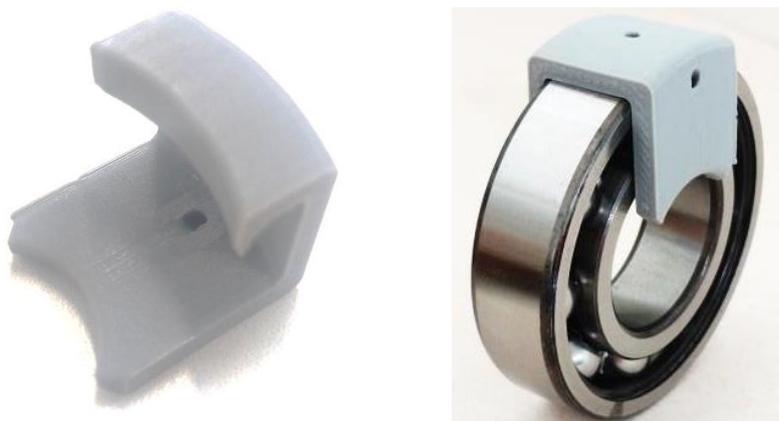


Figura 4.19- Peça guia impressa em material ABS projetada para auxiliar na simulação de falhas em rolamentos pelo processo de eletroerosão.

As falhas simuladas nos rolamentos foram do tipo localizada. Foram simuladas falhas na pista externa, pista interna e falha mista. Na falha mista danos foram feitos tanto na pista interna quanto na pista externa. Duas posições para efetuar as falhas foram utilizadas, sendo elas: *posição Vertical* e *posição Diagonal*. A posição Vertical foi utilizada para gerar falhas na pista externa, de modo que o eletrodo é inserido na posição Vertical e retira material do anel externo até atingir a pista externa do rolamento. Não foi possível utilizar a posição Vertical para gerar falhas na pista interna, devido a dificuldade de inserir o eletrodo de forma controlada em razão do pouco espaço disponível. A posição Diagonal foi utilizada para gerar falhas na pista interna e externa, nesta posição foi possível ter mais controle sobre o processo, sendo necessários apenas alguns toques do eletrodo na pista para efetuar a falha. Na **Figura 4.20**, é possível visualizar a posição que o eletrodo é inserido na região de interesse para gerar a falha, auxiliado pela peça guia impressa em 3D.

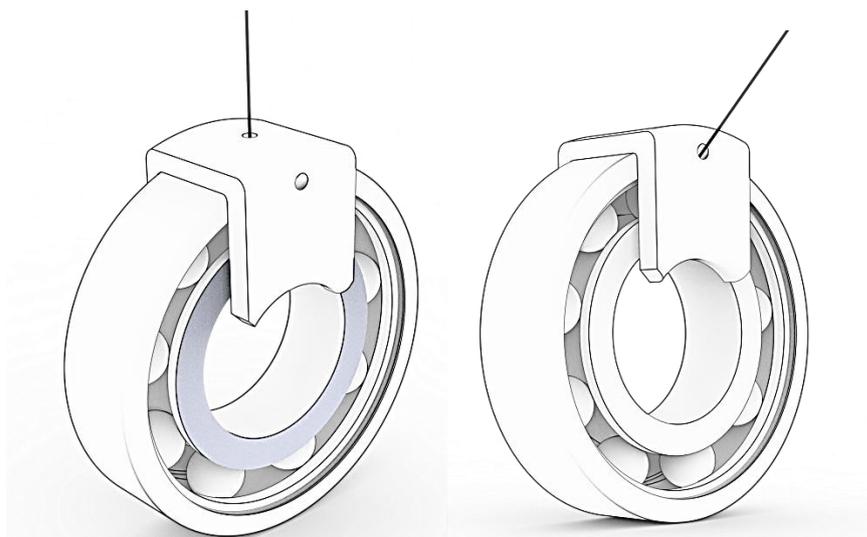


Figura 4.20-Posicionamentos dos eletrodos utilizados para gerar as falhas nos rolamentos.

O diâmetro do eletrodo usado na fabricação das falhas simuladas no rolamento, pode ser utilizado também como indicativo do grau de severidade da falha, para um grau de severidade menor um eletrodo com diâmetro menor pode ser utilizado, já para indicar um grau de severidade maior um eletrodo de maior diâmetro deve ser utilizado. Neste trabalho utilizou-se o menor diâmetro possível, sendo esse de 0,5 mm, tanto para simular as falhas na pista externa quanto para simular as falhas na pista interna, ambas as falhas foram fabricadas utilizando a posição diagonal. Já para a falha mista utilizou-se um furo na pista interna de 0,5 mm feito na posição diagonal e um furo de 1 mm feito na posição vertical. Outro caso também foi analisado, sendo este, referente a uma falha na pista externa com um furo de 0,5 mm feito na posição vertical.

Na **Figura 4.21** é possível visualizar a falha na pista externa (BPFO) simulada com um eletrodo de 0.5 mm que foi inserido na posição diagonal.

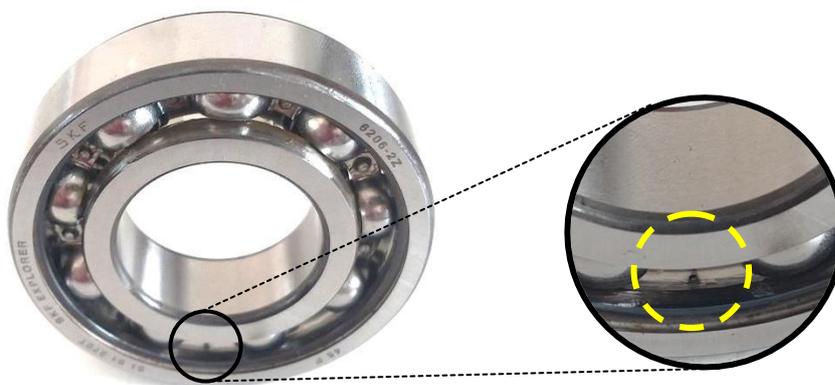


Figura 4.21- Falha BPFO 0,5 mm

A falha na pista interna foi feita também com eletrodo de 0,5 mm inserido na posição diagonal. O rolamento com falha pode ser observado na **Figura 4.22**, abaixo.

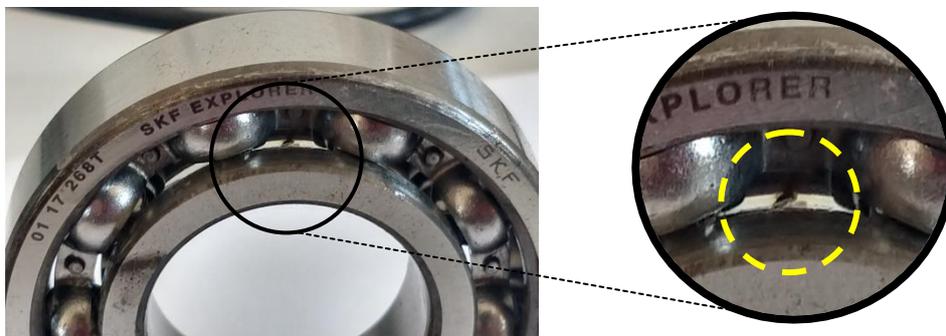


Figura 4.22- Falha BPF 0,5 mm

Podem ocorrer mais de uma falha em um rolamento em simultâneo, devido a fatores como: fadiga, lubrificação ineficiente, contaminação, sobrecarga, etc. Deste modo, optou-se por simular uma falha mista onde danos na pista interna e externa foram feitos. Na Figura 4.23, item 3, observam-se os danos simulados na pista interna e externa. O eletrodo utilizado na pista interna foi o de 0,5 mm inserido na posição diagonal, já para a falha na pista externa foi utilizado um eletrodo de 1 mm inserido na posição vertical. Observa-se também dois outros rolamentos com falha na pista externa feitas com o eletrodo de 0,5 mm, item 1, e 1,5 mm, item 2, ambas as falhas foram feitas com o eletrodo inserido na posição vertical.

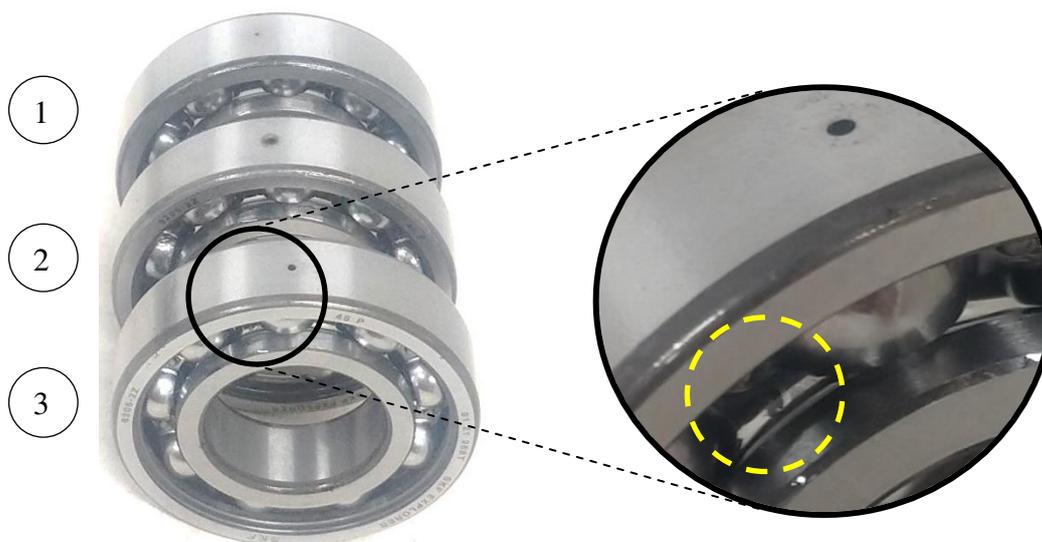


Figura 4.23-Falha mista com BPF 0,5 mm e BPF 1mm.

4.3. Banco de dados

Após a criação de falhas simuladas nos rolamentos, através do processo de eletroerosão, foi traçada uma metodologia para a aquisição dos sinais. O objetivo foi criar um banco de dados que pudesse ser utilizado nesta pesquisa bem como em outros trabalhos, além de ser acessível a comunidade científica. Os sinais de interesse, aquiritados foram: Sinais elétricos do motor de indução trifásico (tensão e corrente), sinais de vibração (mecânica e sonora) e imagens térmicas do motor, gravadas em formato de vídeo. A sequência da coleta de dados seguiu os itens da

Tabela 4.2, com faixas de torque variando entre 0 e 22 N.m e com incremento de 2 N.m, os rolamentos analisados foram: rolamento saudável, com falha na pista externa (BPFO), com falha na pista interna (BPFI) e falha mista. Todos os dados foram coletados simultaneamente e o tempo de aquisição utilizado foi de aproximadamente 34 segundos.

Tabela 4.2 - Matriz de ensaios para os dados coletados

		Rolamento			
		SAUDÁVEL	BPFO	BPFI	Mista
Torque (N.m)	0	10_SAUD	10_BPFO_05D	10_BPFI_05D	10_BPFO_1V_BPFI_05D
		20_SAUD	20_BPFO_05D	20_BPFI_05D	20_BPFO_1V_BPFI_05D
		30_SAUD	30_BPFO_05D	30_BPFI_05D	30_BPFO_1V_BPFI_05D
	2	12_SAUD	12_BPFO_05D	12_BPFI_05D	12_BPFO_1V_BPFI_05D
		22_SAUD	22_BPFO_05D	22_BPFI_05D	22_BPFO_1V_BPFI_05D
		32_SAUD	32_BPFO_05D	32_BPFI_05D	32_BPFO_1V_BPFI_05D
	4	14_SAUD	14_BPFO_05D	14_BPFI_05D	14_BPFO_1V_BPFI_05D
		24_SAUD	24_BPFO_05D	24_BPFI_05D	24_BPFO_1V_BPFI_05D
		34_SAUD	34_BPFO_05D	34_BPFI_05D	34_BPFO_1V_BPFI_05D
	6	16_SAUD	16_BPFO_05D	16_BPFI_05D	16_BPFO_1V_BPFI_05D
		26_SAUD	26_BPFO_05D	26_BPFI_05D	26_BPFO_1V_BPFI_05D
		36_SAUD	36_BPFO_05D	36_BPFI_05D	36_BPFO_1V_BPFI_05D
	8	18_SAUD	18_BPFO_05D	18_BPFI_05D	18_BPFO_1V_BPFI_05D
		28_SAUD	28_BPFO_05D	28_BPFI_05D	28_BPFO_1V_BPFI_05D
		38_SAUD	38_BPFO_05D	38_BPFI_05D	38_BPFO_1V_BPFI_05D
	10	110_SAUD	110_BPFO_05D	110_BPFI_05D	110_BPFO_1V_BPFI_05D
		210_SAUD	210_BPFO_05D	210_BPFI_05D	210_BPFO_1V_BPFI_05D
		310_SAUD	310_BPFO_05D	310_BPFI_05D	310_BPFO_1V_BPFI_05D
	12	112_SAUD	112_BPFO_05D	112_BPFI_05D	112_BPFO_1V_BPFI_05D
		212_SAUD	212_BPFO_05D	212_BPFI_05D	212_BPFO_1V_BPFI_05D
		312_SAUD	312_BPFO_05D	312_BPFI_05D	312_BPFO_1V_BPFI_05D

14	114_SAUD	114_BPFO_05D	114_BPFI_05D	114_BPFO_1V_BPFI_05D
	214_SAUD	214_BPFO_05D	214_BPFI_05D	214_BPFO_1V_BPFI_05D
	314_SAUD	314_BPFO_05D	314_BPFI_05D	314_BPFO_1V_BPFI_05D
16	116_SAUD	116_BPFO_05D	116_BPFI_05D	116_BPFO_1V_BPFI_05D
	216_SAUD	216_BPFO_05D	216_BPFI_05D	216_BPFO_1V_BPFI_05D
	316_SAUD	316_BPFO_05D	316_BPFI_05D	316_BPFO_1V_BPFI_05D
18	118_SAUD	118_BPFO_05D	118_BPFI_05D	118_BPFO_1V_BPFI_05D
	218_SAUD	218_BPFO_05D	218_BPFI_05D	218_BPFO_1V_BPFI_05D
	318_SAUD	318_BPFO_05D	318_BPFI_05D	318_BPFO_1V_BPFI_05D
20	120_SAUD	120_BPFO_05D	120_BPFI_05D	120_BPFO_1V_BPFI_05D
	220_SAUD	220_BPFO_05D	220_BPFI_05D	220_BPFO_1V_BPFI_05D
	320_SAUD	320_BPFO_05D	320_BPFI_05D	320_BPFO_1V_BPFI_05D
22	122_SAUD	122_BPFO_05D	122_BPFI_05D	122_BPFO_1V_BPFI_05D
	222_SAUD	222_BPFO_05D	222_BPFI_05D	222_BPFO_1V_BPFI_05D
	322_SAUD	322_BPFO_05D	322_BPFI_05D	322_BPFO_1V_BPFI_05D

Para cada faixa de torque foram aquiritadas 3 amostras, o intuito é mostrar a repetitividade do sistema de aquisição de dados bem como dos sinais coletados. Para os sinais termográficos apenas uma aquisição foi realizada. Os sinais foram nomeados da seguinte forma: Utilizando como exemplo a terceira aquisição do torque de 4 N.m, para o rolamento saudável, 34_SAUD, o 3 significa a terceira aquisição, o 4 significa a faixa de torque e a SAUD significa a abreviação de saudável. Para o rolamento com falha na pista externa BPFO, 34_BPFO_05D, o 3 significa a terceira aquisição e o 4 a faixa de torque (4 N.m), BPFO (*Ball Pass Frequency Outer Race*) indica falha na pista externa 05 indica o diâmetro da falha, neste caso 0,5mm, caso fosse 1, seria 1mm, o D indica que o furo foi feito com a inserção do eletrodo na diagonal. Vale ressaltar, que no banco de dados há rolamentos em que a falha foi simulada com o eletrodo tocando a pista na posição vertical, para este caso a letra V é utilizada. A mesma lógica se aplica para BPFI (*Ball Pass Frequency Inner Race*). Já para a falha mista há uma junção entre as falhas BPFO e BPFI, e a indicação das amostras segue a mesma lógica descrita anteriormente.

As amostras de áudio foram aquiritadas utilizando um microfone e um notebook. O microfone utilizado é descrito na seção 4.1.4. A frequência de amostragem de usada foi de 44.1 kHz e uma resolução de 16 bits, no processo foi utilizada a placa de áudio do próprio notebook. Graças ao conversor A/D do NI USB 6215 de 16 bits é possível converter os sinais do domínio analógico (contínuos no tempo) para o domínio digital (amostrados), os dados aquiritados são gravados em meio digital e ficam disponíveis para acesso futuro. Os

sinais de vibração foram captados através do acelerômetro descrito na seção 4.1.4 e do sistema de Aquisição de Dados (DAQ) NI USB 6215. Os sinais de corrente foram coletados utilizando os sensores citados no 4.1.4, neste processo utilizou-se também o USB 6215, tanto os sinais de corrente quanto os sinais de vibração foram amostrados a uma frequência de 30 kHz.

Na **Figura 4.24**, é representado o diagrama com todos os sinais adquiridos, sendo eles: tensão e corrente de armadura do motor, velocidade, torque, vibração, sinal sonoro emitido pelo MIT e imagens térmicas captadas por uma câmera termográfica.

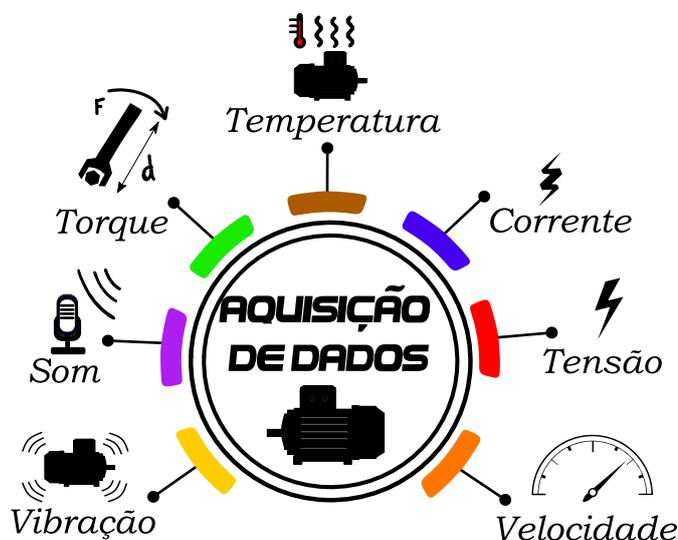


Figura 4.24-Diagrama com todos os sinais adquiridos na bancada de torque controlável.

4.3.1. Metodologia de análise de falha utilizando os sinais de vibração e sinais acústicos.

A detecção de falha por meio da análise do sinal de vibração ainda é o meio mais utilizado nas indústrias no auxílio da manutenção preventiva. A Transformada Rápida de Fourier contribui bastante neste processo, é através dela que é possível enxergar o espectro do sinal no domínio da frequência o que facilita o processo para encontrar as frequências características de falha, entretanto o sinal de vibração muitas vezes é mais dependente da estrutura do que do defeito do rolamento, o sinal de defeito do rolamento costuma estar oculto em meio ao ruído da máquina (BLOCH, GEITNER, 2012). Uma forma de atenuar este problema é aplicando técnicas como filtragem de baixas frequências e detecção de envelope.

Neste trabalho foi utilizada a técnica do envelope para auxiliar na detecção de falha no rolamento, escolhido por ser uma das principais técnicas utilizadas na indústria no auxílio da detecção de falhas em máquinas rotativas. Os conceitos teóricos podem ser melhor compreendidos no item 3.3 do capítulo 3 deste trabalho. O diagrama da metodologia aplicada pode ser visualizado na **Figura 4.25**, onde são representados os passos necessários para a detecção das frequências características de falha.

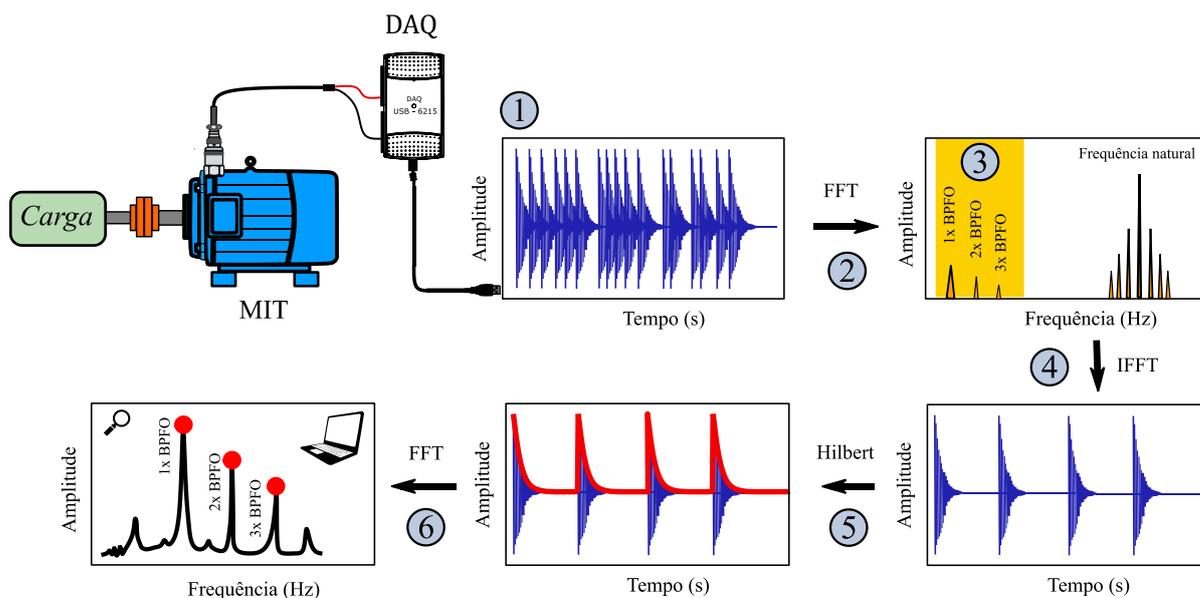


Figura 4.25-Diagrama do processo de detecção das frequências de falha.

As etapas consistem em: ① aquisição do sinal no domínio do tempo; ② converter o sinal para o domínio da frequência por meio da FFT; ③ definir por técnica de filtragem do sinal a região espectral que contém as frequências características de falha do rolamento, esse processo é feito com o auxílio do curtograma que indica a frequência central onde o filtro deve atuar; ④ aplicar a transformada inversa de Fourier no intervalo espectral de interesse para retornar ao sinal no domínio do tempo; ⑤ aplicar a Transformada de Hilbert para detectar o envelope do sinal recuperado para o domínio do tempo do intervalo de interesse; ⑥ aplicar a FFT a fim de obter a frequência característica de falha de um dos componentes estruturais do rolamento. Picos de frequência devem surgir muito próximos das frequências características de falha (FCFs) teóricas, obtidas através da Equação 2.1 ou Equação 2.2, dependendo do tipo de falha.

Os sinais de vibração sonora e vibração mecânica foram analisados aplicando o mesmo processo metodológico, em conformidade com o diagrama mostrado acima. Através da análise do envoltório do sinal e a aplicação posterior da FFT foi possível encontrar as frequências características de falha para os rolamentos com defeito na pista externa, pista interna e falha mista. No capítulo 5 são abordados os resultados obtidos através da metodologia proposta.

4.3.2. Detecção das frequências características de falha usando o método MCSA

O método da análise da assinatura da corrente elétrica do motor (MCSA) foi utilizado para detectar as frequências características de falha na pista externa, interna e falha mista do MIT. Inicialmente ① foi feita a aquisição dos sinais das fases i_a e i_c do motor, os sinais foram adquiridos através do dispositivo de aquisição de dados **Figura 4.16** e foram armazenados em disco rígido para posterior análise; o passo posterior ② consiste em somar os sinais de corrente i_a e i_c ; o terceiro passo ③ consiste na remoção do valor DC presente no sinal resultante; em sequência ④ aplica-se no sinal resultante uma janela Hamming com o intuito de evitar o *Leakage** em sequência é aplicada a Transformada Rápida de Fourier; no passo final ⑤ é feita a análise do espectro do sinal da corrente, nesta etapa são comparados os valores teóricos (obtidos através de fórmulas) com os valores experimentais (obtidos através da análise do espectro do sinal da corrente). O diagrama com as etapas do processo pode ser visualizado na **Figura 4.26**.

**Leakage* ou vazamento ocorre com maior frequência em sinais não periódicos e provoca vazamento espectral de banda larga. O uso de 'janelas' é um dos artifícios utilizados para contornar esse problema.

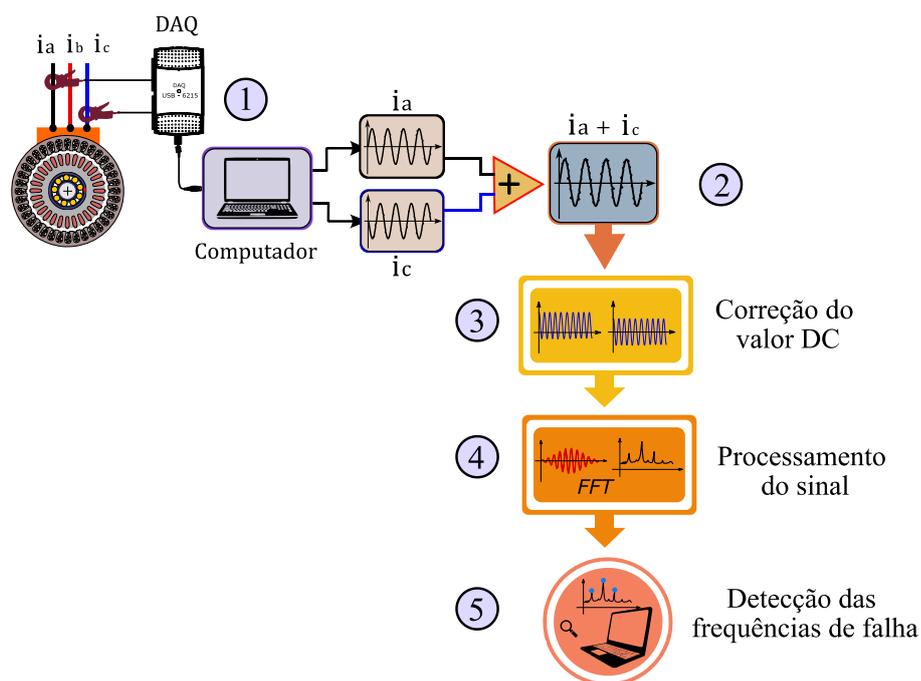


Figura 4.26- Diagrama com as etapas utilizadas no método MCSA.

4.3.3. Detecção das falhas através do método SAC-DM

As etapas do novo método proposto neste trabalho são ilustradas no fluxograma da **Figura 4.27**. A primeira etapa **1** envolve a aquisição dos sinais de corrente com o MIT em funcionamento sob diversas condições de carga e velocidade. As correntes instantâneas i_a e i_c foram adquiridas com uma frequência de amostragem de 30 kHz. Na etapa **2** ocorre à soma das duas correntes $i_a + i_c$ gerando um sinal de corrente resultante. Em seguida, na etapa **3**, aplica-se a transformada de Hilbert para extrair o envelope do sinal da corrente resultante. Na quarta etapa **4**, verifica-se se o sinal é caótico, para realizar essa verificação foram realizados três testes: teste da árvore de símbolos, teste 0-1 e o teste da autocorrelação (detalhado na seção 3.6). Após confirmar o comportamento caótico do sinal, a etapa **5** consiste em identificar os máximos dos sinais (picos) em intervalos regulares de tempo. Na etapa **6**, aplica-se o SAC-DM (item abordado na seção 3.6.4) nesta etapa é feita uma pré-classificação dos sinais por classe de falha. Finalmente, na última etapa **7**, consiste em usar uma rede neural artificial para melhorar ainda mais a classificação dos sinais em: saudável, falha na pista interna (BPFI), falha na pista externa (BPFO) e falha mista (BPFI e BPFO).

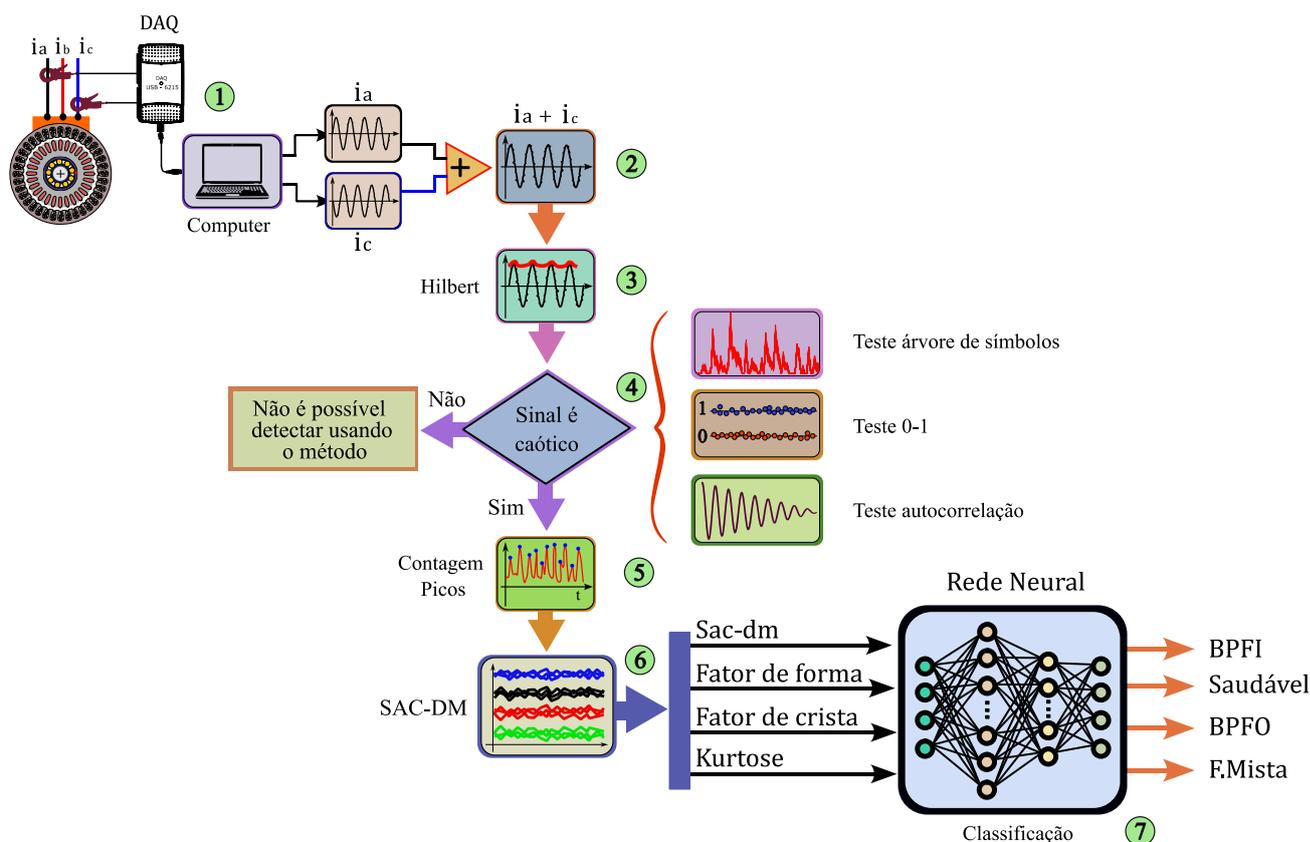


Figura 4.27-Fluxograma do algoritmo proposto usando sinal da corrente e densidade dos máximos (SAC-DM)

Na etapa ⑦, a rede neural utilizada possui uma arquitetura do tipo MLP (*Multilayer Perceptron*), composta por uma camada de entrada, duas camadas ocultas e uma camada de saída, como pode ser visualizada na **Figura 4.28**. A camada de entrada possui 4 neurônios de entrada: a primeira corresponde aos sinais do SAC-DM, a segunda ao fator de forma dos sinais do SAC-DM, a terceira entrada corresponde ao fator de crista do SAC-DM e a quarta e última entrada corresponde à curtose dos sinais do SAC-DM. Na primeira camada escondida (oculta) foram utilizados 15 neurónios com a função de ativação do tipo tangente hiperbólica (*tanh*). Na segunda camada escondida foram utilizados 10 neurónios com a função de ativação também sendo a tangente hiperbólica. A quarta e última camada, composta por 4 neurónios, a função de ativação utilizada foi do tipo *softmax*. Na camada de saída há 4 classes, onde os sinais de entrada podem ser classificados em BPFI, BPFO, Falha mista e saudável.

Vale ressaltar que, a escolha das funções de ativação, bem como a quantidade de neurónios nas camadas escondidas, foi realizada através de testes empíricos e levando em

consideração trabalhos previamente publicados na literatura. A função de custo utilizada foi a entropia cruzada (*cross-entropy*), já o otimizador usado foi o PSO.

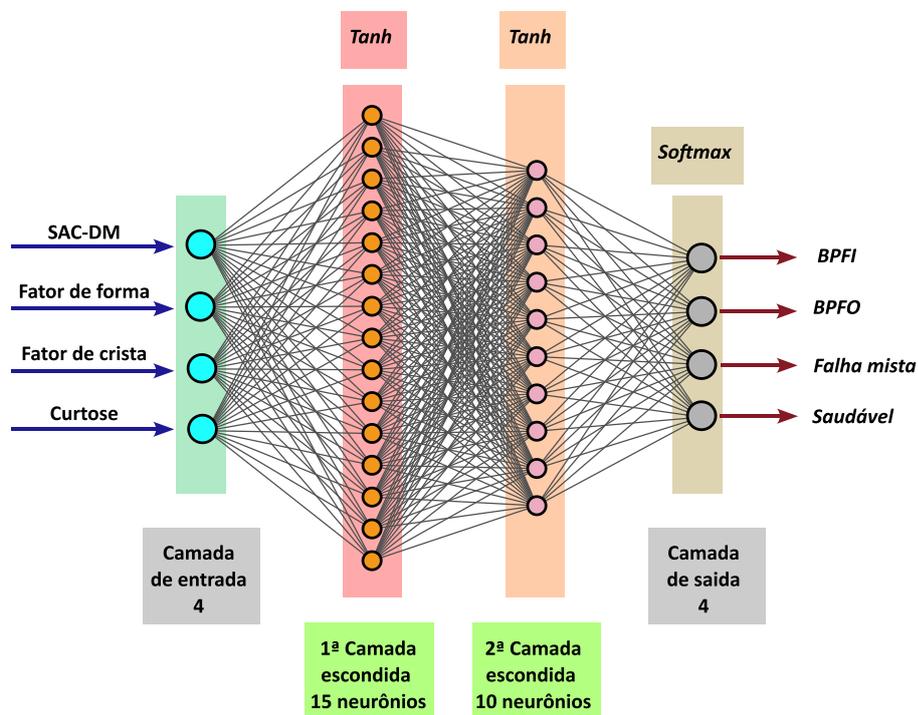


Figura 4.28-Arquitetura da rede neural MLP, utilizada para auxiliar na classificação de falhas no rolamento.

Na partição dos dados, 70% das amostras foram destinadas ao treinamento, 15% foram reservadas para validação, e os 15% restantes foram reservados para teste. Essa divisão é feita para garantir que o modelo tenha dados suficientes para aprender (treinamento), ajustar hiperparâmetros (validação) e avaliar seu desempenho final de forma justa e independente (teste). A separação ajuda a evitar o sobreajuste e a assegurar que o modelo generalize bem para dados não vistos (GOODFELLOW, BENGIO, *et al.*, 2016).

CAPITULO V

5. RESULTADOS E DISCUSSÕES

No presente capítulos são apresentados os resultados experimentais referentes à análise de falhas do rolamento dianteiro do motor elétrico de indução trifásico. Inicialmente, na seção 5.1 são mostrados os resultados da detecção das frequências de falha utilizando o sinal de vibração. Os sinais foram captados utilizando o acelerômetro no sentido radial centrado às 12 horas. Serão abordados na seção 5.2 os resultados da detecção das frequências de falha utilizando a emissão sonora do MIT. Posteriormente foi realizada a comparação entre as duas vibrações, mecânica e sonora. Na seção 5.5 serão apresentados os resultados utilizando o novo método proposto, empregando o sinal da corrente de amadura do MIT e o SAC-DM juntamente com o resultado da classificação auxiliado por uma Rede Neural Artificial.

5.1. DETECÇÕES DAS FREQUÊNCIAS DE FALHA POR MEIO DO SINAL DE VIBRAÇÃO

No presente trabalho optou-se por utilizar a análise da vibração mecânica em conjunto com duas outras análises, a análise do sinal acústico emitido pelo MIT e a análise da corrente do estator. A última análise será abordada através de uma nova técnica baseada na teoria do caos – (SAC-DM) que mostrou-se superior ao método clássico utilizando MCSA.

A análise do sinal de vibração ainda é o meio mais utilizado na detecção de falhas em motores elétricos, sendo uma importante ferramenta na manutenção preditiva, auxiliando na redução de paradas não programadas e otimizando os planos de manutenção.

Neste trabalho os sinais de vibração foram coletados a uma frequência de 30 kHz durante um período de aproximadamente de 34 segundos o que resulta em 1020000 pontos.

Foram realizadas análises para diferentes valores de carga, a saber: 0%, 20%, 40%, 60%, 80% e 100% da carga nominal.

Os dados de vibração foram coletados e analisados utilizando o software Labview. Os sinais coletados foram salvos em arquivo no formato .lvm (*Labview Measurement Format*) extensão desenvolvida pela *National instruments*. Este formato possui uma grande flexibilidade, o que permite ser modificado facilmente para outras extensões, viabilizando ser importado pelo Excel, Matlab ou outros softwares voltados para a análise de dados.

Para detectar a FCF (Frequência Característica de Falha) foi utilizado o método do envelope, que é uma técnica de modulação que permite obter a envoltória de um sinal, conforme a explanação realizada na seção 3.3. Neste método é preciso que o usuário especifique uma banda de frequência, que é utilizada como região de interesse. Após obter o envoltório do sinal de vibração foi aplicada a Transformada Rápida de Fourier (FFT - *Fast Fourier Transform*), o que permitiu caracterizar as frequências características de falha bem como as suas múltiplas.

5.1.1. Análise da falha na pista externa (BPFO)

Inicialmente as coletas foram realizadas com o motor operando sem imposição de carga, ainda assim, acoplado ao motor de corrente contínua. Para o cálculo da FCF em rolamentos é primordial, além das características geométricas do rolamento a medida da velocidade de rotação no eixo do MIT. Para exemplificar o processo de caracterização das falhas, três faixas de carga foram abordadas, sendo: 0%, 60% e 100% da carga nominal. Foram analisados 16 segundos dos sinais de vibração do rolamento com falha BPFO e diâmetro de furo de 0,5 mm fabricado em posição diagonal.

Para 0 % da carga nominal, a velocidade medida com o tacômetro no modo óptico foi de 1797 rpm ou 29,95 Hz que corresponde a f_r (frequência de rotação do motor). Na **Figura 5.1** é possível visualizar as etapas do processo. No item (a) da figura, é possível verificar o sinal de vibração no domínio do tempo do rolamento sem falha (SF) em vermelho e o sinal com falha BPFO em preto. No item (b) verifica-se a FFT dos sinais, onde não é possível identificar as frequências características de falha para o rolamento com defeito na pista externa. Já no item (c), são apresentados os sinais do envelope para SF e BPFO, após esta etapa é aplicada a FFF no sinal do envelope. No item (d) é possível verificar as frequências características de falha na pista externa, bem como suas bandas

laterais. A FCF obtida experimentalmente foi de 107,273 Hz, já a frequência teórica de 106,882 Hz. Vale observar que as frequências até a 5ª harmônica foram também identificadas. Os dados obtidos de forma experimental e de forma teórica, conforme a Equação (2.1) são comparados na Tabela 5.1.

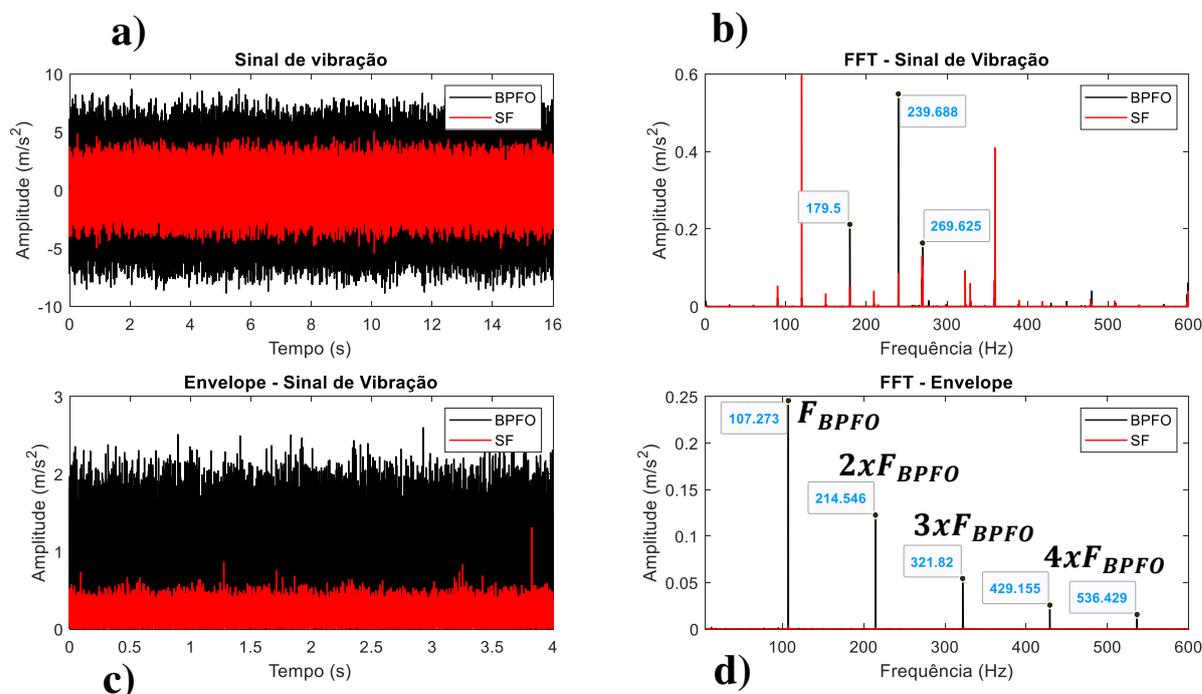


Figura 5.1- Detecção da FCF (BPFO) por meio da análise da vibração, sob carga a 0%.

Aplicando a FFT diretamente no sinal de vibração não foi possível caracterizar a falha na pista externa, entretanto, ao utilizar o método do envelope às frequências de falha foram facilmente caracterizadas. Na tabela abaixo os valores teóricos, obtidos de forma analítica e os valores experimentais são comparados.

Tabela 5.1- Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 0%.

Condição da aquisição	Carga: 0%	Rotação do eixo: 1797 rpm (29,95 Hz)		
Valores obtidos experimentalmente – FFT técnica do envelope (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	107,237	214,546	321,82	
Valores obtidos analiticamente - segundo a Equação (2.1) (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	106,882	213,764	320,646	

Nesta segunda exemplificação a carga utilizada foi de 60% da nominal. Para esta condição de carga a velocidade medida no eixo do motor foi de 1774 rpm o que equivale a 29,57 Hz. Graças ao método do envelope as FCFs foram identificadas. A FCF obtida de forma analítica foi de 105,514 Hz, já a frequência experimental obtida foi de 105,835 Hz. Na **Figura 5.2** é possível verificar os valores das frequências de falha.

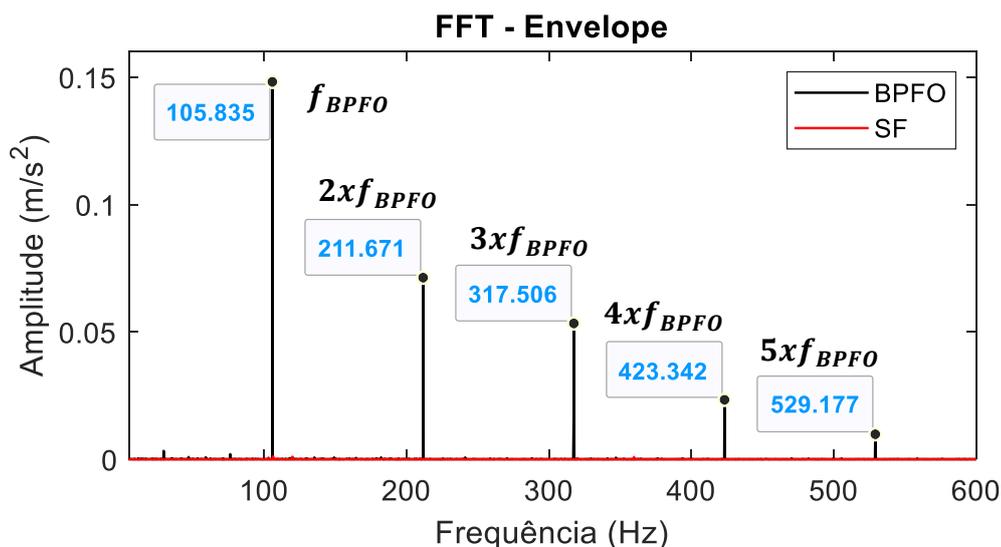


Figura 5.2-Detecção da FCF (BPF0) por meio da análise da vibração, sob carga a 60%.

Na Tabela 5.2 estão descritos os valores das frequências características de falhas e as condições que o sinal foi coletado, além da comparação entre os valores experimentais e teóricos.

Tabela 5.2-Comparação entre a FCF (BPF0) experimental e teórica, sob carga a 60%

Condição da aquisição	Carga: 60%	Rotação do eixo: 1774 rpm (29,57 Hz)		
Valores obtidos experimentalmente – FFT técnica do envelope (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	105,835	211,671	317,506	
Valores obtidos analiticamente - segundo a Equação (2.1) (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	105,514	211,028	316,542	

A carga aplicada para a terceira exemplificação foi de 100% da carga nominal, o processo de detecção das frequências de falhas seguiu a mesma metodologia para as duas

aquisições anteriores. A velocidade de rotação medida no eixo do MIT foi de 1747 rpm ou 29,12 Hz. O Valor da FCF teórica é de 103,909 Hz, já o valor da frequência característica de falha obtido através da análise do sinal de vibração pelo método do envelope foi de 103,335 Hz, sendo possível ainda a identificação dos seus valores múltiplos, como pode ser observado na

Figura 5.3.

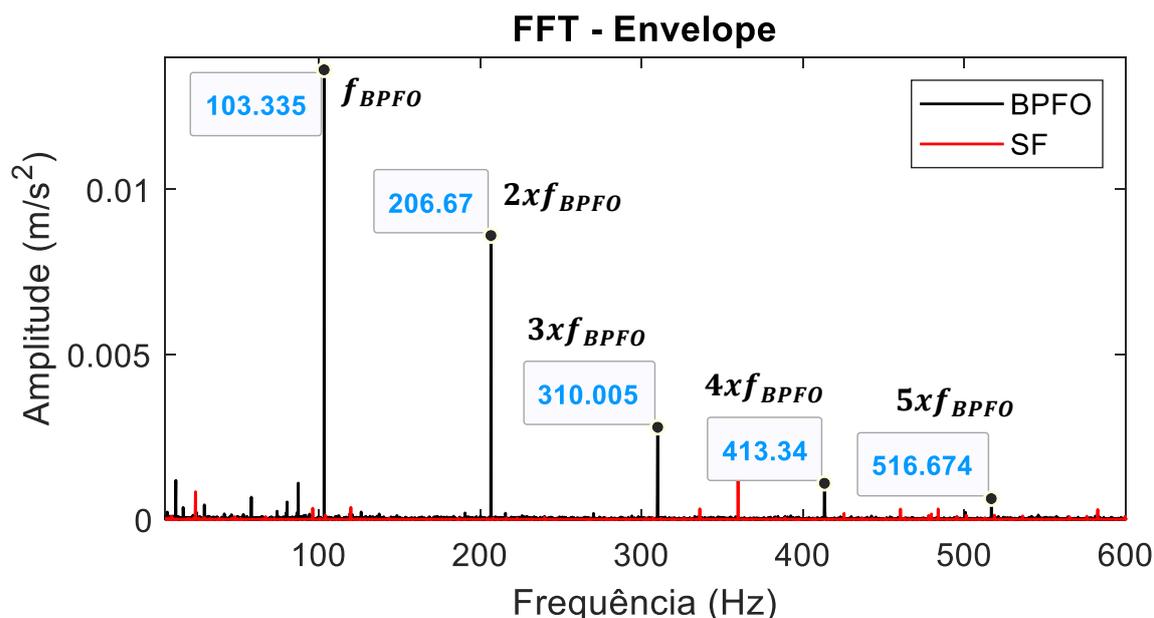


Figura 5.3- Detecção da FCF (BPFO) por meio da análise da vibração, sob carga a 100%.

Na Tabela 5.3 é feita a comparação entre os valores obtidos de forma teórica e os valores encontrados através da análise do sinal de vibração.

Tabela 5.3- Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 100%.

Condição da aquisição	Carga: 100%	Rotação do eixo: 1747 rpm (29,12 Hz)		
Valores obtidos experimentalmente – FFT técnica do envelope (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	103,335	206,67	310,005	
Valores obtidos analiticamente - segundo a Equação (2.1) (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	103,909	207,818	311,727	

Para as demais faixas de carga, os valores das frequências características de falha tanto experimentais quanto teóricas foram compilados na Tabela 5.11.

5.1.2. Análise da falha na pista interna (BPFI)

Para analisar as falhas na pista interna (BPFI), será adotada a mesma metodologia que foi utilizada no tópico anterior. O diâmetro do furo da falha no rolamento utilizado foi de 0,5 mm com eletrodo inserido na posição diagonal. Para fins de exemplificação foi utilizada a carga a 0% da carga nominal.

Na **Figura 5.4** verificam-se os sinais sem falha, em vermelho e com falha na pista interna (BPFI), em azul. O motor opera a 0% de carga, com a velocidade no eixo do motor sendo de 1796 rpm, ou 29,93 Hz. No item (b), analisando o espectro do sinal de vibração através da FFT, não é possível identificar as FCF, já no item (d), após o sinal do envelope ser obtido e a FFT ser aplicada é possível verificar as frequências características de falha e suas múltiplas. A frequência característica de falha teórica para este caso, calculada através das características geométricas do rolamento 6206 ZZ e da velocidade de rotação do eixo, conforme equação 2.2 é de 162,577 Hz, já a FCF encontrada de forma experimental foi de 161,785 Hz.

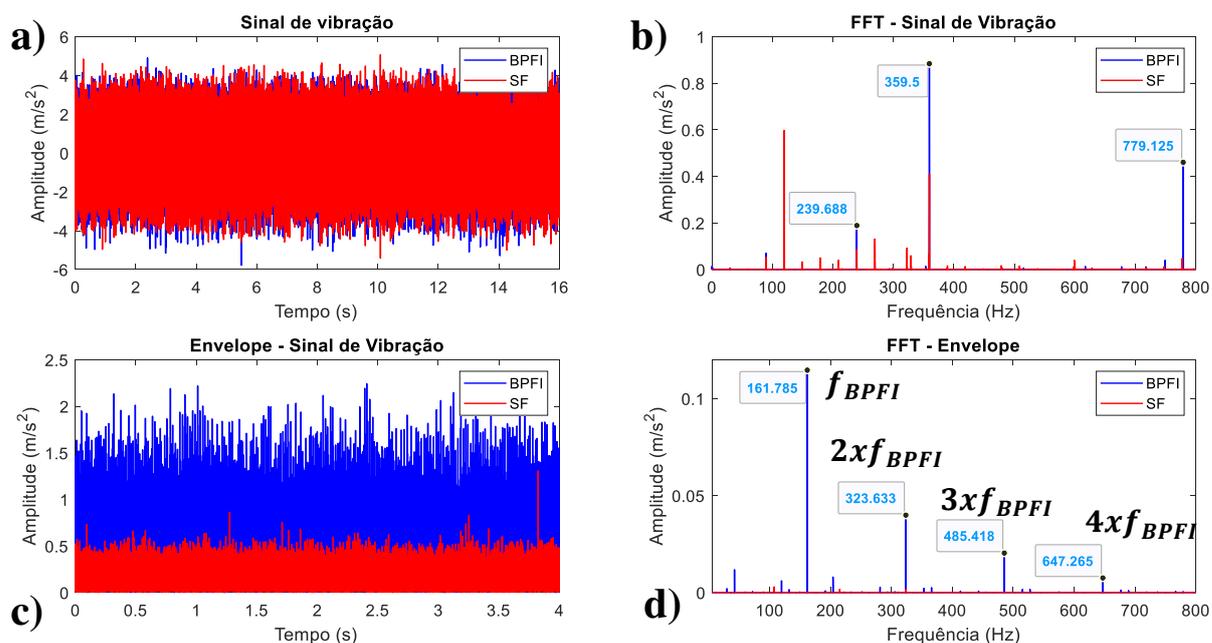


Figura 5.4- Detecção da FCF (BPFI) por meio da análise da vibração, sob carga a 0%.

Na **Tabela 5.4** abaixo os valores teóricos e experimentais das frequências características de falha são comparados.

Tabela 5.4- Comparação entre a FCF (BPFI) experimental e teórica, sob carga a 0%

Condição da aquisição	Carga: 0%	Rotação do eixo: 1796 rpm (29,93 Hz)	
Valores obtidos – FFT técnica do envelope (Hz)			
	1xFCF	2xFCF	3xFCF
Pista interna	161,785	323,633	485,418
Valores obtidos analiticamente segundo a Equação (2.1)(Hz)			
	1xFCF	2xFCF	3xFCF
Pista interna	162,577	325,154	487,731

O método para caracterização da FCFs na pista interna (BPFI) para as demais faixas de carga deram-se da mesma forma que foi abordada no processo acima. Desta forma, para evitar um processo repetitivo, compilou-se esses resultados na Tabela 5.12.

5.1.3. Análise da falha mista (BPFO e BPFI)

Embora não sejam tão comuns, falhas simultâneas podem afetar os rolamentos, o que pode dificultar a detecção das frequências características de falha. Para emular essas condições foi preparado um rolamento com falha simulada na pista interna (BPFI) e falha na pista externa (BPFO). A falha na pista interna foi fabricada utilizando um eletrodo de diâmetro de 0,5 mm inserido na posição diagonal, já a falha na pista externa o diâmetro do eletrodo utilizado foi de 1 mm, inserido na posição vertical. O processo de caracterização das falhas foi utilizado para todas as faixas de carga, por esse motivo, optou-se por exemplificar apenas para a faixa de 0% da carga nominal.

Nesta primeira exemplificação, foi aplicado o método do envelope para o MIT operando com 0% da carga nominal, a uma velocidade de 1796 rpm ou 29,93 Hz. Conforme apresentado na Figura 5.5, mais uma vez, observa-se que a aplicação direta da FFT nos sinais de vibração item (b) não é capaz de detectar as frequências características de falha. Para este caso específico, a frequência de falha teórica para a falha na pista externa (BPFO) deveria ser de 106,82 Hz, enquanto a frequência de falha para a pista interna (BPFI) deveria ser de 162,577 Hz, porém, estas frequências não puderam ser identificadas no espectro de vibração para a falha mista.

Destaca-se que ao utilizar a FFT nos sinais do envelope (item d), foi possível identificar a frequência característica de falha para a pista interna (BPFI), estabelecida em 161,848 Hz. Quanto à frequência de falha para a pista externa, não foi possível identificá-

la. Embora tenha havido um pico de frequência em 102,022 Hz, próximo ao local onde se esperaria encontrar o pico de frequência de falha na pista externa, não é possível atribuir este valor de frequência como sendo uma FCF que caracterize uma BPFO, além de não ser possível identificar as frequências múltiplas, como ocorre para a FCF da falha na pista interna.

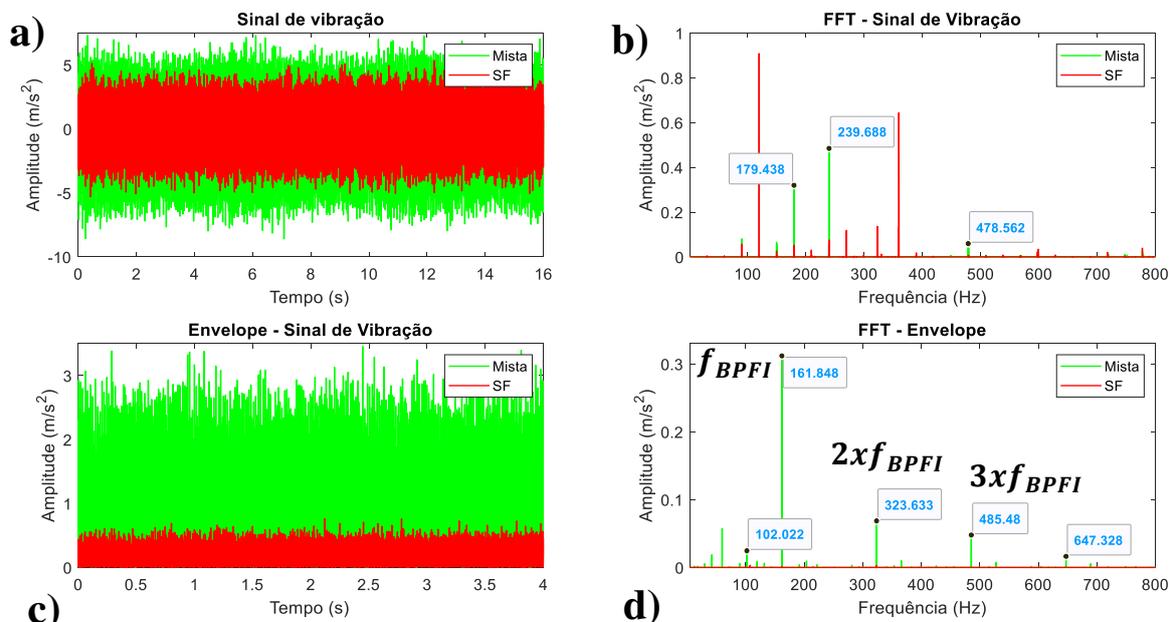


Figura 5.5- Detecção da FCF (Mista) por meio da análise da vibração, com carga a 0%.

Na **Tabela 5.5** são apresentados os resultados teóricos obtidos através das Equações (2.1) e (2.2), e os valores experimentais obtidos através da análise do espectro de vibração do motor de indução trifásico.

Tabela 5.5- Comparação entre a FCF (Mista) experimental e teórica, sob carga a 0%.

Condição da aquisição	Carga: 0%		Rotação do eixo: 1796 rpm (29,93 Hz)	
Valores obtidos – FFT técnica do envelope (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	---	---	---	
Valores obtidos analiticamente segundo a Equação (2.1) (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	106,82	213,64	320,46	
Valores obtidos – FFT técnica do envelope (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista interna	161,848	323,633	485,48	
Valores obtidos analiticamente segundo a Equação (2.2) (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista interna	162,577	325,154	487,731	

As frequências características de falha (FCF) para a falha na pista externa não foi detectada ao analisar o espectro de vibração, já a FCF para a pista interna é facilmente detectável bem como as suas múltiplas.

Uma das razões possíveis para a não identificação da frequência característica de falha na pista externa é o método pelo qual o dano simulado foi realizado. No caso específico aqui analisado, o dano foi provocado por um eletrodo de 1 mm de diâmetro inserido verticalmente, resultando em uma falha que não removeu material suficiente para afetar o sinal de vibração quando ocorria o impacto das esferas na falha. Além disso, a alta amplitude do dano na pista interna pode ter mascarado a presença da falha na pista externa, levando a uma sobreposição das frequências características de falha da pista interna em relação à pista externa.

5.2. DETECÇÕES DAS FREQUÊNCIAS DE FALHA POR MEIO DO SINAL ACÚSTICO

A emissão acústica gerada pelo motor de indução contém informações valiosas que podem fornecer indicações da saúde do equipamento. A detecção de falhas por meio da análise do sinal acústico é um método não invasivo, o que representa uma vantagem significativa em comparação com o método que utiliza vibração mecânica, por exemplo, além de ser de fácil operação.

A aquisição do sinal acústico nesta pesquisa foi realizada utilizando o microfone condensador **Figura 4.15** a aproximadamente 30 cm da fonte emissora, neste caso o MIT. Foi utilizada uma frequência de amostragem de 44,1 KHz e os áudios foram gravados no modo monofônico. Foram realizadas aquisições com diferentes valores de carga, a saber: 0%, 20%, 40%, 60%, 80% e 100% da carga nominal. O método de análise para a detecção das frequências de falhas foi à mesma utilizada para o sinal de vibração, utilizando o método do envelope de Hilbert. Para esta primeira análise (BPFO) e para fins de exemplificação foram utilizadas apenas três faixas de carga: 0%, 60% e 100 % da carga nominal.

5.2.1. Análise da falha na pista externa (BPFO)

A primeira aquisição foi realizada sob carga a 0% da carga nominal a velocidade medida no eixo do motor foi de 1797 rpm ou 29,95 Hz. Observando a **Figura 5.6**, é possível identificar a frequência característica de falha, seu valor teórico corresponde a 106,882 Hz, os valores da FCF experimental, encontrada por meio da análise do espectro do sinal do som, podem ser observados no gráfico do item d) sendo a frequência fundamental de 107,344 Hz e suas frequências múltiplas $2xf_{BPFO}$ e $3xf_{BPFO}$, 214,751 e 322,095 Hz respectivamente.

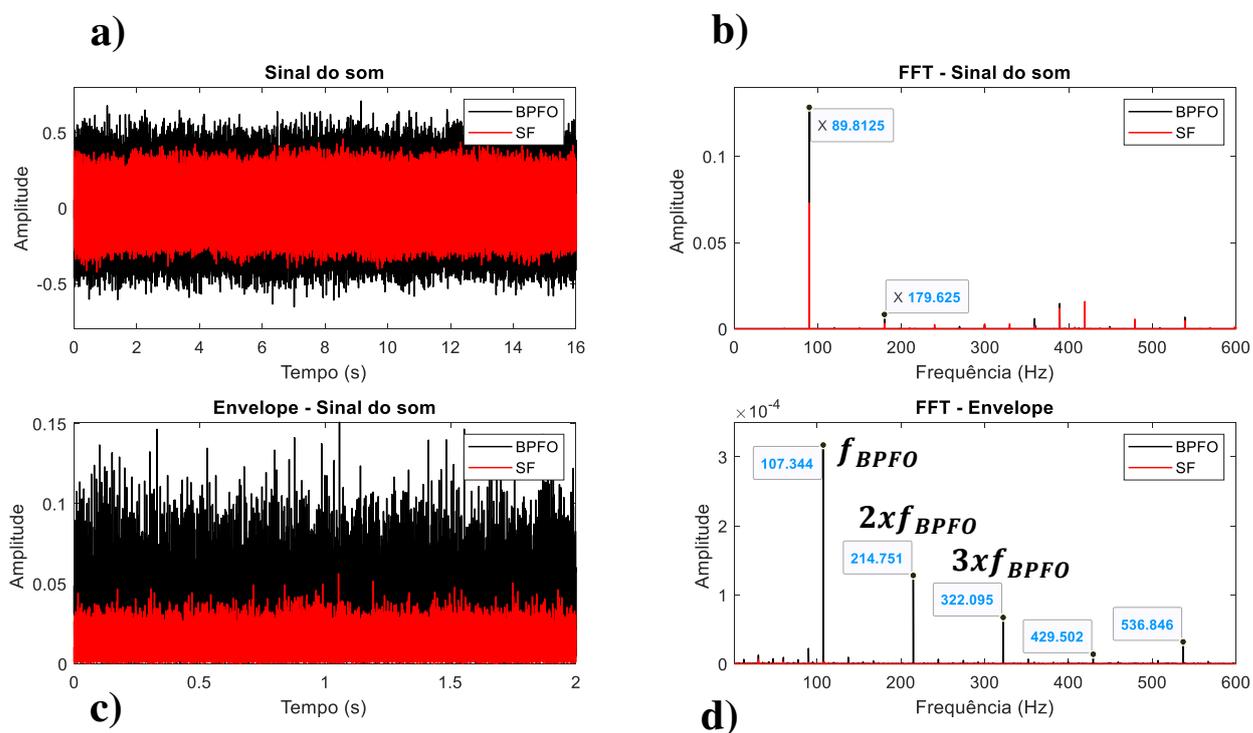


Figura 5.6-Detecção da FCF (BPFO) por meio do sinal acústico, sob carga a 0% da nominal

Os valores teóricos e experimentais podem ser observados na Tabela 5.6, onde são comparados os valores teóricos, obtidos através da equação 2.1, com os valores experimentais obtidos através do método do envelope.

Tabela 5.6-Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 0%.

Condição da aquisição	Carga: 0%	Rotação do eixo: 1797 rpm (29,95 Hz)
Valores obtidos experimentalmente – FFT técnica do envelope (Hz)		

	1xFCF	2xFCF	3xFCF
Pista externa	107,344	214,751	322,095
Valores obtidos analiticamente segundo a Equação (2.1) (Hz)			
	1xFCF	2xFCF	3xFCF
Pista externa	106,882	213,764	320,646

A segunda exemplificação aquisição foi realizada com uma carga correspondente a 60% da carga nominal, a velocidade de rotação medida por meio do tacômetro no eixo do motor foi de 29,57 Hz. Através da aplicação da Transformada Rápida de Fourier no sinal do envelope, foi possível encontrar a frequência característica de falha na pista externa, sendo esta de (105,969 Hz). A frequência característica de falha juntamente com as suas frequências múltiplas podem ser observadas na **Figura 5.7**.

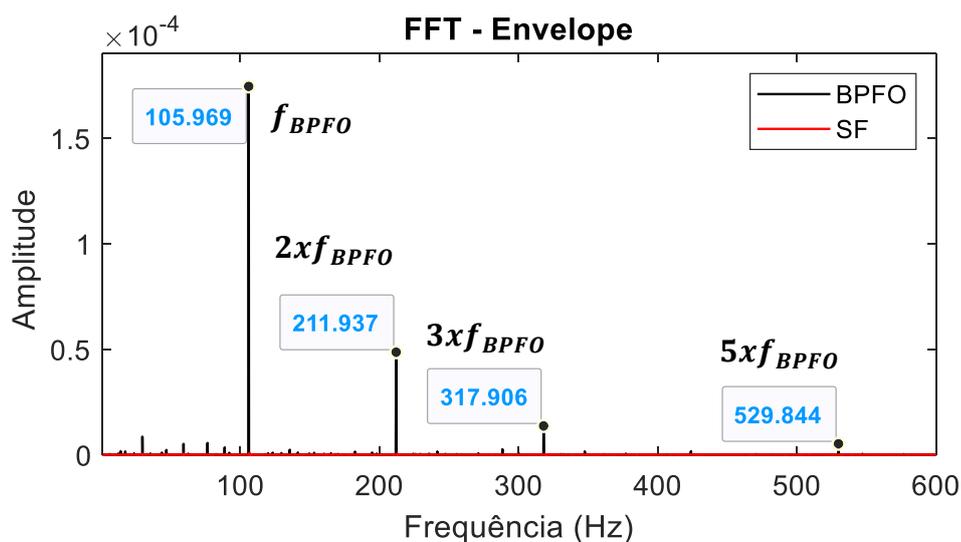


Figura 5.7-Detecção da FCF (BPF0) por meio do sinal acústico, sob carga a 60% da nominal.

Na Tabela 5.7 são apresentadas as frequências características de falha obtidas de forma experimental e de forma teórica através da equação 2.1.

Tabela 5.7-Comparação entre a FCF (BPF0) experimental e teórica, sob carga a 60%

Condição da aquisição	Carga: 60%	Rotação do eixo: 1774 rpm (29,57 Hz)
Valores obtidos experimentalmente – FFT técnica do envelope (Hz)		
	1xFCF	2xFCF
		3xFCF

Pista externa	105,969	211,937	317,906
Valores obtidos analiticamente segundo a Equação (2.1) (Hz)			
	1xFCF	2xFCF	3xFCF
Pista externa	105,514	211,028	316,542

A carga imposta ao MIT na terceira exemplificação corresponde a 100% da carga nominal. Quando o motor excede muito a sua carga nominal gera-se sobreaquecimento, isso ocorre devido ao aumento da corrente elétrica que ultrapassa a corrente nominal. A corrente nominal pode ser encontrada no catálogo do motor ou na própria placa de identificação fixada na carcaça do mesmo. A velocidade de rotação medida no eixo do motor foi de 29,12 Hz. A frequência Característica de falha teórica, para esta faixa de velocidade, conforme a equação 2.1, deve ser de 103,909 Hz, já a frequência obtida de forma experimental foi de 103,468 Hz, o que demonstra a excelente precisão do método implementado. A FCF e suas múltiplas podem ser observadas na **Figura 5.8**.

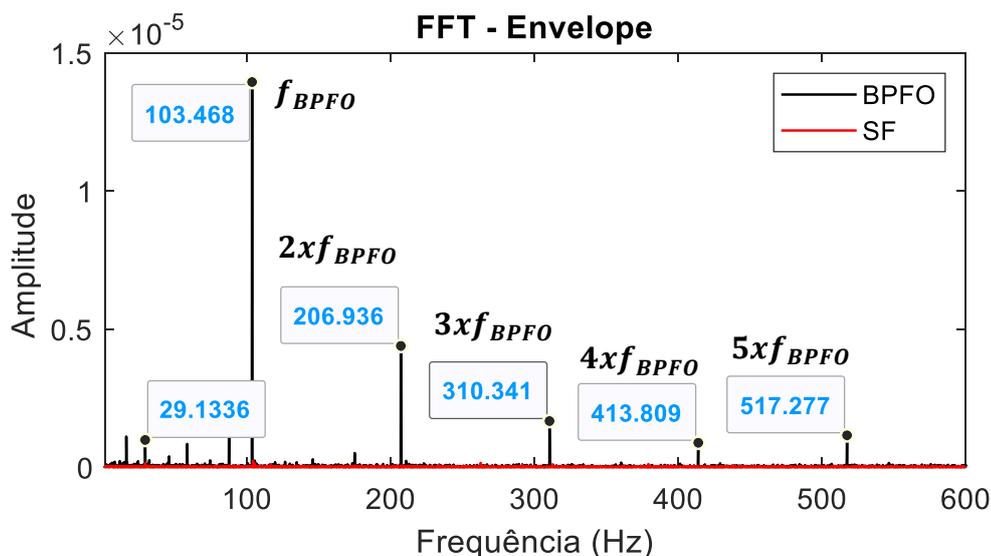


Figura 5.8-Detecção da FCF (BPFO) por meio do sinal acústico, sob carga a 100% da nominal.

Na Tabela 5.8, as frequências de falha teórica e experimentais são confrontadas, juntamente com seus valores múltiplos.

Tabela 5.8-Comparação entre a FCF (BPFO) experimental e teórica, sob carga a 100%.

Condição da aquisição	Carga: 100%	Rotação do eixo: 1747 rpm (29,13 Hz)
Valores obtidos – FFT técnica do envelope (Hz)		

	1xFCF	2xFCF	3xFCF
Pista externa	103,468	206,936	310,341
Valores obtidos analiticamente segundo a Equação (2.1) (Hz)			
	1xFCF	2xFCF	3xFCF
Pista externa	103,909	207,818	311,727

Para a falha na pista externa (BPFO) foi possível identificar todas as frequências características de falha.

5.2.2. Análise de falha na pista interna (BPFI)

A mesma metodologia adota no item anterior, foi adotada neste item para analisar a falha na pista interna (BPFI). O rolamento com falha BPFI possui um diâmetro de falha de 0,5 mm com a falha sendo simulada com o eletrodo inserido na posição diagonal.

Para evitar um processo repetitivo, optou-se por exemplificar a caracterização das frequências de falha para a faixa de carga de 0% da nominal, com as demais faixas de carga sendo compiladas na Tabela 5.12.

Na **Figura 5.9** são apresentados os resultados da análise do sinal sonoro pelo método do envelope, com carga a 0% da carga nominal e velocidade de rotação no eixo do MIT de 29,92 Hz. A frequência característica de falha teórica, para este caso, calculada através da equação 2.2, deve ser de 162,487 Hz. No item (b) após aplicar a FFT diretamente nos sinais do som não foi possível identificar a FCF, pois não há pico de frequência que corresponda ao valor da FCF teórica. No item (d) da figura, após aplicar a FFT no sinal do envelope, percebe-se que o valor do pico de frequência em 162,048 Hz é muito próximo ao valor da FCF teórica, sendo seguido ainda de picos laterais decrescentes que são múltiplos da frequência fundamental da FCF.

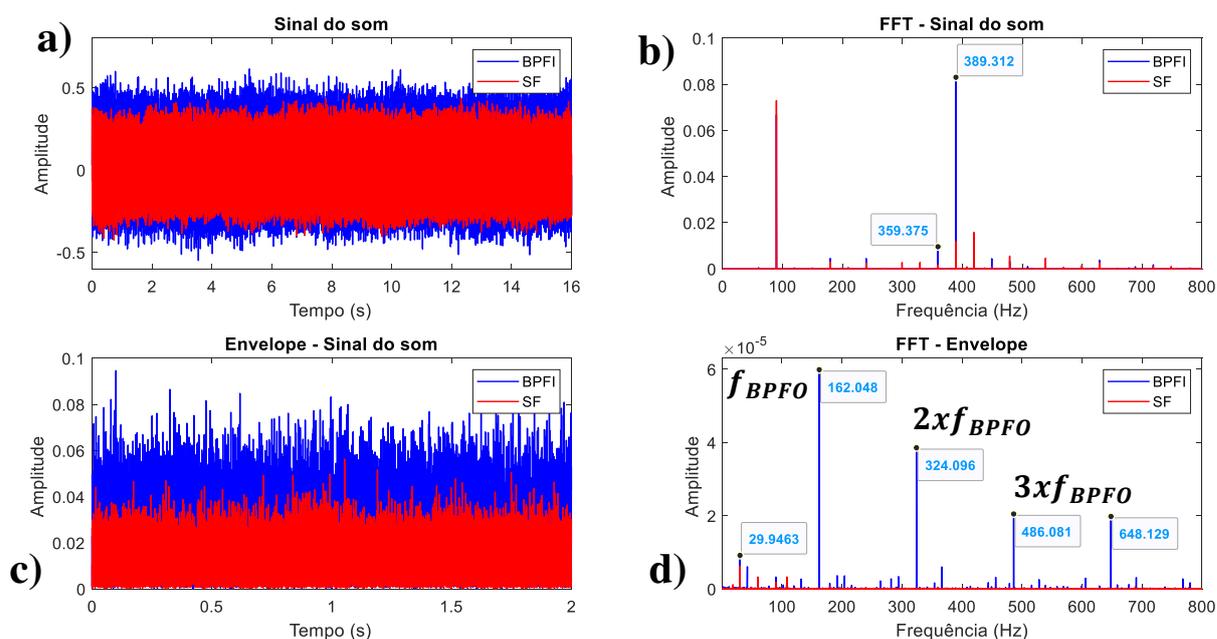


Figura 5.9 - Detecção da FCF (BPFI) por meio do sinal acústico, sob carga a 0% da nominal.

Na Tabela 5.9, abaixo, são comparados os valores teóricos e os valores experimentais, obtidos através da equação 2.2 e da análise do espectro do sinal do som emitido pelo MIT.

Tabela 5.9- Comparação entre a FCF (BPFI) experimental e teórica, sob carga a 0%.

Condição da aquisição	Carga: 0%	Rotação do eixo: 1795 rpm (29,92 Hz)	
Valores obtidos – FFT técnica do envelope (Hz)			
	1xFCF	2xFCF	3xFCF
Pista interna	162,048	324,096	486,081
Valores obtidos analiticamente segundo a Equação (2.1) (Hz)			
	1xFCF	2xFCF	3xFCF
Pista interna	162,487	324,974	487,461

Os resultados para o cenário com falha simulada na pista interna (BPFI), demonstram que as frequências características de falha foram detectadas com sucesso, demonstrando a robustez da técnica do envelope de Hilbert em conjunto com a FFT, e o

bom nível do sistema de aquisição de dados que conseguiu captar os sinais mantendo características e frequências de interesse.

5.2.3. Análise de falha mista (BPFI e BPFO)

Analisar falhas mistas em rolamentos é um processo desafiador, pois há pelo menos dois defeitos simultâneos ocorrendo no mesmo, de forma que as falhas devem ser detectadas e tratadas individualmente.

As falhas no rolamento foram simuladas utilizando um eletrodo de 0,5mm, inserido na posição diagonal, para gerar a falha na pista interna (BPFI), já para a falha na pista externa (BPFO) foi utilizado um eletrodo de 1 mm de diâmetro inserido na posição vertical.

Para fins de exemplificação foi utilizada uma carga a 0% da carga nominal a velocidade do motor medida foi de 29,93 Hz. Para estas condições, e utilizando as características geométricas do rolamento 6205-ZZ a frequência característica de falha teórica para a pista externa deve ser de 106,82 Hz, já a frequência da pista interna deve ser de 162,577 Hz. Observando o item (b) da **Figura 5.10**, verifica-se que no espectro não há nenhum pico de frequência que corresponda à frequência característica de falha, nem para a pista externa nem para a pista interna. Ao analisar o espectro do item (d), obtido a partir do sinal do envelope, verifica-se que um pico de frequência muito próximo a FCF teórica, para falha na pista interna (BPFI), é encontrado, sendo este de 162,048 Hz. Ao continuar a análise do espectro referente ao item (d) não foi possível encontrar um pico de frequência que indique uma correspondência com a FCF teórica, para falha na pista externa.

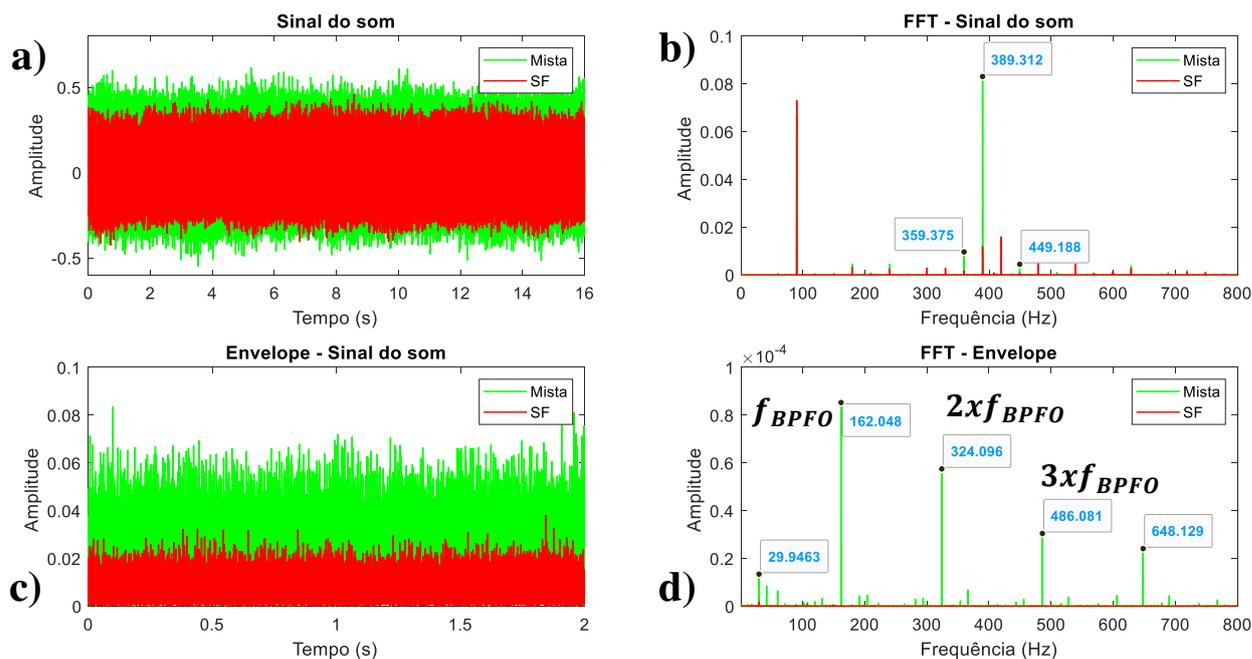


Figura 5.10- Detecção da FCF (Mista) por meio do sinal acústico, sob carga a 0% da nominal.

Na Tabela 5.10 são comparados os valores das frequências características de falha teóricas obtidas através da equação 2.1 e 2.2, com os valores da FCF experimentais, obtidos através da análise do espectro do sinal da vibração sonora emitida pelo MIT.

Tabela 5.10- Comparação entre a FCF (Mista) experimental e teórica, sob carga a 0 %.

Condição da aquisição	Carga: 0%	Rotação do eixo: 1796 rpm (29,93 Hz)		
Valores obtidos – FFT técnica do envelope (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	---	---	---	
Valores obtidos analiticamente segundo a Equação (2.1) (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista externa	106,82	213,64	320,46	
Valores obtidos – FFT técnica do envelope (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista interna	162,048	324,088	488,081	
Valores obtidos analiticamente segundo a Equação (2.2) (Hz)				
	1xFCF	2xFCF	3xFCF	
Pista interna	162,577	325,154	487,731	

Não foi possível identificar as frequências características de falha para pista externa, isso se deve a alguns fatores que podem ter atuado de forma isolada ou em conjunto, são eles: a forma como a falha foi simulada, o diâmetro da falha, a carga aplicada ao MIT pode não ter sido alta o suficiente.

5.3. COMPARAÇÃO ENTRE OS SINAIS DE VIBRAÇÃO MECÂNICA E SONORA EMITIDOS PELO MIT

Para validar o sistema de medição e o algoritmo de detecção de falhas, foram realizados testes em seis níveis de torque diferentes. O torque aplicado ao Motor de Indução Trifásico (MIT) variou entre 0 e 20 Nm, com incrementos de 4 Nm. Cada valor de torque foi submetido a três coletas de dados distintas. Para cada rolamento defeituoso, realizou-se um total de 36 análises: 18 para os sinais de vibração e 18 para os sinais sonoros. Para simplificar a visualização, foi realizada a média dos três sinais para cada faixa de torque. Isso resultou na representação de apenas 6 pontos de frequência em vez dos 18 originais para cada sinal.

Esses procedimentos garantiram uma avaliação abrangente do desempenho do sistema e do algoritmo em diferentes condições de operação. Foram comparados os sinais de vibração mecânica e sonora, para os rolamentos com falha na pista externa (BPFO) e falha na pista interna (BPFI), abordados na seção 5.1 e 5.2.

Na seção 5.3 foi abordada a caracterização das falhas para um rolamento com falha mista. Devido à impossibilidade de obter as frequências características de falha para a pista externa a comparação entre os resultados teóricos e experimentais ficaria comprometida, tendo em vista que apenas as frequências para a pista interna foram obtidas. De tal modo que a análise se assemelharia bastante ao que foi feito para a pista interna na seção 5.2. Assim sendo, as análises das seções 5.3.1 e 5.3.2 se restringiram a abordar apenas as falhas do rolamento na pista interna e externa.

5.3.1. Comparação de resultados para a falha na pista externa (BPFO)

Na **Figura 5.11**, são apresentados os resultados das frequências características de falha para os sinais de vibração mecânica e sonora, exibidos na forma de gráfico de barras. Observa-se que, à medida que o torque aumenta, há uma tendência de queda na frequência de falha. Isso ocorre devido à relação entre torque e velocidade, onde um aumento no

torque leva a uma redução na velocidade. Como a velocidade de rotação do MIT, juntamente com a geometria do rolamento, desempenha um papel crucial na determinação da frequência de falha do rolamento, a variação na velocidade exerce uma influência considerável nos valores observados.

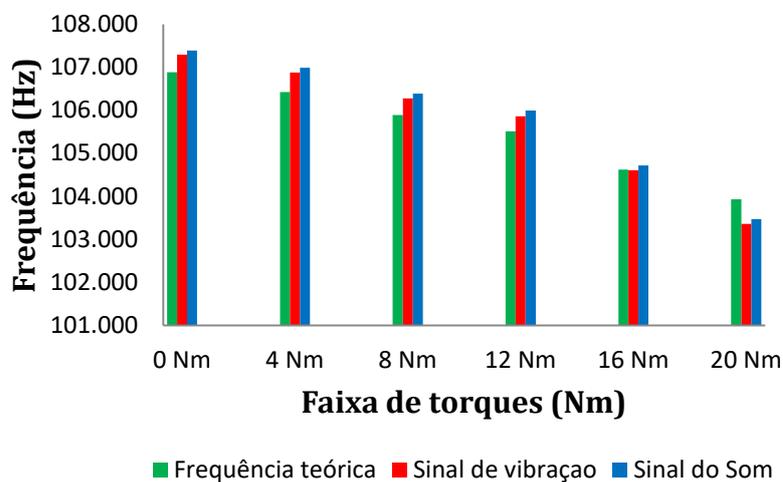


Figura 5.11- Comparação entre as FCFs teóricas e experimentais para falha na pista externa.

Para verificar o grau de aproximação entre as frequências características de falha teóricas e experimentais, tanto para as frequências obtidas através da análise dos sinais de vibração quanto dos sinais do som, foram traçados gráficos de dispersão, e feita uma análise de regressão linear para obter o grau de semelhança entre os dados.

Para avaliar o quão próximas estão às frequências características de falha teóricas das experimentais, tanto para os sinais de vibração quanto para os sinais do som, foram plotados gráficos de dispersão e realizada uma análise de regressão linear. Esse procedimento permitiu determinar o grau de semelhança entre os dados, fornecendo uma visão mais clara da concordância entre as frequências teóricas e experimentais. Esses dados podem ser observados na **Figura 5.12**.

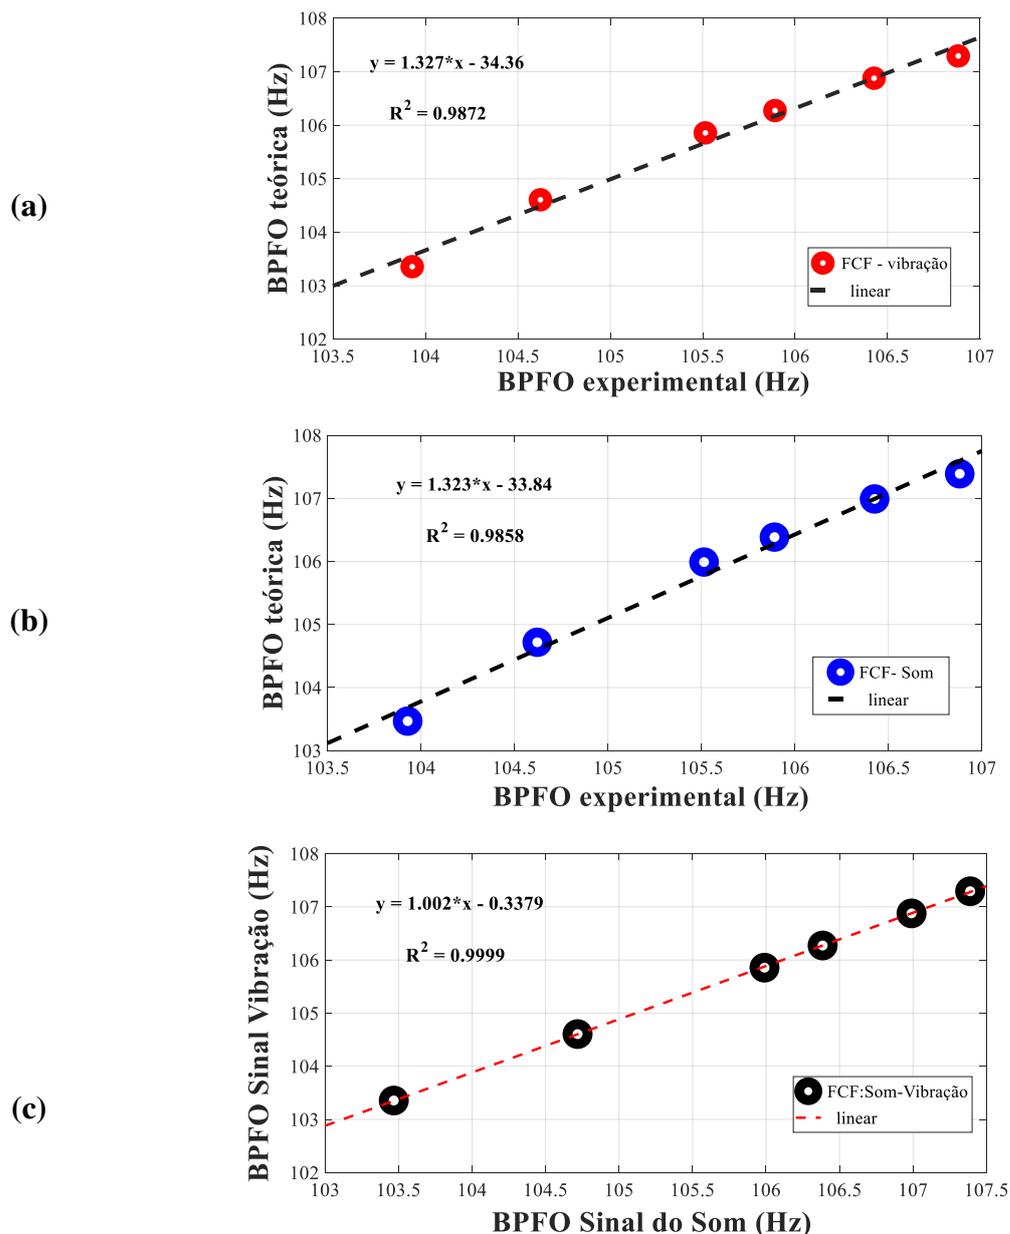


Figura 5.12- Comparação entre as FCF experimentais, obtidas através da análise dos sinais de vibração mecânica e sonora e as FCF teóricas obtidas de forma analítica para falha do tipo BPFO.

No item (a) da figura acima, são comparados os resultados para as FCFs obtidas de forma teórica com as frequências características de falha obtidas através da análise dos sinais de vibração, nesta comparação obteve-se um coeficiente de determinação R^2 de 0,987, o que comprova que aproximadamente 98,7% da variabilidade observada na variável dependente (FCF obtidas através dos sinais de vibração) pode ser explicada pelos regressores incluídos no modelo. Já no item (b) é feita a comparação das FCFs teóricas com a as FCFs obtidas através da análise dos sinais sonoros, onde foi possível obter um coeficiente de determinação R^2 de 0,985. Para ambos os casos, tanto para os sinais de

vibração mecânica quanto para os sinais do som, é possível observar uma excelente aproximação em relação aos valores de referência das FCFs teóricas. No item (c) foi feita a comparação entre as frequências características de falha experimentais, para os sinais de vibração e para os sinais do som, o coeficiente de determinação foi de R^2 0.999, evidenciando a excelente aproximação entre ambos os sinais experimentais.

Na **Figura 5.13** são plotadas as frequências características de falha teóricas e experimentais. Ao analisar o gráfico é possível observar que as frequências características de falha dos sinais de vibração e dos sinais sonoros exibem trajetórias praticamente idênticas, corroborando com o resultado do gráfico de regressão da **Figura 5.12**, item (c), o que demonstra uma grande similaridade entre os dois conjuntos de dados. Quando as FCFs experimentais são confrontadas com as FCF teóricas, percebe-se que há uma forte aproximação na faixa de 16 Nm, ponto em que as trajetórias se interceptam, neste ponto os erros relativos percentuais são mínimos, 0,03 % para a vibração e 0,09 % para o som. Na faixa de 20 Nm ocorre uma inversão nas trajetórias das FCFs do som e da vibração em relação à FCF teórica. O erro relativo percentual máximo para a FCF obtida através da análise dos sinais vibração foi de 0,55 % enquanto para a FCF obtida através da análise dos sinais do som o erro relativo percentual máximo foi de 0,52 %.

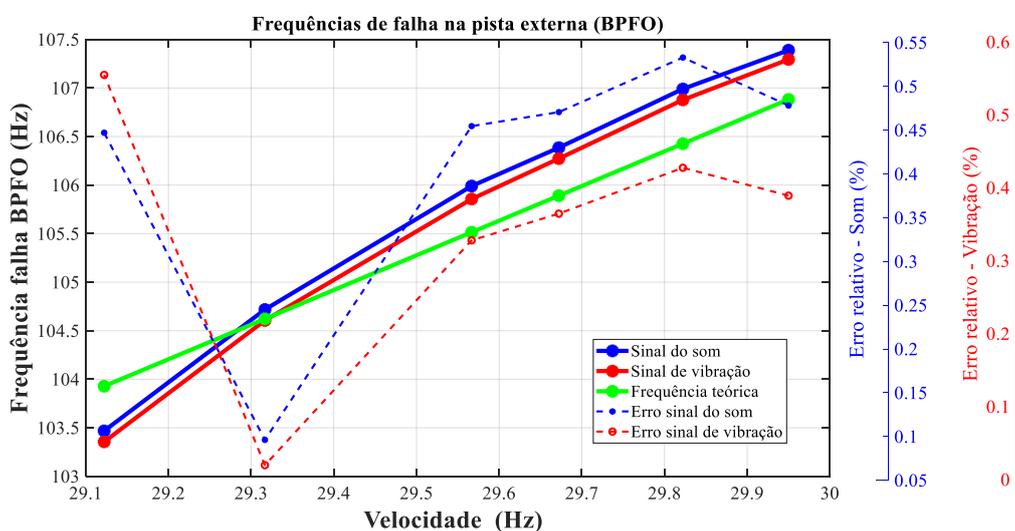


Figura 5.13-Comparação entre os valores teóricos da FCF e os valores experimentais com seus respectivos erros relativos percentuais para uma falha do tipo BPFO.

Os valores de torque e velocidade medidos, assim como os valores de FCF obtidos tanto de forma teórica quanto de forma experimental e os erros relativos percentuais foram condensados na Tabela 5.11, a fim de melhorar a visualização e a compreensão dos resultados obtidos.

Tabela 5.11-Comparação entre as FCFs teóricas e experimentais para defeito na pista externa (BPFO) do rolamento SKF 6206 ZZ com furo de 0.5 mm de diâmetro feito na diagonal

Torque (Nm)	Velocidade (rpm)	Velocidade (Hz)	FCF-Teórica (Hz)	FCF- Vibração (Hz)	FCF - Som (Hz)	Erro % [VM]*	Erro % [VS]**
0	1797	29,950	106,882	107,273	107,416	0,366	0,500
	1797	29,950	106,882	107,273	107,344	0,366	0,432
	1797	29,950	106,882	107,336	107,407	0,425	0,491
4	1789	29,817	106,407	106,836	106,969	0,403	0,528
	1789	29,817	106,407	106,836	106,969	0,403	0,528
	1790	29,833	106,466	106,961	107,032	0,465	0,532
8	1780	29,667	105,871	106,273	106,406	0,380	0,505
	1780	29,667	105,871	106,273	106,406	0,380	0,505
	1781	29,683	105,931	106,273	106,344	0,323	0,390
12	1774	29,567	105,514	105,835	105,969	0,304	0,431
	1774	29,567	105,514	105,898	106,031	0,364	0,490
	1774	29,567	105,514	105,835	105,969	0,304	0,431
16	1759	29,317	104,622	104,585	104,718	0,035	0,092
	1759	29,317	104,622	104,648	104,718	0,025	0,092
	1759	29,317	104,622	104,585	104,718	0,035	0,092
20	1748	29,133	103,968	103,335	103,468	0,609	0,481
	1747	29,117	103,909	103,335	103,468	0,552	0,424
	1747	29,117	103,909	103,397	103,468	0,493	0,424
				VM (Vibração Mecânica)* VS (Vibração sonora)**			

5.3.2. Comparação de resultados para a falha na pista interna (BPFI)

Na presente seção são apresentados os resultados para as análises dos sinais de vibração e som, referentes à falha na pista interna (BPFI). No gráfico da **Figura 5.14** são apresentadas as frequências características de falha tanto teóricas quanto experimentais. Novamente é possível observar a tendência da redução do valor da FCF à medida que a carga aumenta devido à relação da redução da velocidade no eixo do motor à medida que o torque aumenta.

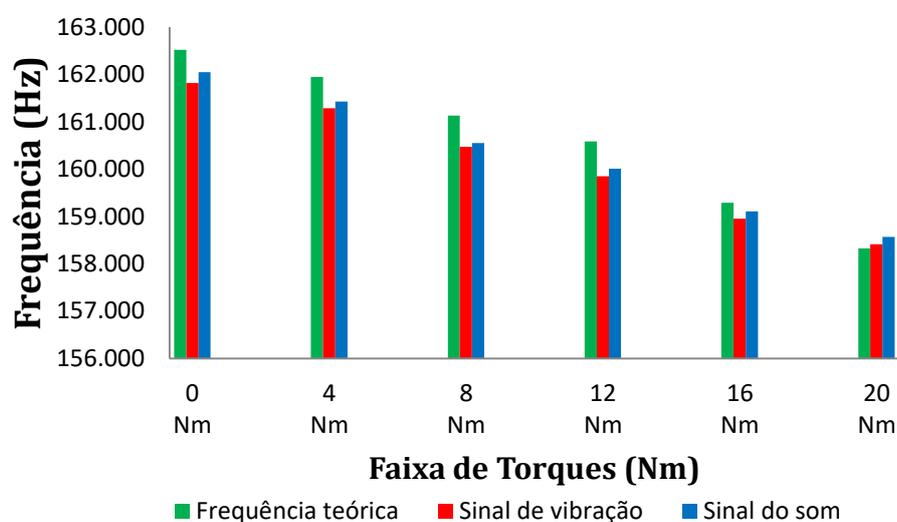


Figura 5.14-Comparação entre as FCFs teóricas e experimentais para falha na pista interna.

Para verificar o grau de relação entre as frequências de falha experimentais e teóricas foi realizada uma regressão linear com o objetivo de verificar a semelhança entre as amostras. Na **Figura 5.15**, item (a), é exibido os resultados para a comparação entre as FCFs experimentais, obtidas através do sinal de vibração, e a FCFs teóricas, obtidas através da Equação 2.2. O coeficiente de determinação R^2 é de 0,985, indicando uma forte relação entre os dados. No item (b) a comparação é feita usando a FCF obtida através da análise dos sinais do som em relação a FCF teórica, para este caso, o coeficiente de determinação (R^2) encontrado é de 0,981, indicando haver também uma forte relação entre os dados teóricos e experimentais. No item (c), uma análise das frequências características de falha experimentais revela uma notável semelhança entre elas. Isso é corroborado pelo coeficiente de determinação (R^2), que se aproxima de 1, atingindo 0,999 neste caso

específico. Essa alta proximidade com o valor máximo sugere uma relação extremamente forte entre os dados experimentais, indicando uma concordância quase perfeita entre eles.

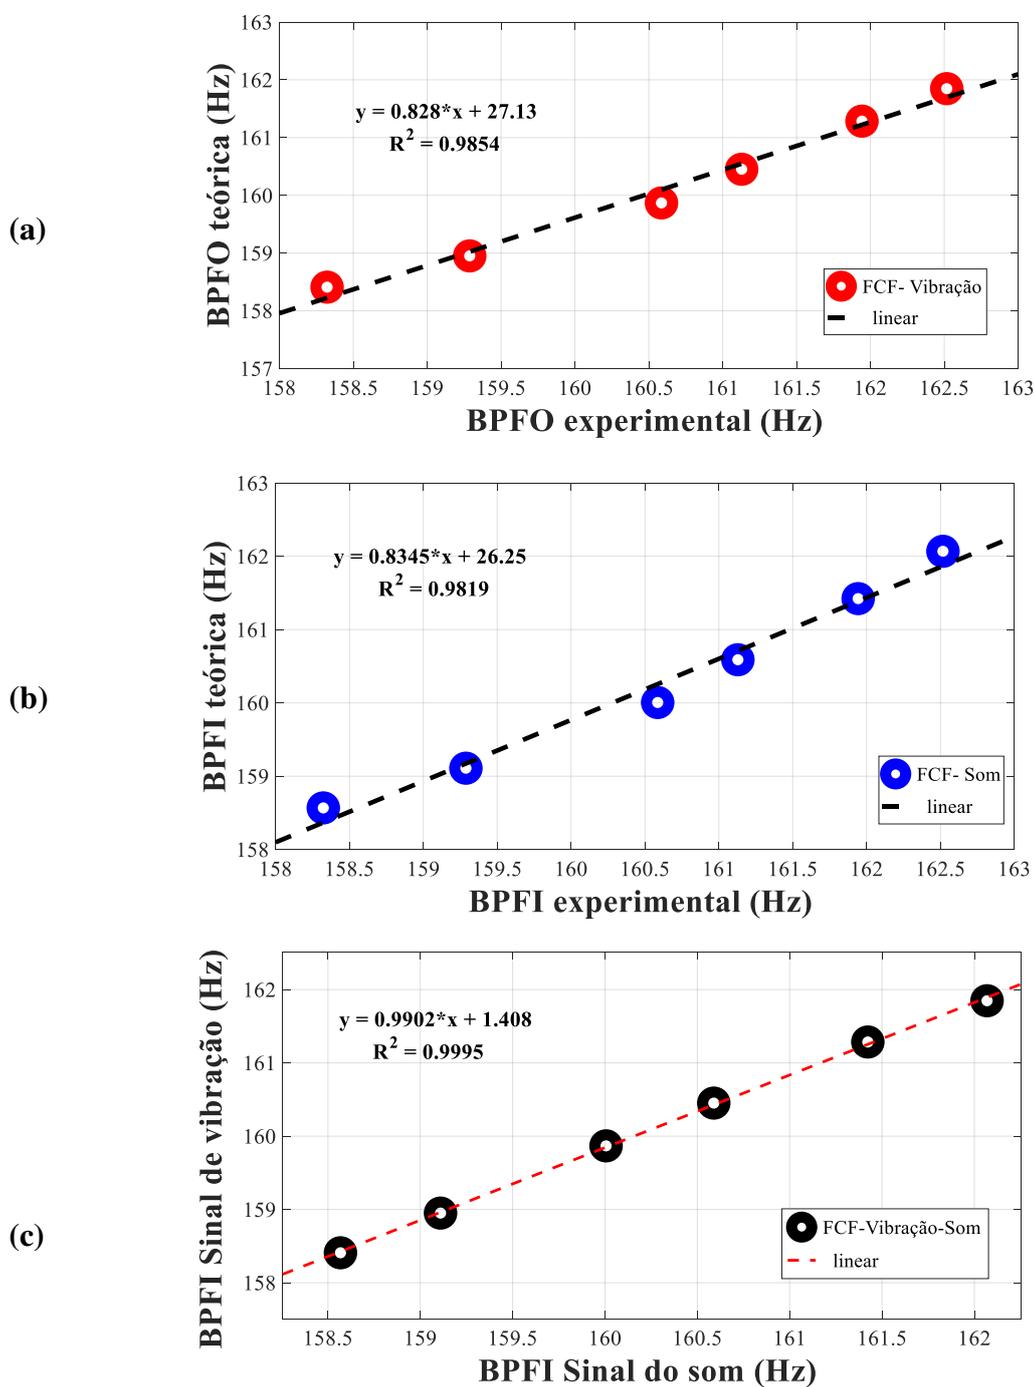


Figura 5.15- Comparação entre as FCF experimentais, obtidas através da análise dos sinais de vibração mecânica e sonora e as FCF teóricas obtidas de forma analítica para falha do tipo BPFi.

Na **Figura 5.16** são apresentados os resultados de comparação para os dados teóricos e experimentais referentes às análises dos sinais de vibração mecânica e sonora. As frequências características de falha obtidas de forma teórica são representadas pela linha verde, já as FCFs experimentais, obtidas através da análise dos sinais de vibração e do som, são representadas pelas linhas de cor vermelha e azul, respectivamente. Percebe-se que para a faixa de 20 N.m ocorre uma interceptação na trajetória dos dados, neste ponto o erro relativo percentual é mínimo, sendo de 0,07 % para as frequências obtidas pela vibração mecânica e 0,15 % para as frequências obtidas pela vibração sonora.

As trajetórias tanto par os dados de vibração quanto para os dados do som são muito semelhantes é fica ainda mais evidenciado ao analisar o gráfico da **Figura 5.15** no item (c), que possui um forte coeficiente de determinação. O erro relativo percentual máximo para os dados teóricos em relação aos dados experimentais da vibração foi de 0,45%, enquanto para os dados experimentais obtidos através da análise do som foi de 0,36 %.

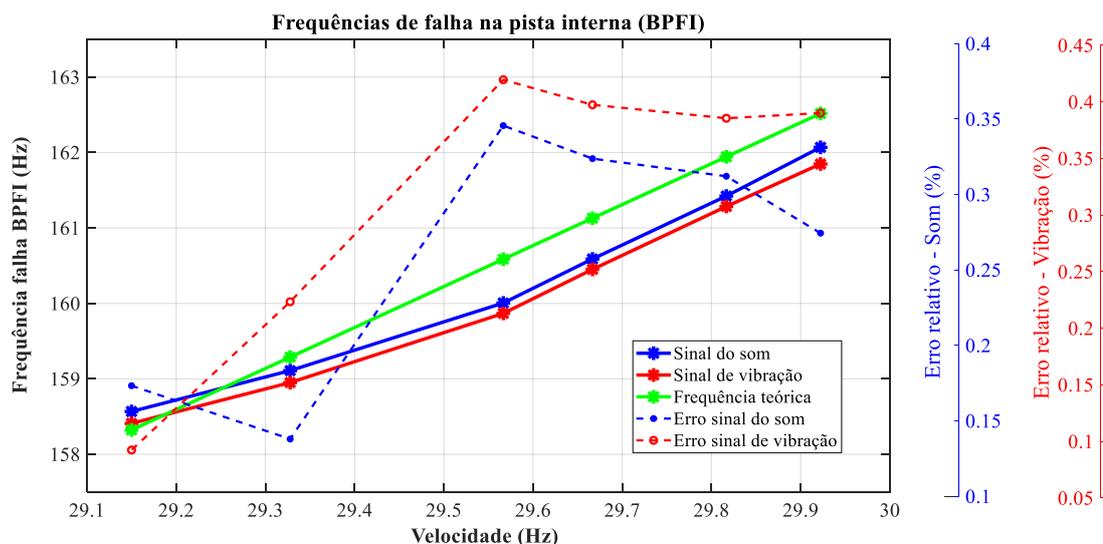


Figura 5.16- Comparação entre os valores teóricos da FCF e os valores experimentais com seus respectivos erros relativos percentuais para uma falha do tipo BPFI.

Os valores teóricos e experimentais, juntamente com os erros relativos percentuais, foram compilados e apresentados na **Tabela 5.12**, abaixo, de forma a melhorar a compreensão e visualização dos dados. Vale ressaltar que os dados apresentados acima foram feitos a partir da média para cada faixa de torque.

Tabela 5.12- Comparação entre as FCFs teóricas e experimentais para defeito na pista interna (BPFI) do rolamento SKF 6206 ZZ com furo de 0.5 mm de diâmetro feito na diagonal

Torque (Nm)	Velocidade (rpm)	Velocidade (Hz)	FCF- teórica (Hz)	FCF- vibração (Hz)	FCF- Som (Hz)	Erro % [VM]*	Erro % [VS]**
0	1796	29,93	162,577	161,785	162,048	0,49	0,33
	1795	29,92	162,487	161,848	162,048	0,39	0,27
	1795	29,92	162,487	161,91	162,11	0,36	0,23
4	1789	29,82	161,943	161,285	161,423	0,41	0,32
	1789	29,82	161,943	161,285	161,423	0,41	0,32
	1789	29,82	161,943	161,285	161,423	0,41	0,32
8	1780	29,67	161,129	160,41	160,547	0,45	0,36
	1780	29,67	161,129	160,472	160,61	0,41	0,32
	1780	29,67	161,129	160,472	160,61	0,41	0,32
12	1774	29,57	160,586	159,91	160,047	0,42	0,34
	1774	29,57	160,586	159,847	159,985	0,46	0,37
	1774	29,57	160,586	159,847	159,985	0,46	0,37
16	1759	29,32	159,228	158,909	159,047	0,20	0,11
	1760	29,33	159,318	159,034	159,172	0,18	0,09
	1760	29,33	159,318	158,909	159,109	0,26	0,13
20	1749	29,15	158,323	158,472	158,609	0,09	0,18
	1749	29,15	158,323	158,472	158,672	0,09	0,22
	1749	29,15	158,323	158,284	158,422	0,02	0,06
						VM (Vibração mecânica)* VS (Vibração sonora)**	

5.4. DETECÇÕES DAS FREQUÊNCIAS DE FALHA POR MEIO DO SINAL DA CORRENTE

O monitoramento dos parâmetros elétricos (tensão e corrente) do MIT é uma ferramenta poderosa na identificação de falhas, tanto elétricas quanto mecânicas. Um dos métodos clássicos baseados na análise da corrente é o método MCSA (*Motor Current Signature Analysis*) e baseia-se na análise da corrente demandada pela máquina em regime permanente (POPALENY e ANTONINO-DAVIU, 2018).

A grande vantagem do método MCSA é sua simplicidade e relativo baixo custo e, a depender do sensor de corrente utilizado pode ser classificado como um método não invasivo. Grande parte dos motores elétricos utilizados na indústria possuem seus circuitos de acionamento e de controle montados em painéis elétricos, a exemplo, do apresentado na **Figura 4.5**. Em alguns casos, dependendo da aplicação, os MITs podem estar inseridos em locais de difícil acesso, como instalações nucleares, compartimentos selados, etc., o que impossibilita a instalação de outros sensores como: acelerômetros, sensores de fluxo magnético, dentre outros. Em tais casos, o monitoramento dos parâmetros elétricos através dos cabos de alimentação do motor é a forma mais viável para o diagnóstico de falhas.

No presente trabalho os sinais de corrente i_a e i_c foram coletados a uma frequência de amostragem de 30 kHz, muito superior a frequência de amplitude máxima do sinal da corrente, que esta em torno de 60 Hz. Desta forma, o teorema da amostragem de Nyquist-Shanon é atendido, tendo em vista que a frequência de amostragem f_s deve ser maior que duas vezes a componente de maior frequência do sinal a ser analisado (LUKE, 1999).

Os valores das Frequências Características de Falhas (FCFs) teóricas que devem aparecer no espectro de potência do sinal de vibração e da corrente foram alocados na Tabela 5.13. Na segunda coluna da tabela a FCF para falha na pista externa do rolamento foi calculada através da Equação (2.6). Na equação são utilizados como parâmetros o número de elementos rolantes (N) do rolamento e a velocidade em Hz no eixo do motor (f_r), assim sendo é possível encontrar a f_{BPFO} . Para o cálculo da FCF utilizando a assinatura da corrente elétrica do motor utiliza-se a Equação (2.5). As equações, para o cálculo das frequências teóricas encontram-se na terceira coluna da Tabela 5.13, os

parâmetros utilizados é a própria frequência característica de falha para defeito na pista externa (f_{BPFO}) e a frequência da rede elétrica (f_s).

Nas seções 5.4.1 e 5.4.2 abaixo, foram computados os valores das frequências de falha até seis vezes a frequência fundamental e analisados os sinais de corrente dos rolamentos com defeito na pista externa (BPFO) e na pista interna (BPFI), ambos com o diâmetro de falha de 0,5 mm com eletrodo inserido na posição diagonal. Para fins de exemplificação, as análises foram realizadas para o motor operando a 0%, 60% e 100% da carga nominal. A análise dos sinais de corrente utilizou a FFT com escala de frequência em dB, já para o janelamento dos sinais foi utilizado uma janela do tipo *Hamming*.

5.4.1. Detecção das frequências de falha na pista externa (BPFO)

Na primeira coleta dos sinais de corrente os sinais das fases i_a e i_c foram adquiridos sob carga a 0% da nominal com uma velocidade de rotação medida no eixo do MIT de 29,95 Hz. A corrente analisada foi à fase i_a , para obter a FCF da primeira componente harmônica calculou-se a f_{BPFO} da seguinte forma:

$$\begin{aligned} f_{BPFO} &= 0.4N_b f_r \\ f_{BPFO} &= 0.4 * 9 * 29,95 \\ f_{BPFO} &= 107,82 \text{ Hz} \end{aligned}$$

Para o método da assinatura da corrente elétrica do motor, utiliza-se o valor da frequência de falha encontrada anteriormente com acréscimo da frequência da rede elétrica f_s . Geralmente são associadas duas componentes harmônicas, uma que decresce com a frequência da rede elétrica e outra que cresce.

$$\begin{aligned} f_{falha_Rolamento} &= |f_s \pm k f_{BPFO}| \\ f_{falha_Rolamento} &= |60 \pm 107,82| \\ f_{falha_Rolamento1} &= 167,82\text{Hz} \\ f_{falha_Rolamento2} &= 47,82\text{Hz} \end{aligned}$$

As demais frequências característica de falha utilizando MCSA podem ser encontradas seguindo as fórmulas descritas na coluna 3 da **Tabela 5.13**.

Tabela 5.13- Frequências características de falha para defeito na pista externa usando MCSA para 0% da carga nominal.

FCF no espectro de vibração (Hz)	Frequência teórica espectro vibração (Hz)	FCF no espectro de corrente (Hz)	Frequência teórica espectro da corrente (Hz)
$1 \times f_{BPFO}$	107,82	$ f_s + f_{BPFO} $	167,82
$2 \times f_{BPFO}$	215,64	$ f_s - f_{BPFO} $	47,82
$3 \times f_{BPFO}$	323,46	$ f_s + 2f_{BPFO} $	275,64
$4 \times f_{BPFO}$	431,28	$ f_s - 2f_{BPFO} $	155,64
$5 \times f_{BPFO}$	539,1	$ 3f_s - f_{BPFO} $	72,18
$6 \times f_{BPFO}$	646,92	$ 5f_s + f_{BPFO} $	407,82
Carga: 0%		Velocidade medida: 29,95 Hz	

Na **Figura 5.17** é possível visualizar algumas faixas verticais que tem como propósito destacar a localização das frequências de falha teórica, as componentes de frequência vão até seis vezes a frequência de falha fundamental. A frequência da rede elétrica f_s pode ser facilmente identificada, sendo esta de 59,93 Hz, é justamente o ponto de maior amplitude do sinal no domínio da frequência, e está próximo do valor teórico da frequência de energia elétrica distribuída no Brasil que é de 60 Hz.

No espectro duas bandas laterais também se fazem presentes, a primeira banda, de maior amplitude, corresponde a $(f_s - f_r)$ que se refere à frequência da rede elétrica menos a velocidade de rotação no eixo do MIT em Hz. É possível estimar a velocidade no eixo do motor através dos valores da amplitude desses dois picos. Para este caso a velocidade medida no eixo do motor foi de 29,95 Hz, utilizando a equação acima a velocidade estimada é de: $(59,9375 - 30)$, que resulta em $29,9375$ Hz, muito próximo do valor medido. As frequências subsequentes em destaque correspondem a: $3f_s, 4f_s, 7f_s$, múltiplas da frequência da rede elétrica.

No espectro da corrente em análise não foram observados picos com frequências que correspondam às frequências teóricas de falha, destacadas pelas linhas tracejadas. Algumas hipóteses podem ser levantadas quanto à ausência das FCFs no espectro, a primeira hipótese diz respeito à região de operação do motor: nesta aquisição a velocidade de operação foi próxima à velocidade síncrona do MIT que é de 1800 rpm, nessa região é difícil à identificação de falhas em rolamentos, devido, sobretudo, as condições de ausência de carga, haja vista que os rolamentos de esferas utilizados em motores elétricos tendem a atuar de melhor forma quando submetidos a atuação de cargas radiais, fazendo

com que o impacto dos elementos rolantes ao passar pela falha sejam amplificados. A segunda hipótese concerne à resolução dos sensores de corrente, os sensores utilizados foram do tipo *Hall* especificamente o modelo ACS712 de 30 A. Como o motor da bancada possui uma corrente nominal de 8.19 A seria mais indicado o modelo de sensor ACS712 de 20 A o que possibilitaria um maior ganho de resolução.

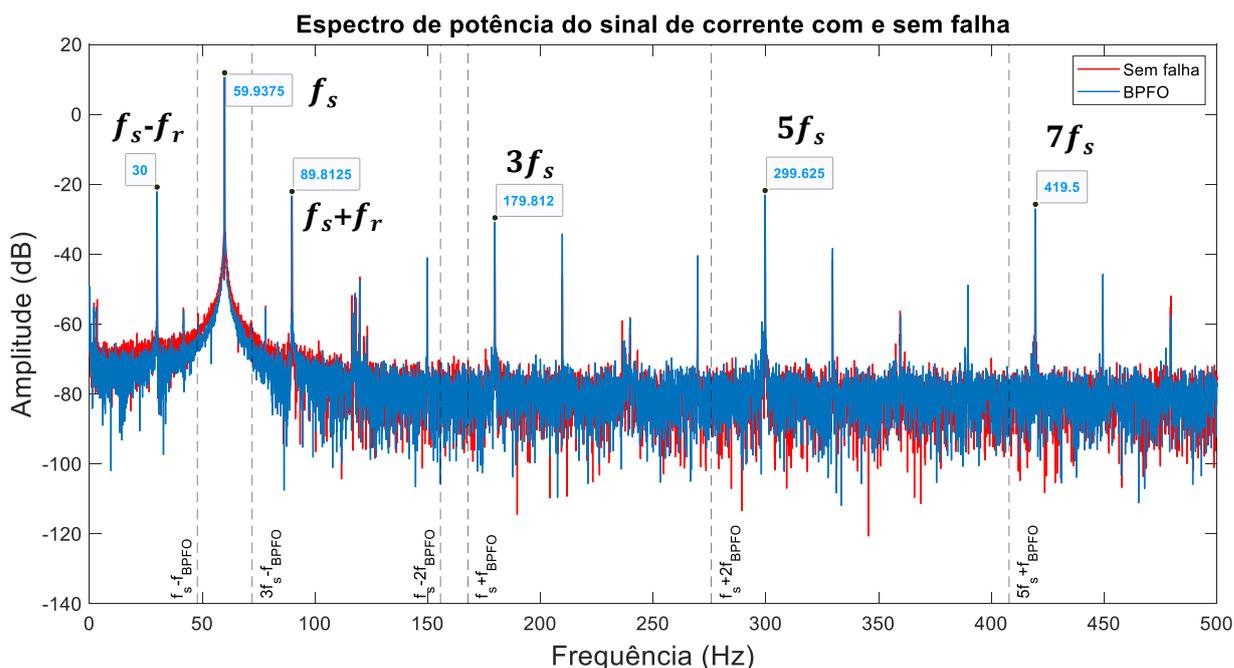


Figura 5.17-Espectro de frequência do sinal de corrente com e sem falha para 0% da carga nominal.

A segunda aquisição foi realizada com o motor operando a uma carga de 60% da carga nominal e a uma velocidade de rotação de 29,56 Hz medida no eixo do MIT. Na Tabela 5.14, os valores teóricos das frequências características de falha na pista externa do rolamento (f_{BPFO}) foram organizados, a terceira coluna descreve as fórmulas que devem ser empregadas para o computo das FCF até $6 \times f_{BPFO}$.

Tabela 5.14- Frequências características de falha para defeito na pista externa usando MCSA para 60% da carga nominal

FCF no espectro de vibração (Hz)	Frequência teórica espectro vibração (Hz)	FCF no espectro de corrente (Hz)	Frequência teórica espectro da corrente (Hz)
$1 \times f_{BPFO}$	106,416	$ f_s + f_{BPFO} $	166,416
$2 \times f_{BPFO}$	212,832	$ f_s - f_{BPFO} $	46,416

$3 \times f_{BPFO}$	319,248	$ f_s + 2f_{BPFO} $	272,832
$4 \times f_{BPFO}$	425,664	$ f_s - 2f_{BPFO} $	152,832
$5 \times f_{BPFO}$	532,08	$ 3f_s - f_{BPFO} $	73,584
$6 \times f_{BPFO}$	638,496	$ 5f_s + f_{BPFO} $	406,416
Carga: 60%		Velocidade medida: 29,56 Hz	

Os espectros de potência do sinal da corrente com e sem falha são mostrados na **Figura 5.18**. Para esta aquisição a velocidade medida foi de 1774 rpm, já utilizando o método descrito anteriormente subtraindo-se $(59,95-30,35) \times 60$, o valor da velocidade estimado foi de 1776 rpm, dessa forma o método empregado fornece um bom indicativo da possibilidade de estimar a velocidade de forma *online* em motores de indução trifásicos tipo gaiola de esquilo.

Ao analisar os espectros dos sinais foram notados picos próximos às frequências de falhas teóricas. Seguindo a sequência das frequências de falhas descritas na terceira coluna da Tabela 5.14, e analisando o espectro de frequência da **Figura 5.18**, foi possível verificar picos de frequência que se aproximam das frequências teóricas, o que seria um forte indicativo de falha, entretanto ao analisar mais detalhadamente, percebe-se que o sinal de corrente para o rolamento saudável também apresenta picos nessa faixa de frequência como, por exemplo, para a frequência $5f_s + f_{BPFO}$.

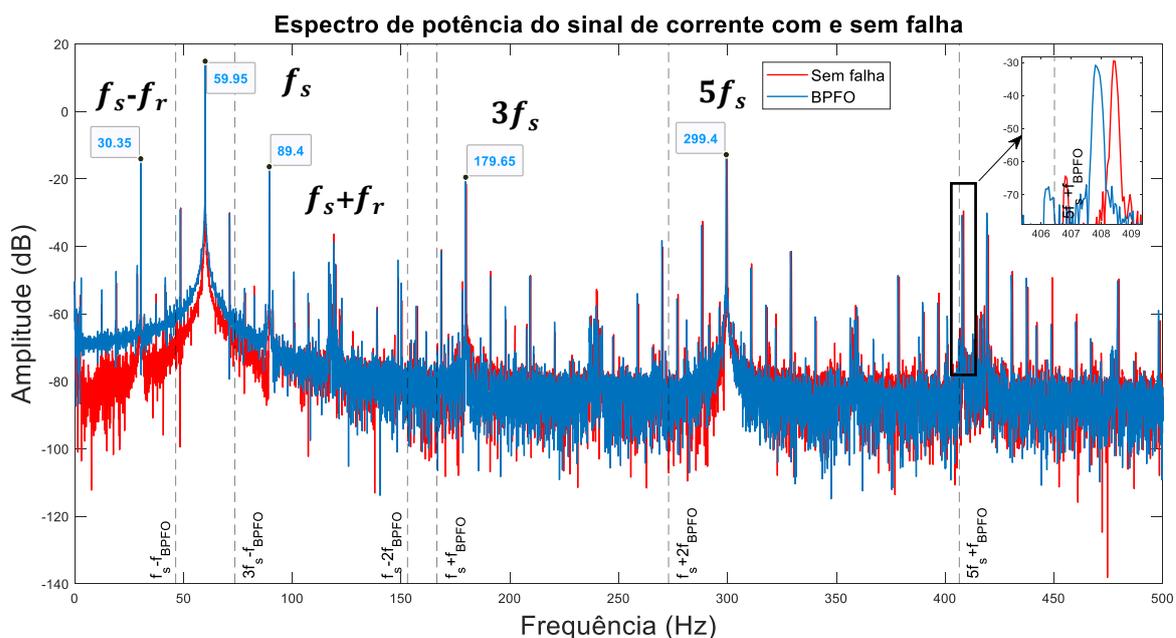


Figura 5.18-Espectro de frequência do sinal de corrente com e sem falha para 60% da carga nominal.

A terceira aquisição foi realizada tendo como parâmetro de referência uma carga aplicada ao eixo do MIT de 100% do torque nominal, nesta faixa de torque o escorregamento do motor ficou a velocidade de rotação no eixo do motor foi de 1748 rpm. Na Tabela 5.15 são apresentados os valores das FCFs para falha na pista externa.

Tabela 5.15- Frequências características de falha para defeito na pista externa usando MCSA para 100% da carga nominal

FCF no espectro de vibração (Hz)	Frequência teórica espectro vibração (Hz)	FCF no espectro de corrente (Hz)	Frequência teórica espectro da corrente (Hz)
$1 \times f_{BPFO}$	104,868	$ f_s + f_{BPFO} $	164,868
$2 \times f_{BPFO}$	209,736	$ f_s - f_{BPFO} $	44,868
$3 \times f_{BPFO}$	314,604	$ f_s + 2f_{BPFO} $	269,736
$4 \times f_{BPFO}$	419,472	$ f_s - 2f_{BPFO} $	149,736
$5 \times f_{BPFO}$	524,34	$ 3f_s - f_{BPFO} $	75,58
$6 \times f_{BPFO}$	629,208	$ 5f_s + f_{BPFO} $	404,868
Carga: 100%		Velocidade medida: 1748 rpm \cong 29,13 Hz	

A análise espectral dos sinais de corrente com e sem falha são apresentados no gráfico da **Figura 5.19**. Observando as FCFs, destacadas por linhas tracejadas verticais, e comparando com o sinal com falha (em azul) não foi possível verificar a coincidência das frequências de falhas teóricas. Quando o motor opera fora da região de torque para o qual foi dimensionado, surgem não linearidades. Essas não linearidades são capazes de interferir no sinal da corrente do motor de indução, podendo mascarar a presença de falhas.

Analisando o espectro do sinal não é possível identificar picos de frequência que coincidam com as frequências fundamentais, $f_s + f_{BPFO}$ e $f_s - f_{BPFO}$, tracejadas no gráfico. Existe, porém, um pico de frequência em $f_s + f_{BPFO}$, de 270,688 Hz muito próximo a frequência característica de falha teórica, que é de 269,737 Hz, entretanto não há como comprovar tratar-se de uma frequência que possa caracterizar falha na pista externa, tendo em vista a ausência de outros picos de frequência próximos as FCFs teóricas.

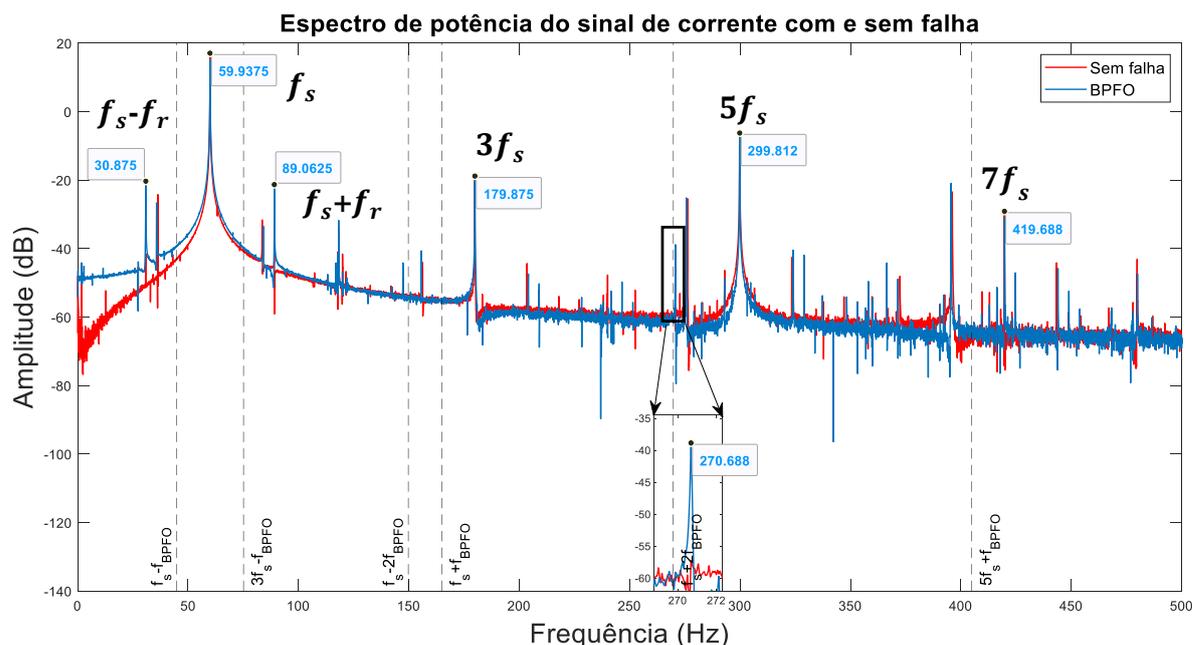


Figura 5.19-Espectro de frequência do sinal de corrente com e sem falha para 100% da carga nominal.

5.4.2. Detecção das frequências de falha na pista interna (BPFI)

Para caracterizar as frequências de falha na pista interna, a Equação (2.7) e a Equação (2.5) foram utilizadas. A primeira aquisição para o motor operando a 0% da sua carga nominal a velocidade de rotação medida no eixo do motor foi de 1796 rpm, ou 29,93 Hz, dispondo desses valores e da geometria do rolamento do motor (modelo 6206 ZZ), é possível calcular a frequência teórica da falha. Logo, pela Equação (2.7), tem-se que:

$$f_{BPFO} = 0.6N_b f_r$$

$$f_{BPFO} = 0.6 * 9 * 29,93$$

$$f_{BPFO} = 161,622 \text{ Hz}$$

As duas frequências de falha fundamentais podem ser encontradas pela seguinte expressão:

$$f_{falha_Rolamento} = |f_s \pm k f_{BPFO}|$$

$$f_{falha_Rolamento} = |60 \pm 161,622|$$

$$f_{falha_Rolamento1} = 221,622 \text{ Hz}$$

$$f_{falha_Rolamento2} = 101,622 \text{ Hz}$$

Na Tabela 5.16 são exibidas as equações e as frequências características de falha utilizadas para caracterizar a falha na pista interna do rolamento por meio do método da análise de assinatura da corrente do motor (MCSA).

Tabela 5.16- Frequências características de falha para defeito na pista interna usando MCSA para 0% da carga nominal.

FCF no espectro de vibração (Hz)	Frequência teórica espectro vibração (Hz)	FCF no espectro de corrente (Hz)	Frequência teórica espectro da corrente (Hz)
$1 \times f_{BPFO}$	161,622	$ f_s + f_{BPFO} $	221,622
$2 \times f_{BPFO}$	323,244	$ f_s - f_{BPFO} $	101,622
$3 \times f_{BPFO}$	484,866	$ f_s + 2f_{BPFO} $	383,244
$4 \times f_{BPFO}$	646,488	$ f_s - 2f_{BPFO} $	263,244
$5 \times f_{BPFO}$	808,11	$ 3f_s - f_{BPFO} $	18,378
$6 \times f_{BPFO}$	969,732	$ 5f_s + f_{BPFO} $	461,622
Carga: 0%		Velocidade medida: 29,93 Hz	

Na **Figura 5.20** apresenta-se o espectro dos sinais de corrente sem e com falha na pista interna (BPFI). Ao analisar os picos de frequência dos sinais, especialmente para as frequências características de falha $|f_s + f_{BPFO}|$ e $|f_s - f_{BPFO}|$ não se observa nenhum pico de frequência que corresponda à frequência teórica, nem mesmo em seus múltiplos. Não sendo possível a caracterização do defeito na pista interna.

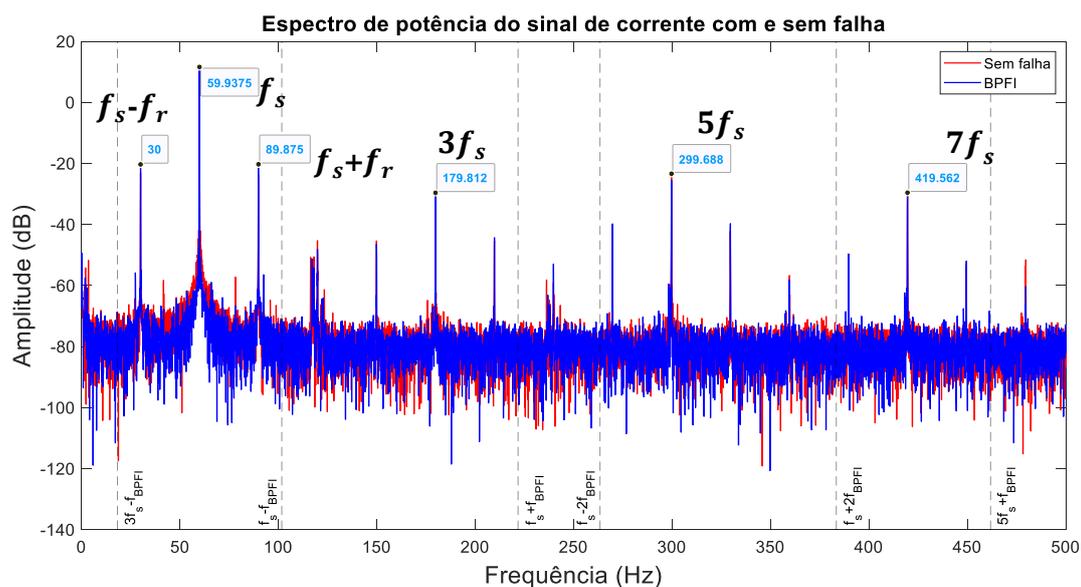


Figura 5.20-Espectro de frequência do sinal de corrente com e sem falha para 0% da carga nominal.

Para o motor operando a 60% da sua carga nominal a velocidade de rotação medida no eixo foi de 1774 rpm ou 29,57 Hz aproximadamente. Na Tabela 5.17 são exibidos os cálculos para as frequências características de falha até a sexta harmônica.

Tabela 5.17-Frequências características de falha para defeito na pista interna usando MCSA para 60% da carga nominal.

FCF no espectro de vibração (Hz)	Frequência teórica espectro vibração (Hz)	FCF no espectro de corrente (Hz)	Frequência teórica espectro da corrente (Hz)
$1 \times f_{BPFO}$	159,678	$ f_s + f_{BPFO} $	219,678
$2 \times f_{BPFO}$	319,356	$ f_s - f_{BPFO} $	99,678
$3 \times f_{BPFO}$	479,034	$ f_s + 2f_{BPFO} $	379,356
$4 \times f_{BPFO}$	638,712	$ f_s - 2f_{BPFO} $	259,356
$5 \times f_{BPFO}$	798,39	$ 3f_s - f_{BPFO} $	20,322
$6 \times f_{BPFO}$	958,068	$ 5f_s + f_{BPFO} $	459,678
Torque: 60%		Velocidade medida: 29,57 Hz	

Na **Figura 5.21** os espectros da corrente do rolamento saudável e com falha na pista interna são confrontados, observa-se que há correspondências entre as frequências características de falha, de linhas tracejadas, com picos de frequência que estão naquela faixa. Ao analisar com mais detalhes percebe-se que estes picos de frequência aparecem

tanto para o sinal com falha quanto para o sinal sem falha na pista interna (BPFI), como por exemplo, a coincidência que aparece na faixa de frequência em $|f_s + 2f_{BPFO}|$. A caracterização da falha fica comprometida, pois em ambos os sinais há coincidência com a FCF teórica.

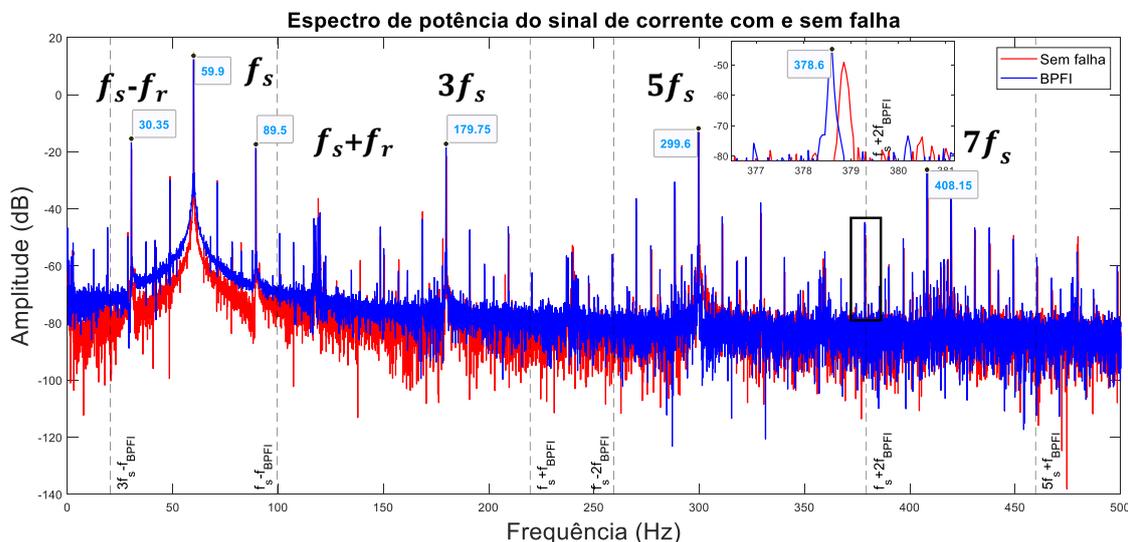


Figura 5.21-Espectro de frequência do sinal de corrente com e sem falha para 60% da carga nominal.

A terceira análise, para o motor operando a 100% da carga nominal, a velocidade de rotação medida na ponta do eixo foi de 1748 rpm, aproximadamente 29,13 Hz. Para esta velocidade e considerando a geometria do rolamento a frequência teórica de falha para $|f_s + f_{BPFO}|$ é de 217,302 Hz, já para $|f_s - f_{BPFO}|$ a frequência é de 97,302 Hz. Tais dados foram compilados na Tabela 5.18, especificamente na quarta coluna, que corresponde a frequência teórica obtida através do espectro da corrente.

Tabela 5.18-Frequências características de falha para defeito na pista interna usando MCSA para 100% da carga nominal.

FCF no espectro de vibração (Hz)	Frequência teórica espectro vibração (Hz)	FCF no espectro de corrente (Hz)	Frequência teórica espectro da corrente (Hz)
$1 \times f_{BPFO}$	157,302	$ f_s + f_{BPFO} $	217,302
$2 \times f_{BPFO}$	314,604	$ f_s - f_{BPFO} $	97,302
$3 \times f_{BPFO}$	471,906	$ f_s + 2f_{BPFO} $	374,604
$4 \times f_{BPFO}$	629,208	$ f_s - 2f_{BPFO} $	254,604
$5 \times f_{BPFO}$	786,51	$ 3f_s - f_{BPFO} $	22,698
$6 \times f_{BPFO}$	943,812	$ 5f_s + f_{BPFO} $	457,302

Torque: 100%	Velocidade medida: 29,13 Hz
--------------	-----------------------------

Ao examinar as linhas tracejadas na **Figura 5.22**, que representam as frequências teóricas, e os espectros dos sinais de corrente, não é possível identificar picos de frequência coincidentes que sugiram a presença de uma falha na pista interna.

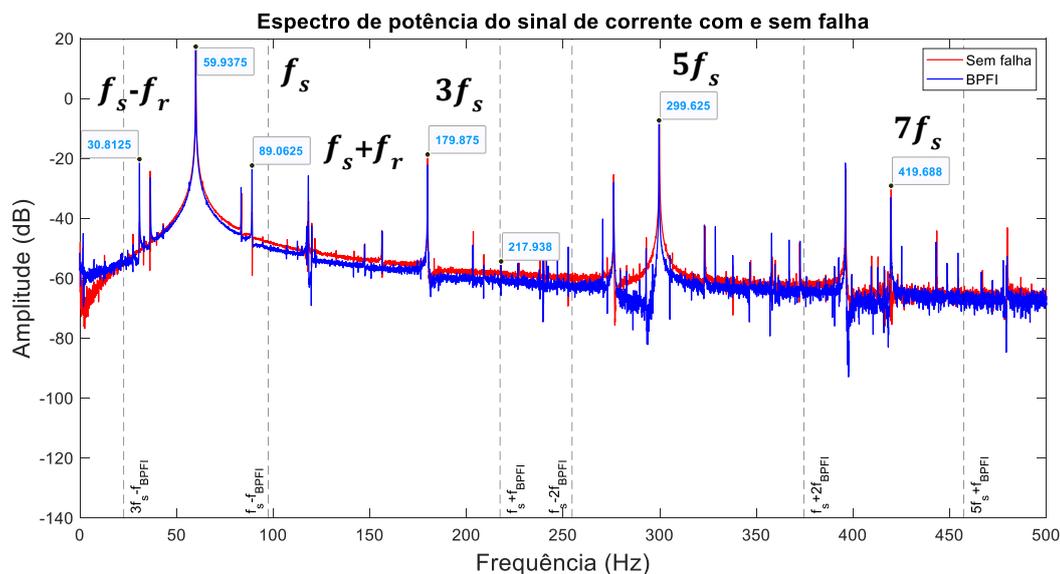


Figura 5.22 -Espectro de frequência do sinal de corrente com e sem falha para 100% da carga nominal.

Não foi possível caracterizar as frequências de falhas nos rolamentos utilizando o método MCSA. Embora o método utilizando a assinatura da corrente do estator do MIT seja bem definido e a caracterização das frequências de falhas seja relativamente simples, nem sempre é possível detectar as FCFs presentes nos rolamentos. Um dos fatores preponderantes é o nível da severidade da falha, seja na pista externa, interna, ou em seus elementos rolantes. Outro fator importante está associado à forma como a carga é aplicada ao motor, se a carga estiver sendo exercida no sentido radial há uma melhor possibilidade de obter sucesso no processo de caracterização das frequências de falha.

5.5. MÉTODO PROPOSTO SAC-DM

Nesta seção são apresentados os resultados acerca do novo método proposto para detecção de falhas em rolamentos, tendo por base à técnica SAC-DM, onde foi utilizado o sinal da corrente elétrica do motor de indução trifásico. O estudo tem por base teórica o

trabalho desenvolvido por BASEIA *et al.* (2017), demonstrado na seção 3.6.4. Os passos seguem a metodologia adotada na **Figura 4.27**.

Inicialmente os sinais de corrente elétrica das fases i_a e i_c do MIT são somados, dando origem a um novo sinal. A partir do novo sinal resultante da soma das correntes retira-se o sinal do envelope. Na **Figura 5.23** é possível observar o processo de soma das correntes até a extração do envelope do sinal resultante. O sinal do envelope constitui a base inicial do estudo, tendo em vista que é a partir dele que a Técnica SAC-DM é aplicada. Contudo, antes de aplicar o SAC-DM, é necessário realizar algumas etapas, com o objetivo de verificar se o sinal é de fato caótico.

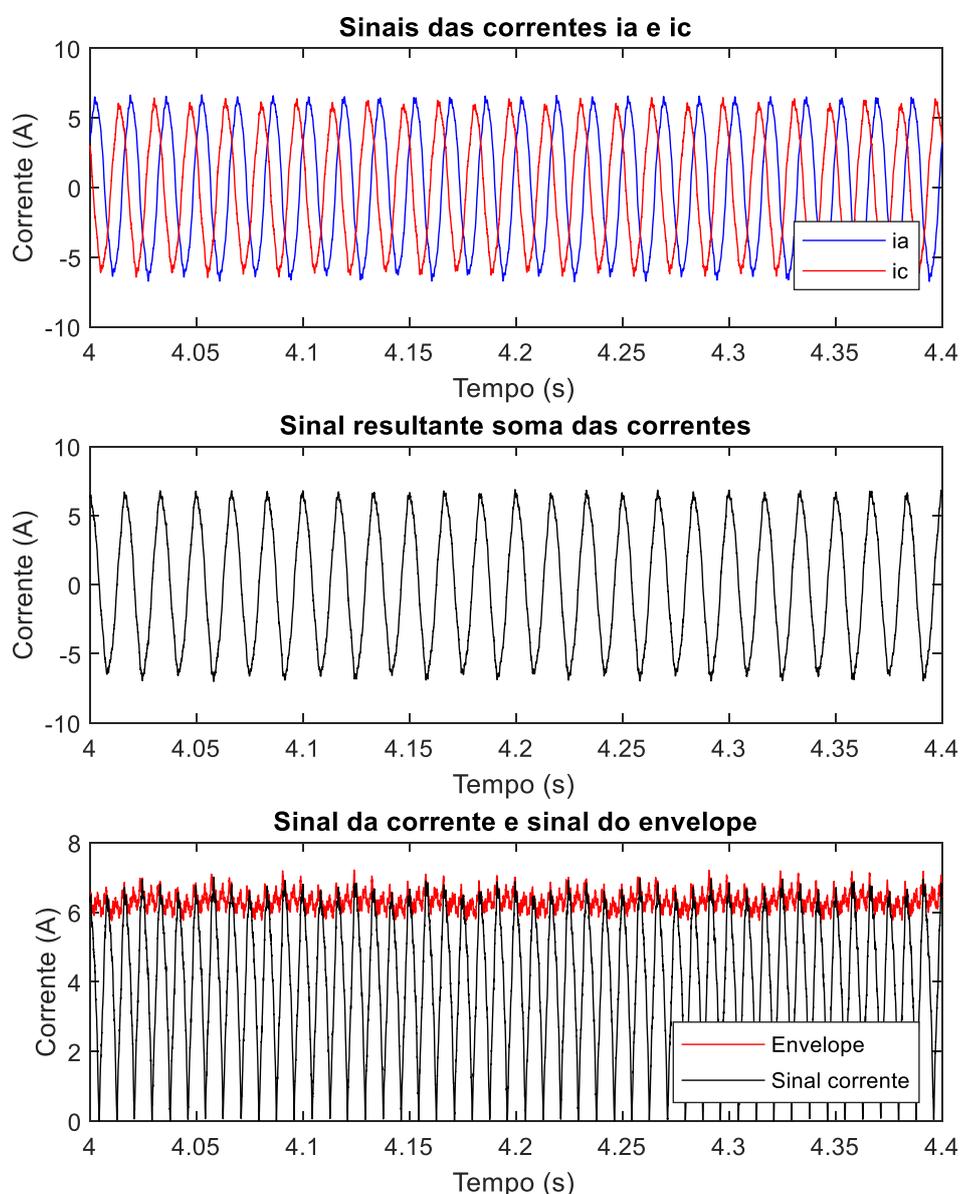


Figura 5.23-Soma dos sinais de corrente i_a e i_c e extração do envelope do sinal resultante. Motor operando a 20% da carga nominal.

Para verificar se uma série temporal possui comportamento caótico determinístico, recomenda-se a caracterização para verificar, inicialmente, se ela é determinística. A fim de analisar o sinal do envelope e verificar se ele é determinístico ou estocástico foi utilizado o teste da árvore de símbolos. Esta é uma etapa que se complementa com o teste de correlação e o teste 0-1 para verificar se o sinal de fato é caótico. Os testes são abordados nos tópicos abaixo.

5.5.1. Teste da árvore de símbolos

O teste realizado consiste em analisar um trecho do sinal do envelope obtido através do sinal da corrente. O número de pontos para análise no teste foi de $N=20.000$, o que corresponde a pouco menos de um segundo, já o comprimento da partição foi definindo para $l=1000$ e o agrupamento das “palavras” foi definido para um $L=6$, vale ressaltar que $2^L \ll l$. Dito isso, o gráfico terá 64 palavras com 20 espectros sobrepostos e pode ser observado na **Figura 5.24**.

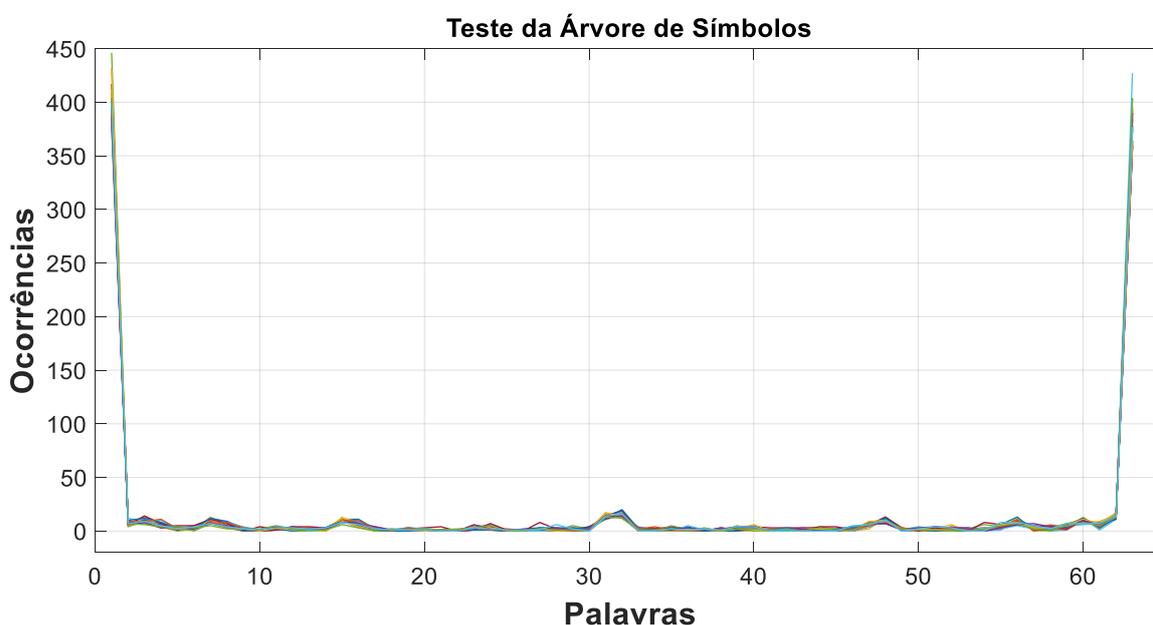


Figura 5.24- Teste árvore de símbolos para o sinal da corrente do MIT

A escolha de 20 espectros se baseia em pesquisas anteriores (KULP e ZUNINO, 2014; KULP e SMITH, 2011), segundo os autores 20 espectros tendem a ser suficientes para determinar se os espectros são semelhantes ou não. Caso poucos espectros sejam utilizados será difícil distinguir se uma série é determinística ou estocástica, devido à

dificuldade em estabelecer um padrão ou falta dele entre os espectros. Já se o número de partições for muito grande o comprimento da partição pode ser muito curto para produzir um espectro confiável. O sinal analisado apresenta formação de um padrão com os espectros sobrepostos e similares o que caracteriza a série temporal como sendo determinística.

5.5.2. Teste 0-1

O teste 0-1 é um método intuitivo para verificar se uma série temporal é ou não caótica, os conceitos do método podem ser compreendidos com maiores detalhes na seção 3.6.2. Além do teste 0-1 existem outros métodos que podem ser utilizados para caracterizar uma série temporal entre dinâmicas determinísticas e caóticas, a exemplo do método que trata do cálculo do expoente máximo de Lyapunov. Outro método é o espectro de potência, entretanto, segundo GOTTWALD e MELBOURNE (2009), essa técnica se baseia no teorema de Wiener-Khintchine, que assume um decaimento somatório de correlação e, portanto, exclui dinâmicas periódicas ou quasi-periódicas.

Ainda de acordo com os autores, aludidos no parágrafo acima, um dos problemas inerentes que afetam todos os testes de caos diz respeito ao tamanho da amostra, de modo que o tamanho da série temporal precisa ser longa o suficiente para explorar e amostrar a área dos espaço de fase relevante (ou seja, o atrator). No teste 0-1 a definição do deslocamento quadrado médio envolve um limite que requer $n \ll N$, de tal forma que $n < n_{cut} = N/10$, sendo N o tamanho da série temporal e n a décima parte relativa ao comprimento da série (neste caso o sinal do envelope da corrente de uma das fases do MIT).

Para este teste também foi utilizado um número de pontos $N=20.000$, de tal forma que $n=2.000$. Para evitar que ressonâncias distorçam as estatísticas vários valores de “ c ” (sendo $c \in (0, \pi)$) escolhidos aleatoriamente precisam ser executados, na prática 100 valores de c são suficientes, desde que obedeça a restrição do intervalo $\pi/5 < c < 4\pi/5$ (GOTTWALD e MELBOURNE, 2016).

O valor da mediana dos Kc 's resulta em k que é o resultado final da caracterização, a escolha da mediana é utilizada para suprimir quaisquer ressonâncias que podem não ter sido evitadas na determinação do intervalo restrito em c (KULP e SMITH, 2011). Na

Figura 5.25 verifica-se o gráfico do teste 0-1 para o sinal da corrente, no qual os valores de Kc estão muito próximos de 1 para todos os valores de c . Para um valor de K maior que 1 implica que o sistema estará sob efeito de comportamento ressonante, o que compromete o resultado do teste (LUCENA-JUNIOR *et al.*, 2020). O valor da mediana dos pontos de Kc foi de 0,9984, o que comprova que o comportamento do sinal do envelope da corrente do motor de indução trifásico é caótico.

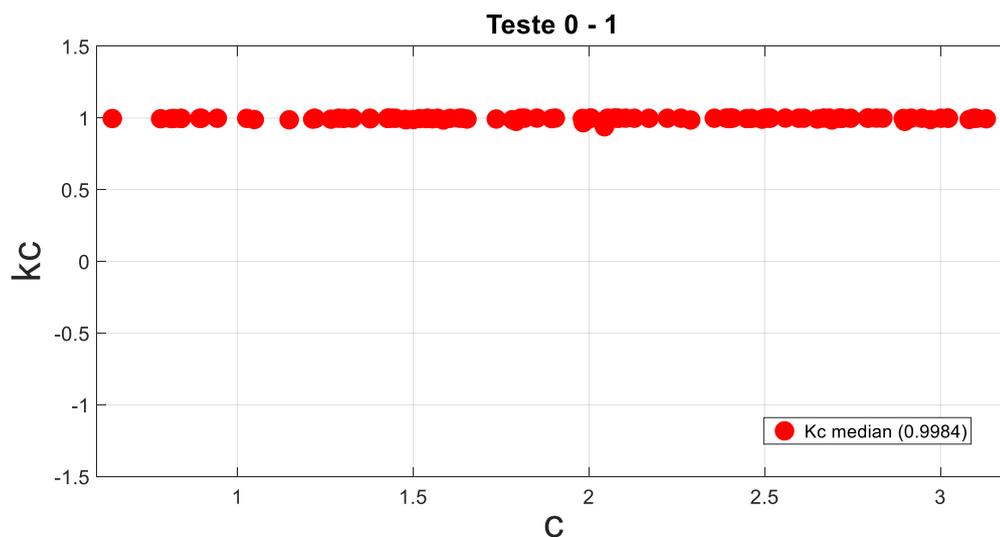


Figura 5.25- Teste 0-1 para o sinal da corrente do motor de indução trifásico.

5.5.3. Teste da autocorrelação para o caos

No presente tópico são apresentados alguns resultados acerca do teste para o caos utilizando o sinal do envelope da corrente elétrica do MIT. Nesta abordagem foi utilizado o método da autocorrelação. O método da autocorrelação juntamente com o método do espectro de potências são dois métodos utilizados na análise de sinais experimentais, possibilitando a identificação de processos regulares, distinguindo-os daqueles caóticos ou estocásticos (FIEDLER-FERRARA e DO PRADO, 1994).

As amostras do sinal foram selecionadas para uma análise de 33 segundos, totalizando $N = 9,9 \times 10^5$ pontos, os resultados das análises estão ilustrados na **Figura 5.26**, na qual são apresentados os resultados do teste de autocorrelação para os 12 sinais analisados, estes sinais correspondem a: três sinais para falha do tipo BPFI, três sinais para falha BPFO, três para falha mista e três para o rolamento saudável.

De forma simplificada a função de autocorrelação mede o grau de semelhança existente no sinal consigo mesmo ao longo do tempo. Caso o sinal seja periódico ou *quasi*-periódico a função de autocorrelação tende a permanecer diferente de zero. Em contrapartida para um sinal caótico ou sinal multi-periódico com diversas frequências independentes a semelhança do sinal consigo mesmo tende a zero ao longo do tempo. Vale ressaltar, contudo, que o método clássico da autocorrelação não permite, para fins gerais, distinguir uma dinâmica caótica determinística de um comportamento estocástico, sendo sugerido ao menos o uso de mais um método que auxilie na caracterização do sinal para comprovar seu comportamento caótico. Assim sendo, foram adotados também os métodos do teste da árvore de símbolos e o teste 0-1, explanados acima.

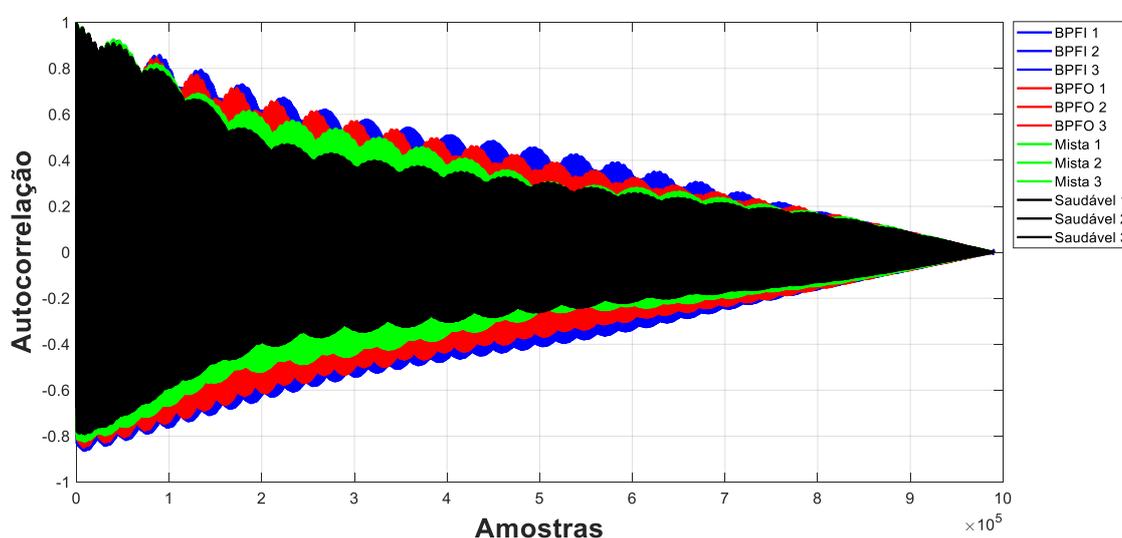


Figura 5.26- Função de autocorrelação para o sinal da corrente do MIT, sem falha e com falha na pista externa do rolamento.

Considerando a tendência dos sinais convergirem para uma autocorrelação próxima de zero ao longo do tempo, fica claro que se trata de um sinal com dinâmica caótica. Esse resultado é corroborado pela análise do teste 0-1, que também confirma a natureza caótica do sinal.

Em seu trabalho DE DEUS *et al.* (2020) utilizando a análise do sinal da corrente elétrica do estator para diagnosticar barras quebradas no motor de indução trifásico, por meio da teoria do caos usando o método SAC-DM, comprovou que o sinal da corrente do MIT possui uma dinâmica caótica determinística.

5.5.4. Detecção das falhas pelo método SAC-DM.

Neste item, serão apresentados os resultados do novo método proposto, utilizando SAC-DM em conjunto com redes Neurais Artificiais. O objetivo é de demonstrar o potencial da nova técnica no diagnóstico de falhas em rolamentos de motores de indução trifásicos.

Seguindo o roteiro delineado na metodologia apresentada na seção 4.3.2 e representada na **Figura 4.27**, foram utilizadas duas das três fases de alimentação do Motor de Indução Trifásico (MIT) sendo elas: a fase i_a e a fase i_c . A frequência de amostragem empregada nas aquisições foi de 30 kHz. Foi utilizado o processo de partida direta para acionar o MIT. Cargas foram aplicadas ao eixo, abrangendo valores desde um torque nulo até o torque nominal do MIT. As cargas utilizadas foram: 0%, 20%, 40%, 60%, 80% e 100% da carga nominal.

A técnica SAC-DM utiliza a contagem de picos (Máximos do sinal) para calcular o ρ experimental (densidade de máximos) conforme a Equação (3.55). Para fins de exemplificação, na **Figura 5.27** é ilustrado um pequeno trecho do sinal do envelope, obtido a partir dos sinais das correntes do MIT, para uma faixa de 20% da carga nominal ou 4 Nm. Na figura é possível visualizar uma pequena parcela do sinal com um intervalo $\delta t = 1$ segundos, para este intervalo de tempo (utilizando a função *findpeaks* do Matlab) foram contabilizados 1723 picos.

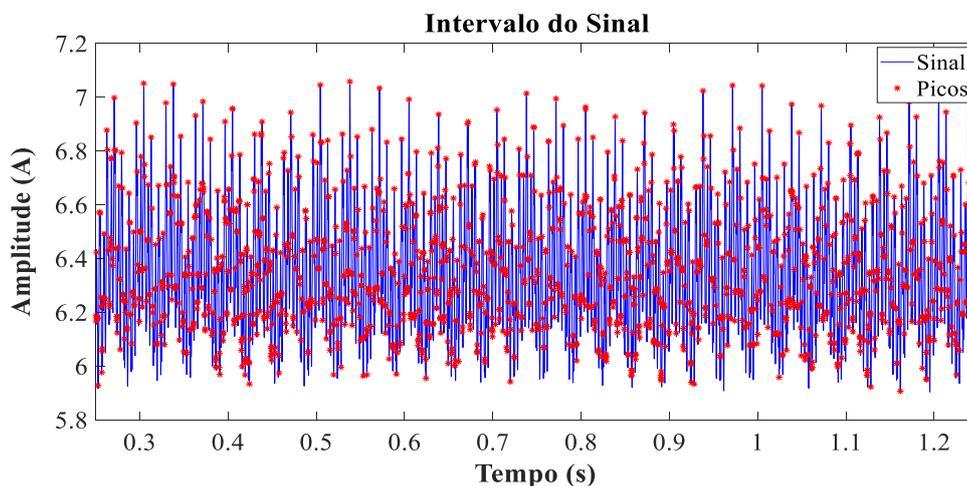


Figura 5.27 - Sinal do envelope e detecção dos picos

Mediante o número da quantidade de picos contabilizados em um determinado intervalo de tempo é possível através da Equação (3.55) calcular a densidade de máximos experimental, conforme a relação:

$$SAC - DM = \frac{\text{Total de picos no intervalo}}{\text{tempo do intervalo}} = \frac{\sum \text{picos}}{\Delta t}$$

$$\frac{1723}{1} = 1736 \text{ picos/segundo}$$

Para aplicar o método da densidade de máximos, o sinal analisado é subdividido em N intervalos regulares de δt (denominado aqui de intervalo do SAC-DM). Em cada intervalo é realizada a contagem do número de picos. Este processo gera pontos sucessivos de densidade de máximos, que são cruciais para definir o padrão da falha a ser diagnosticada. Na **Figura 5.28**, é apresentado um exemplo do funcionamento desse processo. Para exemplificar, foi utilizado um intervalo total de 10 segundos com o intervalo do SAC-DM definido para 1 segundo, o que resulta em 10 pontos de densidade de máximos. É importante destacar que o intervalo δt pode ser facilmente ajustado.

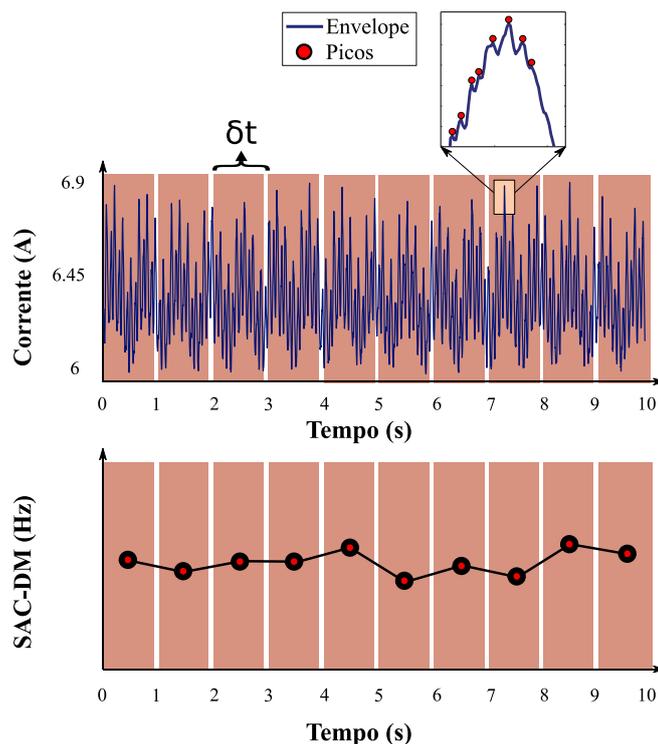


Figura 5.28- Descrição do processo para obter os pontos de densidade de máximos para cada intervalo δt , obtidos a partir do sinal do envelope da corrente.

Os sinais com falhas e os sinais saudáveis analisados correspondem às faixas de 0, 20, 40, 60, 80 e 100% da carga nominal. Foram analisados no total 12 sinais, divididos em

4 categorias, que correspondem a: 3 sinais com falha do tipo BPFI, 3 sinais com falha BPFO, 3 sinais com falha mista e 3 sinais saudável. O objetivo de utilizar 3 sinais para cada categoria foi de testar a repetitividade do método, cujo intuito é provar que a classificação das falhas segue uma tendência de agrupamento.

Nos tópicos a seguir, para fins de exemplificação, serão apresentados os resultados para três faixas de carga: 0%, 60%, e 100% da carga nominal. É importante destacar que os testes também foram realizados para as cargas de 0%, 20%, 40%, 60%, 80%, e 100% da carga nominal e foram usados no treinamento e validação da rede neural artificial.

5.5.4.1. SAC-DM para 0% da carga nominal

O intervalo total, usado em cada sinal analisado foi de aproximadamente 33 segundos, já o intervalo escolhido para o δt (intervalo do SAC-DM) foi de 0,25 segundos. Foram obtidos 131 valores possíveis para o SAC-DM. Assim sendo, para cada faixa de torque uma matriz 12x131 foi gerada.

Para fins de exemplificação será utilizada a faixa de carga a 0% da nominal, de modo que, o mesmo processo se aplica as demais faixas de carga. Na Tabela 5.19 são mostrados os resultados do SAC-DM obtido para cada intervalo de tempo δt , formando uma matriz 12x131. Na tabela a Classe de Estado do Rolamento (CER), é dividida em: BPFI, BPFO, Mista e Saudável.

Tabela 5.19-Valores do SAC-DM para rolamento com e sem falha

Estado Rolamento	SAC-DM para 0% da carga nominal										
	1	2	3	4	5	...	127	128	129	130	131
BPFI 1	2188	2008	2148	2228	2136	...	2136	2236	2280	1968	1984
BPFI 2	2164	2164	2228	2160	2112	2344	2280	2088
BPFI 3	2132	2192	2048	2208	2112	2308
BPFO 1	1608	1516	1580	1532
BPFO 2	1516	1556
...
Mista 2	1300	1380
Mista 3	1392	1452	1444	1440
Saudável 1	1908	1800	1820	1952	1824	1732
Saudável 2	1904	2052	2004	1852	1972	1884	1904	1920
Saudável 3	1692	1828	1804	1752	1796	...	1752	1704	1804	1792	1716

Os resultados compilados em forma de gráfico são exibidos na **Figura 5.29**. Pode-se verificar que os três sinais que pertencem a mesma classe de estado do rolamento (BPFI, BPFO, Mista ou Saudável) permanecem agrupados entre si. Globalmente, há uma clara separação entre as classes de estado do rolamento, o que permite distinguir com clareza os sinais saudáveis dos sinais com falha.

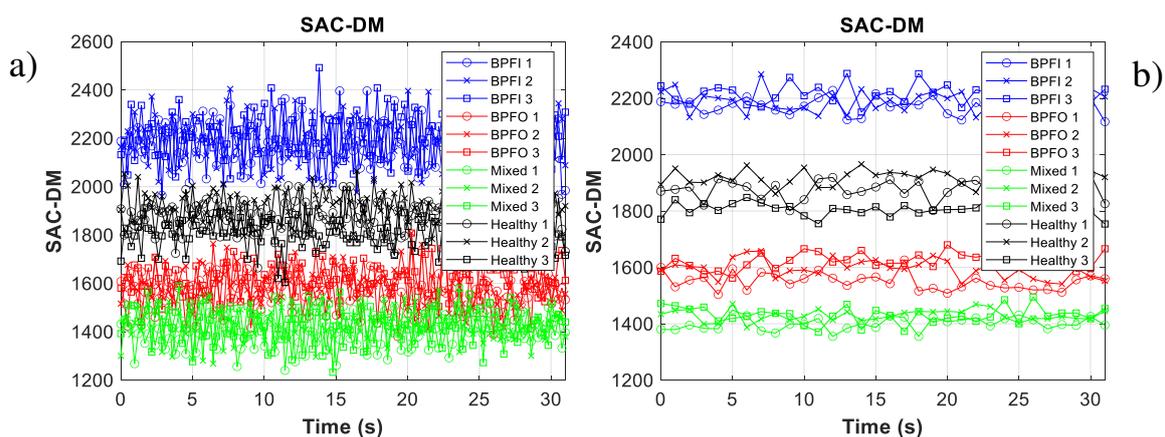


Figura 5.29- Resultado do SAC-DM para (a) $\delta t = 0,25$ e (b) $\delta t = 0,5$. Sinais com o rolamento saudável, com falha na pista interna, pista externa e falha mista, sob 0% da carga nominal.

Analisando estatisticamente os dados do SAC-DM da **Figura 5.29** a), utilizou-se a média e o desvio padrão para gerar o gráfico da **Figura 5.30**. Este gráfico permite uma distinção mais clara entre a classe de sinais sem falha e as classes de sinais com falha na pista externa, interna e mista.

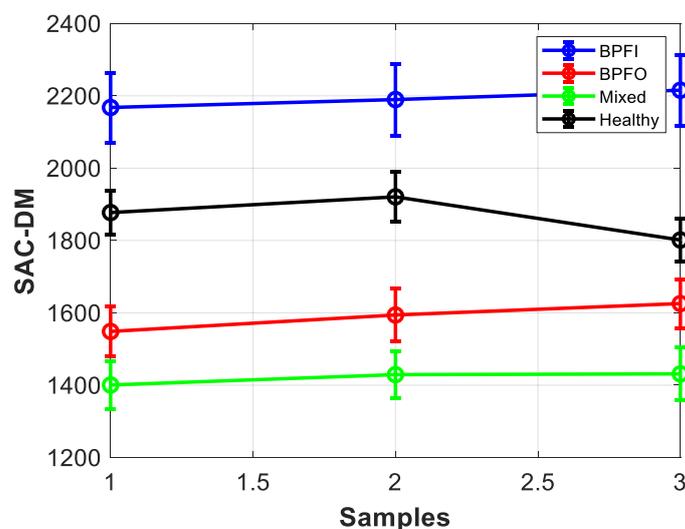


Figura 5.30- Valores médios e desvio padrão do SAC-DM para o rolamento com e sem falha atuando sob carga a 0% da nominal.

5.5.4.2. SAC-DM para 60% da carga nominal

A análise dos sinais para 60% da carga nominal foi conduzida de forma semelhante a anterior, mantendo-se o mesmo intervalo do SAC-DM e período de análise. Na **Figura 5.31** são exibidos os resultados do SAC-DM. (Figura (a)) Para um intervalo δt de apenas 0,25 segundos a visualização e a distinção das classes referentes aos sinais saudáveis e com falhas começa a ficar comprometida, muito embora, haja a separação das classes de falhas dos sinais e o agrupamento dos 3 sinais pertencentes a suas respectivas classes. Reduzindo este intervalo (figura (b)) para 0,5 segundos nota-se com maior facilidade a classificação dos sinais com e sem falha, o que permite constatar a flexibilidade da técnica para diferentes δt (intervalo do SAC-DM).

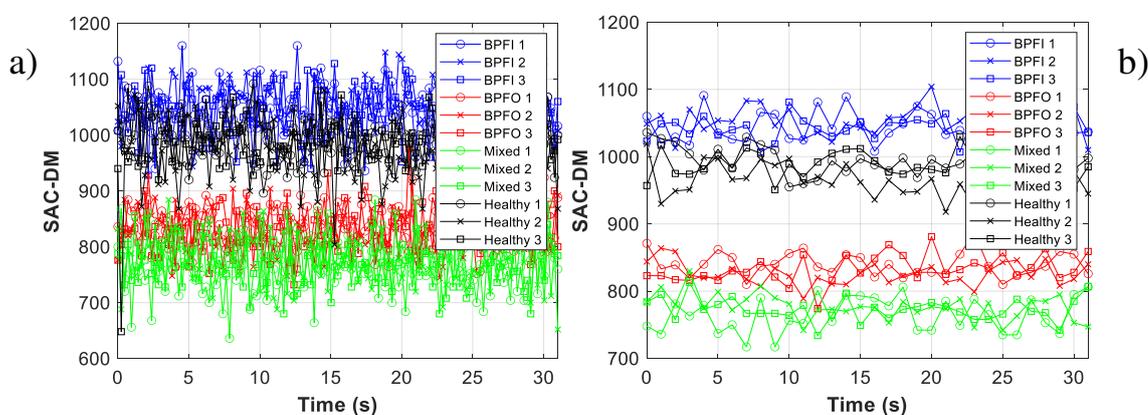


Figura 5.31- Resultado do SAC-DM para (a) $\delta t = 0,25$ e (b) $\delta t = 0,5$. Sinais com o rolamento saudável, com falha na pista interna, pista externa e falha mista, sob 60% da carga nominal.

Na **Figura 5.32** com a adoção dos valores médios e desvio padrão para o SAC-DM com intervalo de 0,25 segundos, comprova-se a classificação dos sinais por classes de estado do rolamento: falha na pista interna (BPF1), Saudável, falha na pista externa e falha mista.

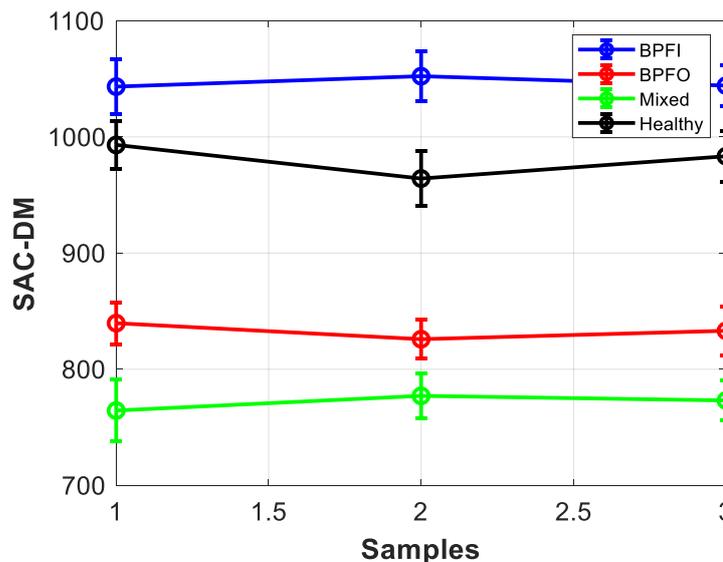


Figura 5.32-Valores médios e desvio padrão do SAC-DM para o rolamento com e sem falha atuando sob carga a 60% da nominal.

5.5.4.3. SAC-DM para 100% da carga nominal

À medida que a carga se aproxima ou excede a carga nominal, começam a surgir não linearidades. O menor nível de desbalanceamento faz com que o MIT comece a oscilar em frequências com amplitudes maiores, o que pode ocasionar sobreaquecimento e, em casos mais graves sobrecorrente, além de flutuações na corrente e no campo magnético do MIT (SEN, 2013).

Na **Figura 5.33** são apresentados os valores do SAC-DM para o motor operando a 100% da carga nominal. A classificação das falhas para 0,25 segundos, visualmente não apresenta uma distinção clara entre as classes dos sinais, entretanto quando o intervalo é reduzido para 0,5 segundos verifica-se que as classes dos sinais com e sem falha tendem a apresentar um padrão de separação, indicando que há uma classificação por estado de falha nos sinais de corrente dos rolamentos analisados.

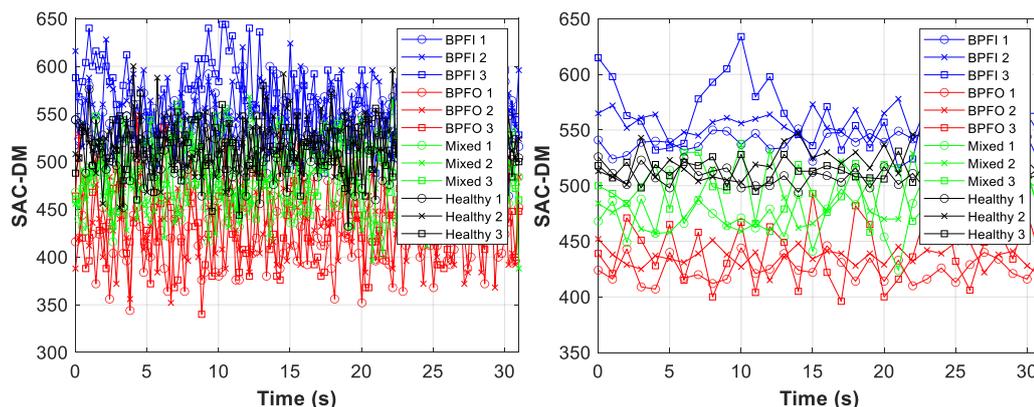


Figura 5.33-Resultado do SAC-DM para (a) $\delta t=0,25$ e (b) $\delta t=0,5$. Sinais com o rolamento saudável, com falha na pista interna, pista externa e falha mista, sob 60% da carga nominal.

Na **Figura 5.34** são exibidos os valores médios e o desvio padrão de cada classe dos sinais do SAC-DM. Verifica-se com maior clareza a separação entre as classes de estado do rolamento. Os desvios para essa faixa de carga tenderam a ser maior, devido ao aumento das não-linearidades provocadas quando o MIT esta operando em seu ponto nominal ou sobrepondo-se a ele.

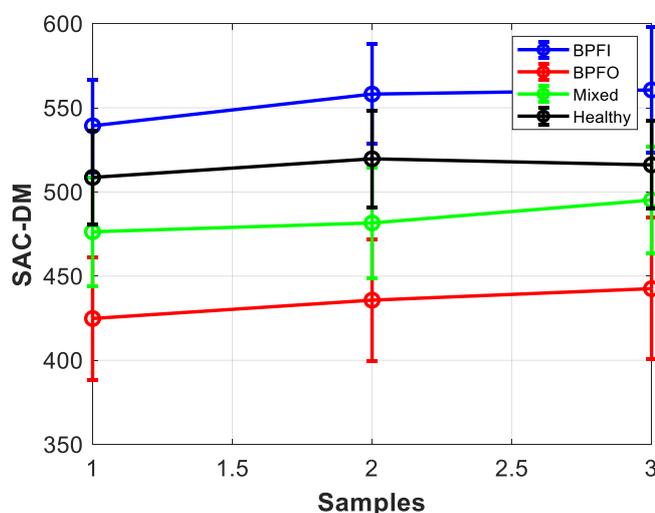


Figura 5.34-Valores médios e desvio padrão do SAC-DM para o rolamento com e sem falha atuando sob carga a 100% da nominal.

Com o objetivo de melhorar ainda mais a classificação dos sinais com e sem falha no rolamento, de modo a identificar as Classes de Estado do Rolamento (CER) foi utilizada uma rede neural perceptron multicamadas, cujos resultados são abordados no tópico abaixo.

5.5.5-Rede Neural Perceptron Multicamadas

Os sinais analisados conforme a metodologia adotada, descrita no item 4.3.3, são compostos por 70% dos dados destinados ao treinamento, 15% destinado à validação e os 15% restantes destinados para os testes. Os sinais utilizados foram provenientes do próprio SAC-DM, para o intervalo de 0,22 segundos, totalizando 6200 amostras. As métricas utilizadas como parâmetros de entrada, foram o próprio SAC-DM, fator de forma, fator de crista e a curtose.

Para avaliar o processo de desempenho e generalização da rede neural, é representada na **Figura 5.35** a evolução da perda (*loss*) durante o treinamento da rede neural ao longo de 200 épocas, tanto para o conjunto de treinamento (*Train*) quanto para o conjunto de validação (*Validation*). Nas primeiras 20-30 épocas, há uma rápida diminuição na perda para ambos os conjuntos (treinamento e validação). Isso indica que o modelo está aprendendo rapidamente no início. A estabilização da perda em torno de 5% para os conjuntos de treinamento e validação indica que o modelo convergiu, fazendo boas previsões, sem a necessidade de melhorias significativas ao adicionar mais épocas. Essa perda baixa sugere um bom desempenho e a proximidade das curvas mostra que o modelo generaliza bem, controlando o *overfitting* e mantendo um desempenho satisfatório.

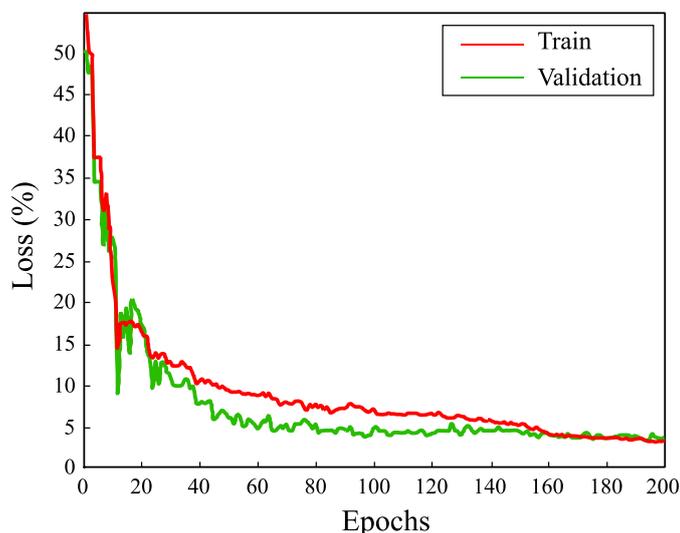


Figura 5.35- Curvas de perda de treinamento e validação ao longo das épocas para a rede neural de classificação de falhas.

Na **Figura 5.36** é apresentada a matriz de confusão da rede neural *Perceptron* multicamadas. Ela permite avaliar o desempenho do algoritmo de classificação, comparando suas previsões com os valores reais, além de permitir uma análise detalhada

do desempenho do modelo em diferentes classes. Para a análise e compreensão de seus principais parâmetros, por gentileza, consultar o item 3.4.6.

Accuracy: 96.8226

True Class	BPFI_0.5mm	1440	49	15	46	92.9%	7.1%
	BPFO_0.5mm	3	1511		36	97.5%	2.5%
	Falha_mista	4		1543	3	99.5%	0.5%
	Saudável	12	19	10	1509	97.4%	2.6%
		98.7%	95.7%	98.4%	94.7%		
		1.3%	4.3%	1.6%	5.3%		
		BPFI_0.5mm	BPFO_0.5mm	Falha_mista	Saudável		
		Predicted Class					

Figura 5.36- Matriz de confusão para a rede MLP.

Os resultados da matriz de confusão indicam alta precisão e *recall* em todas as classes, com F1 scores variando de 95,7% a 98,9%. A classe "Falha_mista" apresentou o melhor desempenho com um F1 score de 98,9%, seguida pela classe "BPFO" com 96,6%. As classes "BPFI_0.5mm" e "saudável" também mostraram robustez, com F1 scores de 95,7% e 96,0%, respectivamente. Esses altos valores de *F1 score* refletem uma excelente capacidade do modelo para discriminar entre diferentes tipos de falhas e condições normais, indicando forte generalização e baixa taxa de falsos positivos e falsos negativos.

Na Tabela 5.20 são compilados os principais valores referentes a matriz de confusão com especial destaque para a precisão, *recall* e *F1 score*.

Tabela 5.20- Compilação dos resultados da matriz de confusão e seus principais parâmetros

Classe	Precisão (%)	Recall (%)	F1 Score (%)
BPFI_0.5mm	98.7	92.9	95.7
BPFO_0.5mm	95.7	97.5	96.6
Falha_mista	98.4	99.5	98.9
Saudável	94.7	97.4	96.0

A precisão média do modelo é alta, com valores de 98,7% para "BPFI_0.5mm", 95,7% para "BPFO_0.5mm", 98,4% para "Falha_mista" e 94,7% para "Saudável". A acurácia geral do modelo ficou em torno de 96,82%, sugerindo que o modelo está bem equilibrado, identificando corretamente as falhas com baixa margem de erro. A precisão e *recall* elevadas em todas as classes indicam que o modelo juntamente com a metodologia apresentada é confiável para a detecção e classificação de falhas em rolamentos utilizando os sinais da corrente elétrica do MIT.

CAPITULO VI

6. CONSIDERAÇÕES FINAIS

O presente trabalho abordou a aplicação de uma nova técnica de análise de falhas em rolamentos de motores de indução trifásicos (MITs) por meio da técnica SAC-DM (do inglês - *Signal Analysis based on Chaos using Density of Maxima*), utilizando a análise da assinatura da corrente elétrica do motor. Além disso, foram implementados dois outros métodos de detecção de falhas em rolamentos: o primeiro utilizando o sinal de vibração mecânica e o segundo o som emitido pelo MIT em operação. Ambos os métodos empregaram a técnica do Envelope de Hilbert em conjunto com a transformada rápida de Fourier para detectar as frequências características de falhas. As análises de falhas foram realizadas no rolamento dianteiro do MIT em três situações distintas: falha na pista externa, falha na pista interna e falha mista (pista interna e pista externa).

As análises dos sinais de vibração mecânica e vibração sonora, combinadas com a técnica do envelope e a transformada rápida de Fourier (FFT), demonstrou ser uma ferramenta eficaz na detecção de falhas em rolamentos. Ao Comparar as frequências características de falhas teóricas com as frequências experimentais, foi possível detectar falhas do tipo (BPFO) de 0,5 mm com alta precisão. Para os sinais de vibração a média dos erros relativos percentuais foi de apenas 0,34%, enquanto o erro relativo percentual máximo foi de 0,60%. O método utilizando o som emitido pelo motor em operação teve desempenho igualmente exitoso em comparação ao método usando sinal de vibração. Para o som a média dos erros relativos percentuais foi de 0,40% enquanto o erro relativo percentual máximo foi de apenas 0,53%.

Na análise dos sinais de vibração mecânica e sonora para o rolamento com falha na pista interna (BPFI) com falha de diâmetro de 0,5 mm, os métodos mostraram-se igualmente eficientes. Ao analisar os sinais de vibração, a média dos erros relativos

percentuais foi de apenas 0,33%, enquanto o erro relativo percentual máximo foi de 0,49%. Na análise dos sinais sonoros, a média dos erros relativos percentuais foi de 0,26%, com um erro relativo percentual máximo de 0,36%.

O método utilizando a análise dos sinais do som mostrou-se igualmente confiável em comparação ao método utilizando sinais de vibração, com a vantagem de ser não-invasivo e ser de baixo custo.

Embora o método de análise da assinatura da corrente elétrica do MIT tenha uma base teórica bem consolidada, ele apresenta limitações na detecção de falhas iniciais nos rolamentos dos motores elétricos. No presente trabalho, mesmo utilizando a Transformada Rápida de Fourier, não foi possível identificar as frequências características de falha que deveriam aparecer no espectro do sinal da corrente, as quais são indicativas de falhas.

O método proposto neste estudo, baseado em uma extensão da teoria do caos, empregou técnicas para avaliar se o sinal da corrente elétrica do MIT pode ser caracterizado como uma série temporal caótica determinística. A comprovação do comportamento caótico do sinal foi realizado através das técnicas do teste da árvore de símbolos e do teste 0-1. Após a etapa de comprovação a análise dos sinais foi conduzida utilizando o SAC-DM.

Como contribuição deste trabalho, constatou-se que a aplicação do método SAC-DM foi eficaz no diagnóstico de falhas de rolamentos em motores de indução trifásicos via análise da corrente elétrica do estator. Para aprimorar ainda mais a metodologia, utilizou-se uma rede neural do tipo MLP (*Multi-Layer Perceptron*), cuja acurácia de classificação foi de 96,82%. Assim sendo, esta abordagem se apresenta como uma ferramenta adicional valiosa para o diagnóstico e caracterização de falhas em rolamentos de motores de indução trifásicos, podendo atuar, inclusive, de forma não invasiva.

Outra importante contribuição deste trabalho consiste na elaboração de um banco de dados contendo diversos sinais, tanto de grandezas elétricas quanto mecânicas, tais como: corrente e tensão elétrica, vibração mecânica e sonora, torque, velocidade e imagens térmicas. O conjunto desses sinais totalizou em torno de 50 GB de dados, que poderão ser utilizados em pesquisas futuras, para auxiliar nos testes de novos algoritmos de detecção e diagnóstico de falhas em rolamentos.

6.1. Sugestões de trabalhos futuros

Para o desenvolvimento de trabalhos futuros com o propósito de melhorar a parte experimental e aplicar o SAC-DM como ferramenta de análise para outros tipos de falhas, pretende-se:

- Instrumentalização da bancada de testes, para receber comandos automáticos de ajuste do torque, objetivando automatizar o controle da carga imposta ao MIT;
- Análise de falhas em outros tipos de rolamentos, rolamento de rolos cilíndricos, por exemplo. Análise de falhas no estator do MIT, em especial destaque para a falha do tipo *Inter Turn* (falha entre as espiras), já que corresponde a segunda maior causa de falhas em MITs.
- Desenvolvimento de um sistema embarcado para o diagnóstico online de falhas em MITs, tanto falhas elétricas quanto mecânicas por meio da análise da corrente e da vibração mecânica utilizando o SAC-DM.
- Criação de um novo banco de dados que englobe outros tipos de falhas em motores de indução trifásicos.

REFERÊNCIAS

ADISSI, M. O. **Estudo e Desenvolvimento De Sistema De Monitoramento Da Eficiência Energética Em Motores Elétricos Na Indústria**. Tese de doutorado (Engenharia Mecânica)—João Pessoa - Paraíba: Universidade Federal da Paraíba-UFPB, 2015.

ADISSI, M. O. et al. Implementation and Deployment of an Intelligent Industrial Wireless System for Induction Motor Monitoring. **Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME**, v. 139, n. 12, 2017.

AGRAWAL, S.; MOHANTY, S. R.; AGARWAL, V. Bearing fault detection using hilbert and high frequency resolution techniques. **IETE Journal of Research**, v. 61, n. 2, p. 99–108, 2015.

ALICANDO, M. A. R.; RAMOS, G. M.; OSTIA, C. F. Bearing Fault Detection of a Single-phase Induction Motor Using Acoustic and Vibration Analysis Through Hilbert-Huang Transform. **2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management, HNICEM 2021**, p. 0–5, 2021.

AMAR, M.; GONDAL, I.; WILSON, C. Vibration Spectrum Imaging: A Novel Bearing Fault Classification Approach. **IEEE Transactions on Industrial Electronics**, v. 62, n. 1, p. 494–502, jan. 2015.

BARTHELD, R. G.; HABETLER, T. G.; KAMRAN, F. Motor Bearing Damage Detection Using Stator Current Monitoring. **IEEE Transactions on Industry Applications**, v. 31, n. 6, p. 1274–1279, 1995.

BASTOS, H. C. P. DE A. **Densidade de Máximos e Função de Correlação em Mecânica Clássica e Sinais Biológicos**. Dissertação de mestrado (Física)—João Pessoa - Paraíba: Universidade Federal da Paraíba - UFPB, 2017.

BAUTISTA-MORALES, M. DEL R.; PATIÑO-LÓPEZ, L. D. Acoustic detection of bearing faults through fractional harmonics lock-in amplification. **Mechanical Systems and Signal Processing**, v. 185, n. August 2022, p. 109740, 2023.

BAZEIA, D. et al. A novel procedure for the identification of chaos in complex biological systems. **Scientific Reports**, v. 7, 2017.

BENDAT, J. S.; PIERSOL, A. G. **Random data: analysis and measurement procedures**. 4. ed ed. Hoboken, NJ: Wiley, 2010.

BESSOUS, N.; CHEMSA, A.; SBAA, S. New Vision about the Mixed Eccentricity Fault Causes in Induction Motors and its relationship with the Rolling Element Bearing Faults : Analytical model dedicated to the REB faults. **Proceedings - International Conference on Communications and Electrical Engineering, ICCEE 2018**, p. 1–11, 2019.

BLOCH, H. P.; GEITNER, F. K. **Machinery failure analysis and troubleshooting**. 4. ed. Amsterdam Heidelberg: Elsevier, Butterworth-Heinemann, 2012.

BUDYNAS, R. G.; NISBETT, J. K. **Shigley 's Mechanical Engineering Design**. 11. ed. | New York, NY: McGrawHill, 2020.

CHAPMAN, S. J. **Fundamentos de máquinas elétricas**. 5 edição ed. Porto Alegre: Bookman, 2013.

CHAPRA, S. C.; CANALE, R. P. **Métodos numéricos para engenharia**. 5ª edição ed. Porto Alegre - Rio Grande do Sul: McGraw-Hill, 2011.

CHOUDHARY, A. et al. Condition Monitoring and Fault Diagnosis of Induction Motors: A Review. **Archives of Computational Methods in Engineering**, v. 26, n. 4, p. 1221–1238, 2019.

CHOUDHARY, A. et al. Multi-input CNN based vibro-acoustic fusion for accurate fault diagnosis of induction motor. **Engineering Applications of Artificial Intelligence**, v. 120, n. December 2022, p. 105872, 2023.

CHOUDHARY, A.; SHIMI, S. L.; AKULA, A. Bearing fault diagnosis of induction motor using thermal imaging. **2018 International Conference on Computing, Power and Communication Technologies, GUCON 2018**, n. c, p. 950–955, 2019.

CISZEWSKI, T. et al. Novel Investigation of Higher Order Spectral Technologies for Fault Diagnosis of Motor-Based Rotating Machinery. **Sensors**, v. 23, n. 7, 2023.

COOLEY, J. W.; TUKEY, J. W. An Algorithm for the Machine Calculation of Complex Fourier Series. v. 19, p. 5, 1965.

CRUZ, A. G. DE A. **Sistema Híbrido Para Diagnóstico De Falhas Em Motores De Indução Trifásicos Com Base No Método Vibracional, Corrente De Armadura E Lógica Fuzzy**. Tese de doutorado (Engenharia Mecânica)—João Pessoa - Paraíba: Universidade Federal da Paraíba - UFPB, 2015.

DA SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**. 2. ed. São Paulo: ArtLiber, 2016.

DA SILVA, J. C. **Sistema Totalmente Não-Invasivo Para Determinação Da Velocidade De Rotação Do Eixo , Torque E Rendimento Em Motores De Indução Em Operação**. Dissertação de mestrado (Engenharia Mecânica)—João Pessoa- Paraíba: Universidade Federal da Paraíba - UFPB, 2018.

DA SILVA, M. A. **Método de estimação da velocidade em motores de indução trifásicos através da corrente de armadura com aplicação da teoria do caos**. Tese de doutorado (Engenharia Mecânica)—João Pessoa - Paraíba: Universidade Federal da Paraíba - UFPB, 2021.

DE DEUS, D. B. B. **Diagnóstico De Barras Quebradas Em Motores De Indução Trifásicos Através Da Análise Da Densidade De Máximos Do Sinal De Corrente**.

Dissertação de mestrado (Engenharia Mecânica)—João Pessoa- Paraíba: Universidade Federal da Paraíba - UFPB, 2020.

DEEKSHIT KOMPELLA, K. C.; VENU GOPALA RAO, M.; SRINIVASA RAO, R. Bearing fault detection in a 3 phase induction motor using stator current frequency spectral subtraction with various wavelet decomposition techniques. **Ain Shams Engineering Journal**, v. 9, n. 4, p. 2427–2439, 2018.

DELGADO-ARREDONDO, P. A. et al. Methodology for fault detection in induction motors via sound and vibration signals. **Mechanical Systems and Signal Processing**, v. 83, p. 568–589, 2017.

DINIZ, P. S. R.; SILVA, E. A. B. DA; NETTO, S. L. **Processamento digital de sinais: projeto e análise de sistemas**. 2 edição ed. [s.l.] Bookman, 2014.

EKMAN, M. **Learning Deep Learning**. [s.l.] Adisson-Wesley, 2022.

EL IDRISSE, A. et al. [105] Bearing Fault Diagnosis for an Induction Motor Controlled by an Artificial Neural Network—Direct Torque Control Using the Hilbert Transform. **Mathematics**, v. 10, n. 22, 2022.

ELBOUCHIKHI, E. et al. Motor current signal analysis based on a matched subspace detector. **IEEE Transactions on Instrumentation and Measurement**, v. 66, n. 12, p. 3260–3270, 2017.

ELMALEEH, M. A. A.; SAAD, N. **Acoustic emission techniques for early detection of bearing faults using LabVIEW**. 2008 5th International Symposium on Mechatronics and Its Applications. **Anais...** Em: 2008 5TH INTERNATIONAL SYMPOSIUM ON MECHATRONICS AND ITS APPLICATIONS (ISMA). Amman: IEEE, maio 2008.

EPE. **Balanco Energético Nacional**. Rio de Janeiro-Brasil: Empresa de Pesquisa Energética - EPE, 2022. Disponível em: <<https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-675/topico-638/BEN2022.pdf>>.

FAIZ, J.; MOOSAVI, S. M. M. Eccentricity fault detection - From induction machines to DFIG - A review. **Renewable and Sustainable Energy Reviews**, v. 55, p. 169–179, 2016.

FEIGENBAUM, M. J. Quantitative universality for a class of nonlinear transformations. **Journal of Statistical Physics**, v. 19, n. 1, p. 25–52, 1978.

FEIGENBAUM, M. J. The universal metric properties of nonlinear transformations. v. 21, p. 38, 1979.

FIGLIOLA, R. S.; BEASLEY, D. E. **Theory and Design for Mechanical Measurements**. 7th edition ed. [s.l.] Wiley, 2020.

GANGSAR, P.; TIWARI, R. Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. **Mechanical Systems and Signal Processing**, v. 144, p. 106908, 2020.

GIRDHAR, P.; SCHEFFER, C. **Practical Machinery Vibration Analysis and Predictive Maintenance**. [s.l.] Elsevier, 2004.

GLEICK, J. **Caos a criação de uma nova ciência**. 16. ed. Rio de Janeiro: Elsevier, 1989.

GLOWACZ, A. Fault diagnosis of single-phase induction motor based on acoustic signals. **Mechanical Systems and Signal Processing**, v. 117, p. 65–80, fev. 2019.

GLOWACZ, A.; GLOWACZ, Z. Diagnosis of stator faults of the single-phase induction motor using acoustic signals. **Applied Acoustics**, v. 117, p. 20–27, 2017.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. 1. ed. Cambridge-Massachusetts: MIT Press, 2016.

GOTTWALD, G. A.; MELBOURNE, I. On the Implementation of the 0–1 Test for Chaos. **SIAM Journal on Applied Dynamical Systems**, v. 8, n. 1, p. 129–145, jan. 2009.

GUEDES, J. J. et al. Three-phase induction motor fault identification using optimization algorithms and intelligent systems. **Soft Computing**, 2024.

HANITSCH, R. **ENERGY EFFICIENT ELECTRIC MOTORS**. RIO 02. **Anais...Rio de Janeiro-Brasil: 2002. Disponível em: <http://www.rio12.com/rio02/proceedings/pdf/045_Hanitsch.pdf>**

HAYKIN, S. **Neural networks and contagion**. 3rd ed. ed. New Jersey: Pearson, 2009. v. 3

HENAO, H. et al. Trends in fault diagnosis for electrical machines: A review of diagnostic techniques. **IEEE Industrial Electronics Magazine**, v. 8, n. 2, p. 31–42, 2014.

HOANG, D. T.; KANG, H. J. A Motor Current Signal-Based Bearing Fault Diagnosis Using Deep Learning and Information Fusion. **IEEE Transactions on Instrumentation and Measurement**, v. 69, n. 6, p. 3325–3333, 2020.

HOSSAIN, E. **Machine Learning Crash Course for Engineers**. Cham: Springer International Publishing, 2024. v. 1

ISO 10816-1. **Mechanical vibration — Evaluation of machine vibration by measurements on non-rotating parts**. , [s.d.].

JUVINALL, R. C.; M.MARSHEK, K. **Fundamentos Do Projeto De Componentes De Máquinas**. 4. ed. Rio de Janeiro-Brasil: LTC-Livros Técnicos E Científicos Editora, 2008.

KABUL, A.; ÜNSAL, A. Diagnosis of Multiple Faults of an Induction Motor Based on Hilbert Envelope Analysis. **Metrology and Measurement Systems**, v. 29, n. 1, p. 191–205, 2022.

KARVELIS, P. et al. An automated thermographic image segmentation method for induction motor fault diagnosis. **IECON Proceedings (Industrial Electronics Conference)**, p. 3396–3402, 2014.

KEMALKAR, A. K.; BAIRAGI, V. K. **Engine fault diagnosis using sound analysis**. 2016 International Conference on Automatic Control and Dynamic Optimization Techniques (ICACDOT). **Anais...** Em: 2016 INTERNATIONAL CONFERENCE ON AUTOMATIC CONTROL AND DYNAMIC OPTIMIZATION TECHNIQUES (ICACDOT). Pune, India: IEEE, set. 2016.

KENNEDY, J.; EBERHART, R. Particle Swarm Optimization. p. 1942–1948, 1995.

KIM, S.; AN, D.; CHOI, J. H. Diagnostics 101: A tutorial for fault diagnostics of rolling element bearing using envelope analysis in MATLAB. **Applied Sciences (Switzerland)**, v. 10, n. 20, p. 1–23, 2020.

KINGMA, D. P.; BA, J. L. Adam: A method for stochastic optimization. **3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings**, p. 1–15, 2014.

KLUCZYK, M.; GRZĄDZIELA, A. Vibration Diagnostics of the Naval Propulsion Systems. **Scientific Journal of Polish Naval Academy**, v. 208, n. 1, p. 15–29, 2017.

KULP, C. W.; SMITH, S. Characterization of noisy symbolic time series. **Physical Review E - Statistical, Nonlinear, and Soft Matter Physics**, v. 83, n. 2, 2011.

KULP, C. W.; ZUNINO, L. Discriminating chaotic and stochastic dynamics through the permutation spectrum test. **Chaos**, v. 24, n. 3, 2014.

KUMAR, T. CH. A.; SINGH, G.; NAIKAN, V. N. A. **Sensitivity of rotor slot harmonics due to inter-turn fault in induction motors through vibration analysis**. 2018 International Conference on Power, Instrumentation, Control and Computing (PICC). **Anais...** Em: 2018 INTERNATIONAL CONFERENCE ON POWER, INSTRUMENTATION, CONTROL AND COMPUTING (PICC). Thrissur: IEEE, jan. 2018.

LEES, A. W. **Vibration Problems in Machines Diagnosis and Resolution**. 2. ed. [s.l.] CRC Press, 2020.

LEITE, V. C. M. N. et al. Detection of localized bearing faults in induction machines by spectral kurtosis and envelope analysis of stator current. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1855–1865, 2015.

LI, T.-Y.; YORKE, J. A. Period Three Implies Chaos. **The American Mathematical Monthly**, v. 82, n. 10, p. 985, dez. 1975.

LI, X. et al. Research on the influence of air-gap eccentricity on the temperature field of a motorized spindle. **Mechanical Sciences**, v. 12, n. 1, p. 109–122, 2021.

LIMA FILHO, A. C. **Estudo E Desenvolvimento De Soluções Para Determinação Do Torque Em Unidades De Bombeio Mecânico Utilizadas Na Extração De Petróleo**. Tese de doutorado (Engenharia Mecânica)—João Pessoa - Paraíba: Universidade Federal da Paraíba - UFPB, 2009.

LIU, H. et al. Perceptual Vibration Hashing by Sub-Band Coding: An Edge Computing Method for Condition Monitoring. **IEEE Access**, v. 7, p. 129644–129658, 2019.

LOPEZ-GUTIERREZ, R. et al. Induction Machine Bearing Fault Detection Using Empirical Wavelet Transform. **Shock and Vibration**, v. 2022, p. 1–12, abr. 2022.

LOPEZ-PEREZ, D.; ANTONINO-DAVIU, J. Application of Infrared Thermography to Failure Detection in Industrial Induction Motors: Case Stories. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 1901–1908, maio 2017.

LORENZ, E. N. Deterministic Nonperiodic Flow. **Journal of the Atmospheric Sciences**, v. 20, n. 2, p. 130–141, 1963.

LU, B.; HABETLER, T. G.; HARLEY, R. G. A Nonintrusive and In-Service Motor-Efficiency Estimation Method Using Air-Gap Torque With Considerations of Condition Monitoring. **Industry Applications, IEEE Transactions on**, v. 44, n. 6, p. 1666–1674, 2008.

LUCAS, G. B. et al. **Sensors Applied to Bearing Fault Detection in Three-Phase Induction Motors**. The 8th International Electronic Conference on Sensors and Applications. **Anais...**Basel Switzerland: MDPI, nov. 2021.

LUCENA-JUNIOR, J. A. et al. Chaos theory using density of maxima applied to the diagnosis of three-phase induction motor bearings failure by sound analysis. **Computers in Industry**, v. 123, p. 103304, 2020.

LYRA, G. J. **Análise de métodos para estimação da velocidade no eixo de motores de indução trifásicos**. Dissertação de mestrado (Engenharia Mecânica)—João Pessoa-Paraíba: Universidade Federal da Paraíba - UFPB, 2014.

MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier nonlinearities improve neural network acoustic models. **in ICML Workshop on Deep Learning for Audio, Speech and Language Processing**, v. 28, 2013.

MALIUK, A. S. et al. Novel bearing fault diagnosis using gaussian mixture model-based fault band selection. **Sensors**, v. 21, n. 19, p. 6579, out. 2021.

MARTINEZ-MONTES, E. et al. **Evaluation of the Detectability of Bearing Faults at Different Load Levels Through the Analysis of Stator Currents**. 2018 XIII International Conference on Electrical Machines (ICEM). **Anais...** Em: 2018 XIII INTERNATIONAL CONFERENCE ON ELECTRICAL MACHINES (ICEM). Alexandroupoli: IEEE, set. 2018.

MAY, R. M. Simple mathematical models with very complicated dynamics. **Universality in Chaos, Second Edition**, p. 459–467, 1976.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, dez. 1943.

MEDEIROS, R. L. V. et al. A Novel Approach for Speed and Failure Detection in Brushless DC Motors Based on Chaos. **IEEE Transactions on Industrial Electronics**, v. 66, n. 11, p. 8751–8759, 2019.

MINSKY, M.; PAPERT, S. A. **Perceptrons: an introduction to computational geometry**. [s.l.] The MIT Press, 1969. v. 1

NAIR, V.; HINTON, G. E. Rectified linear units improve Restricted Boltzmann machines. **ICML 2010 - Proceedings, 27th International Conference on Machine Learning**, n. 3, p. 807–814, 2010.

NAKAMURA, H.; MIZUNO, Y. Diagnosis for Slight Bearing Fault in Induction Motor Based on Combination of Selective Features and Machine Learning. **Energies**, v. 15, n. 2, p. 1–12, 2022.

NANNI, L. et al. Comparison of Different Convolutional Neural Network Activation Functions and Methods for Building Ensembles for Small to Midsize Medical Data Sets. **Sensors**, v. 22, n. 16, p. 6129, 16 ago. 2022.

NORTON, R. **Projeto de máquinas: uma abordagem integrada**. 4.ed ed. Porto Alegre: Bookman, 2013.

NOUREDDINE, B. et al. Rolling Bearing Failure Detection in Induction Motors using Stator Current, Vibration and Stray Flux Analysis Techniques. **IECON Proceedings (Industrial Electronics Conference)**, v. 2020- Octob, p. 1088–1095, 2020.

NOUREDDINE, B.; EDDINE, Z. S.; MOHAMED, S. Experimental exploitation for the diagnosis to the induction machine under a bearing fault - Using MCSA. **2015 4th International Conference on Electrical Engineering, ICEE 2015**, 2016.

NUNEZ, J. A. R. et al. Low-cost thermographic analysis for bearing fault detection on induction motors. **Journal of Scientific and Industrial Research**, v. 75, n. 7, p. 412–415, 2016.

OCAK, H.; LOPARO, K. A. Estimation of the running speed and bearing defect frequencies of an induction motor from vibration data. **Mechanical Systems and Signal Processing**, v. 18, n. 3, p. 515–533, 2004.

OSORNIO-RIOS, R. A.; ANTONINO-DAVIU, J. A.; ROMERO-TRONCOSO, R. D. J. Recent Industrial Applications of Infrared Thermography: A Review. **IEEE Transactions on Industrial Informatics**, v. 15, n. 2, p. 615–625, fev. 2019.

PANDARAKONE, S. E. et al. Fault classification of outer-race bearing damage in low-voltage induction motor with aid of fourier analysis and SVM. **Proceedings of the IEEE International Conference on Industrial Technology**, v. 2018- Febru, p. 407–412, 2018.

PRAINETR, S.; WANGNIPPANTO, S.; TUNYASIRUT, S. **Detection mechanical fault of induction motor using harmonic current and sound acoustic**. 2017 International Electrical Engineering Congress (iEECON). **Anais... Em: 2017 INTERNATIONAL ELECTRICAL ENGINEERING CONGRESS (IEECON)**. Pattaya, Thailand: IEEE, mar. 2017. PRUDHOM, A. et al. Time-frequency vibration analysis for the detection of motor

damages caused by bearing currents. **Mechanical Systems and Signal Processing**, v. 84, p. 747–762, fev. 2017.

RAYNER, R. VIBRATION. Em: **Pump Users Handbook**. [s.l.] Elsevier, 1995. v. 21p. 203–211.

RESENDIZ-OCHOA, E. et al. Induction Motor Failure Analysis: An Automatic Methodology Based on Infrared Imaging. **IEEE Access**, v. 6, n. c, p. 76993–77003, 2018.

RINKEVIČIENE, R.; PETROVAS, A. Modelling of frequency controlled induction drive with ventilator type load. **Elektronika ir Elektrotechnika**, v. 6, n. 6, p. 69–72, 2009.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, 1986.

SAADI, M. N. et al. Bearing failures detection in induction motors using the stator current analysis based on hilbert huang transform. **Proceedings - 2017 European Conference on Electrical Engineering and Computer Science, EECS 2017**, p. 101–106, 2018.

SANTANDER, E. J. O. **Aplicação de Curtose Espectral na Identificação de Falhas em Mancais de Rolamentos**. Dissertação de mestrado (Engenharia Oceânica-COPPE)—Rio de Janeiro: Universidade Federal do Rio de Janeiro - UFRJ, 2014.

SANTOS, R. D. S. **Detecção De Falhas Em Rolamentos De Máquinas Rotativas Utilizando Técnicas De Processamentos De Sinais**. Tese de doutorado (Engenharia Mecânica)—Guaratinguetá - SP: Universidade Estadual Paulista- UNESP, 2017.

SCHOENT, R. R. et al. Detection Using Stator Current Monitoring Fault Detection Using Stator Current Monitoring. **Ieee**, p. 103–109, 1994.

SEN, DR. P. C. **PRINCIPLES OF ELECTRIC MACHINES AND POWER ELECTRONICS**. 3 rd ed. [s.l.] Wiley, 2013.

SHANNON, C. E. A Mathematical Theory of Communication. **Bell System Technical Journal**, v. 27, n. 3, p. 379–423, jul. 1948.

SHARMA, A.; MATHEW, L.; CHATTERJI, S. **Analysis of Broken Rotor bar Fault Diagnosis for Induction Motor**. 2017 International Conference on Innovations in Control, Communication and Information Systems (ICICCI). **Anais...** Em: 2017 INTERNATIONAL CONFERENCE ON INNOVATIONS IN CONTROL, COMMUNICATION AND INFORMATION SYSTEMS (ICICCI). Greater Noida, India: IEEE, ago. 2017.

SHIN, K.; HAMMOND, J. K. **Fundamentals of Signal Processing for Sound and Vibration Engineers**. [s.l.] Wiley, 2008. v. 1

SINGH, M.; SHAIK, A. G. Bearing fault diagnosis of a three phase induction motor using stockwell transform. **2016 IEEE Annual India Conference, INDICON 2016**, p. 2–7, 2017.

SINGH, S.; KUMAR, N. Detection of Bearing Faults in Mechanical Systems Using Stator Current Monitoring. **IEEE Transactions on Industrial Informatics**, v. 13, n. 3, p. 1341–1349, 2017.

SKF. **Rolling bearings Rolamentos de esferas.** , 2015. Disponível em: <https://cdn.skfmediahub.skf.com/api/public/0901d19680416a2b/pdf_preview_medium/0901d19680416a2b_pdf_preview_medium.pdf>

SKF. **Produtos SKF para Manutenção e Lubrificação.** , 2022. Disponível em: <https://cdn.skfmediahub.skf.com/api/public/0947a1855ed1c8fb/pdf_preview_medium/0947a1855ed1c8fb_pdf_preview_medium.pdf>

SKIADAS, C. H.; SKIADAS, C. **Applications of Chaos Theory.** [s.l.] CRC Press, 2016.

STROGATZ, S. H. **Nonlinear Dynamics And Chaos.** [s.l.] CRC Press, 2018. v. 2

SUJATHA, C. **Vibration, Acoustics and Strain Measurement.** Cham: Springer International Publishing, 2023.

TAYLOR, J. I. BOOK The Vibration Analysis Handbook - A practical guide solving rotary Machinery Problems.pdf. **Time**, p. 345, 2003.

TÉL, T.; GRUIZ, M. **Chaotic Dynamics An Introduction Based on Classical Mechanics Since.** [s.l.] Cambridge University press, 2006.

THOMSON, W. T.; CULBERT, I. **Current Signature Analysis for Condition Monitoring of Cage Induction Motors.** [s.l.] Wiley, 2016.

TIAN, J. et al. Motor Bearing Fault Detection Using Spectral Kurtosis-Based Feature Extraction Coupled With K -Nearest Neighbor Distance Analysis. **IEEE Transactions on Industrial Electronics**, v. 63, n. 3, p. 1793–1803, mar. 2016.

TOLIYAT, H. A. et al. **Electric Machines modeling, condition monitoring and fault diagnosis.** [s.l.] CRC Press, 2017.

TYAGI, S.; PANIGRAHI, S. K. An improved envelope detection method using particle swarm optimisation for rolling element bearing fault diagnosis. **Journal of Computational Design and Engineering**, v. 4, n. 4, p. 305–317, 2017.

UPADHYAY, R. K.; IYENGAR, S. R. K. **Introduction to Mathematical Modeling and Chaotic Dynamics.** [s.l.] CRC Press, 2013.

VÉRAS, F. C. L. **Detecção de Velocidade e de Falha de Excentricidade em Motores Elétricos a Partir de Sinais Sonoros Utilizando Densidade de Máximos.** Tese de doutorado (Engenharia Mecânica)—João Pessoa - Paraíba: Universidade Federal da Paraíba - UFPB, 2019.

WANG, Y.; REN, Q. **Deep Learning-Based Forward Modeling and Inversion Techniques for Computational Physics Problems**. [s.l.] CRC Press, 2023.

WEG. **Guia De Especificação Motores Elétricos**. Jaraguá do Sul-SC- Brazil: Weg, 2023.

YANG, T. et al. Feature Knowledge Based Fault Detection of Induction Motors Through the Analysis of Stator Current Data. **IEEE Transactions on Instrumentation and Measurement**, v. 65, n. 3, p. 549–558, 2016.

YANG, Z.; ZHAO, G. APPLICATION OF SYMBOLIC TECHNIQUES IN DETECTING DETERMINISM IN TIME SERIES. v. 20, n. 5, p. 2670–2673, 1998.

YETGIN, A. G. Investigation of the Effects of Stator Slot Permeance on Induction Motor and Obtaining the Best Starting Torque Using Permeance Calculation. **Canadian Journal of Electrical and Computer Engineering**, v. 43, n. 1, p. 25–29, 2020.

YU, H.; WILAMOWSKI, B. Levenberg–Marquardt Training. Em: **Intelligent Systems**. Boca Raton: CRC Press, 2011. v. 46p. 16.

ZHUKOVSKIY, Y.; BULDYSKO, A.; REVIN, I. Induction Motor Bearing Fault Diagnosis Based on Singular Value Decomposition of the Stator Current. **Energies**, v. 16, n. 8, 2023.

ZOLGHADR-ASLI, B. **Computational Intelligence-based Optimization Algorithms: From Theory to Practice**. 1. ed. Boca Raton: CRC Press, 2023.