



**UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO**



**Programa de Pós-Graduação em
Engenharia Elétrica**

**Identificação de Falhas em Rolamentos Aplicados em Motores de
Indução por meio de Sensores de Corrente de Efeito Hall,
Técnicas de Processamento de Sinais e Sistemas Inteligentes**

WALLACE GABRIEL DE SOUZA

Bauru - SP

2022



**UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO**

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Identificação de Falhas em Rolamentos Aplicados em Motores de
Indução por meio de Sensores de Corrente de Efeito Hall,
Técnicas de Processamento de Sinais e Sistemas Inteligentes**

WALLACE GABRIEL DE SOUZA

Tese apresentada ao programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Bauru (FEB) – UNESP, para obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Prof. Dr. André Luiz Andreoli

Bauru - SP

2022

Souza, Wallace Gabriel de.

Identificação de Falhas em Rolamentos Aplicados em Motores de Indução por meio de Sensores de Corrente de Efeito Hall, Técnicas de Processamento de Sinais e Sistemas Inteligentes / Wallace Gabriel de Souza, 2022

103 f. : il.

Orientador: Prof. Dr. André Luiz Andreoli

Tese (Doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2022

1. Motores de Indução Trifásicos. 2. Falhas em Rolamentos. 3. Processamento de Sinais. 4. Sistemas Inteligentes. 5. Técnica Cromática. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.

ATA DA DEFESA PÚBLICA DA TESE DE DOUTORADO DE WALLACE GABRIEL DE SOUZA, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 03 dias do mês de agosto do ano de 2022, às 14:00 horas, por meio de Videoconferência, realizou-se a defesa de TESE DE DOUTORADO de WALLACE GABRIEL DE SOUZA, intitulada **IDENTIFICAÇÃO DE FALHAS EM ROLAMENTOS APLICADOS EM MOTORES DE INDUÇÃO POR MEIO DE SENSORES DE CORRENTE DE EFEITO HALL, TÉCNICAS DE PROCESSAMENTO DE SINAIS E SISTEMAS INTELIGENTES**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. ANDRE LUIZ ANDREOLI (Orientador(a) - Participação Virtual) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru UNESP, Prof. Dr. PAULO JOSÉ AMARAL SERNI (Participação Virtual) do(a) Departamento de Engenharia Elétrica - docente voluntário / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. BRUNO ALBUQUERQUE DE CASTRO (Participação Virtual) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. RICARDO AUGUSTO SOUZA FERNANDES (Participação Virtual) do(a) Departamento de Engenharia Elétrica / Universidade Federal de São Carlos - UFSCar, Prof. Dr. ALESSANDRO GOEDEL (Participação Virtual) do(a) Departamento de Engenharia Elétrica / Universidade Tecnológica Federal do Paraná. Após a exposição pelo doutorando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: APROVADO. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.



Prof. Dr. ANDRE LUIZ ANDREOLI

AGRADECIMENTOS

Agradeço a Deus, pois tudo que precisei e desejei tive forças para conquistar.

Agradeço aos meus pais, Antônio e Rosinéya, por todo apoio, dedicação e carinho para que eu conseguisse chegar até aqui. Ao longo do meu desenvolvimento, sei que abriram mão de muitas coisas para que eu pudesse estudar e ter o conforto que sempre tive. Vocês são minha base e inspiração para seguir em frente.

Ao meu orientador, Prof. Dr. André Luiz Andreoli, pela amizade, paciência e dedicação ao longo de minha carreira acadêmica, principalmente no meu doutorado, além da orientação, confiança nesta pesquisa e em meu potencial. Agradeço por todos os ensinamentos, conselhos, disponibilidades e oportunidades que me foram dadas ao longo desta jornada.

Ao Prof. Dr. Bruno Albuquerque, pela amizade e o companheirismo durante os trabalhos, principalmente pela disposição em tirar as minhas dúvidas para concluir este doutorado.

Aos meus amigos e companheiros de laboratório, Guilherme Beraldi e Marco Aurélio, pela parceria e amizade. Vocês fizeram da Unesp minha segunda casa e sempre estiveram presentes em me auxiliar no término deste trabalho.

A todos os meus colegas da pós-graduação em Engenharia Elétrica – Unesp/Bauru, em especial ao meu amigo Felipe Alexandre (*in memoriam*), pela amizade que remonta aos tempos de meu mestrado. Trocamos muitas experiências e risadas.

Ao técnico de laboratório Osmar Martinelli, que me auxiliou junto ao meu orientador nos procedimentos experimentais, oferecendo preciosas sugestões.

A todos os funcionários e professores do Departamento de Engenharia Elétrica (DEE) da Unesp/Bauru e da Sessão Técnica de Pós-Graduação.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pelo apoio financeiro para consecução deste trabalho, através da bolsa de doutorado acadêmico. Processo nº. 88882.432863/2019-01.

*“Nada é tão maravilhoso que não possa ser verdade,
se for consistente com as leis da natureza.”*

(Michael Faraday)

RESUMO

Os motores de indução trifásicos pertencem ao conjunto das máquinas elétricas mais encontradas nas aplicações industriais. Devido às vantagens de baixo custo, robustez, confiabilidade e disponibilidade, muitas vezes são utilizados para operar em condições com elevadas taxas de umidade, altas temperaturas e dimensionamentos inadequados. A interrupção de um motor de indução levará à altos custos de manutenção e graves perdas financeiras devido aos tempos de paradas não programados das plantas industriais. Nesse caso, os rolamentos representam cerca de 40 a 50 % dos tipos de danos em máquinas elétricas, que afetam as condições operacionais do motor de indução, reduzindo a sua vida útil por meio de falhas. Como componente principal dos sistemas rotativos, os rolamentos ajudam a reduzir as perdas rotacionais e garantem o alinhamento do rotor em relação ao estator. Dessa maneira, a detecção e o diagnóstico precoce dos danos nos rolamentos garantem a segurança e o suporte para a manutenção preditiva das máquinas elétricas. À vista disso, inúmeras técnicas foram desenvolvidas para identificar anomalias na operação da máquina. Dentre elas, o monitoramento da corrente se destaca devido ao baixo custo e fácil acesso às plantas industriais. Com esse propósito, o presente trabalho propõe uma nova abordagem que utiliza métricas de agrupamentos de dados combinada com sistemas inteligentes na identificação de falhas nos rolamentos de um motor de indução trifásico pela assinatura da corrente do estator. Nesse caso, foram abordadas falhas que ocorrem na indústria, como os desgastes das pistas e das esferas dos rolamentos, a oxidação e os danos originados pelas das correntes de eixo. Nessa situação, foram utilizadas a transformada wavelet discreta, a largura de banda eficaz e a frequência média no processamento dos sinais amostrados. Essas técnicas possibilitam o treinamento de um sistema inteligente para identificar os danos nos rolamentos. Assim sendo, foi comparado o desempenho de uma rede neural artificial. Além disso, o *índice silhouette* foi utilizado como validação estatística da qualidade dos agrupamentos de dados obtidos a partir do conjunto de falhas nos rolamentos abordadas neste trabalho. A base de dados foi obtida por meio de experimentos laboratoriais realizados em uma máquina de indução de 4 CV sob condições de variação do conjugado para demonstrar que o método proposto não depende do torque do motor e pode ser aplicado em qualquer carregamento. Os resultados experimentais revelaram que a técnica proposta foi eficaz na identificação das falhas nos rolamentos neste trabalho.

Palavras-chave: motores de indução trifásicos, falhas em rolamentos, processamento digital de sinais, sistemas inteligentes, classificadores de padrões.

ABSTRACT

Three-phase induction motors are part of the electrical machines most commonly found in industrial applications. Due to their advantages of low cost, robustness, reliability, and availability, they are often used to operate in conditions with high humidity rates, high temperatures, and inadequate sizing. Stopping an induction motor will lead to high maintenance costs and severe financial losses due to unscheduled downtime of industrial plants. In this case, bearings represent about 40 to 50 % of the types of damage in electrical machines, which affect the operating conditions of the induction motor, reducing its lifetime through faults. As a principal component of rotating systems, bearings help reduce rotational losses and ensure alignment of the rotor relative to the stator. Thus, early detection and diagnosis of bearing damage provide safety and support for predictive maintenance of electrical machines. Given this, numerous techniques have been developed to identify anomalies in machine operation. Among them, current monitoring stands out due to its low cost and easy access to industrial plants. With this purpose, the present work proposes a new approach that uses data grouping metrics combined with intelligent systems to identify faults in the bearings of a three-phase induction motor by the stator current signature. In this case, the faults present in the industry, such as the wear of bearing races and balls, oxidation, and damage from shaft currents, were addressed. In this situation, the discrete wavelet transform, RMS-Bandwidth, and average frequency were used in the digital signal processing of the sampled signals. These techniques make it possible the training an intelligent system to identify bearing damage. Therefore, the performance of an artificial neural network was compared. In addition, the silhouette index was used as a statistical validation of the data clusters obtained from the bearing faults group addressed in this paper. The database was obtained through laboratory experiments performed on a 4 HP induction machine under conditions of varying torque to demonstrate that the proposed method does not depend on motor torque and can be applied at any loading. The experimental results revealed that the proposed technique was efficacious in the bearing fault identification in this work.

Keywords: three-phase induction motors, bearing faults, digital signal processing, intelligent systems, pattern classifiers

LISTA DE FIGURAS

Figura 1 – Principais tipos de falhas em máquinas elétricas.....	6
Figura 2 – Elementos de um rolamento	7
Figura 3 – Possíveis caminhos da corrente em rolamentos.....	10
Figura 4 – Exemplo de oxidação nos rolamentos	11
Figura 5 – Tipos de excentricidades em um motor	12
Figura 6 – Tipos de desalinhamentos em um motor	13
Figura 7 – Desbalanceamento de massa.....	14
Figura 8 – Origens dos curtos-circuitos no estator de um motor de indução.....	15
Figura 9 – Exemplo de origem de descargas parciais	17
Figura 10 – Estrutura da isolamento de um motor de alta tensão.....	18
Figura 11 – Barras quebradas.....	20
Figura 12 – Anel de extremidade quebrado	20
Figura 13 – Transformadores de potencial (TP)	23
Figura 14 – Transformador de corrente (TC).....	24
Figura 15 – Efeito Hall.....	25
Figura 16 – Sensor Hall de corrente.....	25
Figura 17 – Bobina de Rogowski.....	26
Figura 18 – Sensores de fluxo	27
Figura 19 – Sensores de temperatura	28
Figura 20 – Acelerômetro industrial	29
Figura 21 – Sensores piezoelétricos	30
Figura 22 – Sensores de torque	31
Figura 23 – Princípio de amostragem	34
Figura 24 – Espectro de Fourier do sinal amostrado.....	35
Figura 25 – Representação das distribuições de probabilidade	39
Figura 26 – Decomposição Wavelet	42
Figura 27 – Exemplo de rede neural com três camadas.....	47
Figura 28 – Organização geral da metodologia proposta.....	50
Figura 29 – Bancada experimental: diagrama das ligações	51
Figura 30 – Bancada experimental.....	53
Figura 31 – Curva de torque vs. corrente do motor de indução	54
Figura 32 – Procedimento do desgaste abrasivo dos rolamentos.....	55

Figura 33 – Procedimento da oxidação dos rolamentos.....	56
Figura 34 – Simulação dos danos por correntes de rolamento.....	56
Figura 35 – Detalhe da remoção dos rolamentos	58
Figura 36 – Rolamentos	58
Figura 37 – Sensores de corrente	59
Figura 38 – Aquisição dos dados	59
Figura 39 – Processamento dos sinais.....	62
Figura 40 – Falhas nos rolamentos: corrente da Fase A	66
Figura 41 – Falhas nos rolamentos: espectro de frequências – Fase A.....	67
Figura 42 – Desgastes no rolamento dianteiro; rolamento traseiro íntegro	69
Figura 43 – <i>Índice silhouette</i> : desgastes no rolamento dianteiro; rolamento traseiro íntegro..	70
Figura 44 – Desgastes no rolamento traseiro; rolamento dianteiro íntegro	71
Figura 45 – <i>Índice silhouette</i> : desgastes no rolamento traseiro; rolamento dianteiro íntegro..	72
Figura 46 – Desgastes nos rolamentos dianteiro e traseiro simultaneamente	72
Figura 47 – <i>Índice silhouette</i> : desgastes nos rolamentos dianteiro e traseiro	73
Figura 48 – Oxidação dos rolamentos dianteiro e traseiro.....	74
Figura 49 – <i>Índice silhouette</i> : oxidação dos rolamentos	75
Figura 50 – Danos por correntes de rolamento: elemento dianteiro e traseiro	76
Figura 51 – <i>Índice silhouette</i> : correntes de rolamento	76
Figura 52 – Falhas nos rolamentos dianteiro e traseiro.....	78
Figura 53 – Performance da RNA.....	80
Figura 54 – Histograma de erros da RNA.....	80
Figura 55 – Curvas ROC da RNA.....	81

LISTA DE TABELAS

Tabela 1 – Parâmetros do motor de indução trifásico	52
Tabela 2 – Parâmetros do gerador de corrente contínua	52
Tabela 3 – Equipamentos utilizados.....	52
Tabela 4 – Ensaios realizados: combinação das falhas nos rolamentos.....	57
Tabela 5 – Saídas da rede neural	63
Tabela 6 – Topologias testadas de RNA	64
Tabela 7 – Erro percentual das topologias das RNA	79
Tabela 8 – Área sobre a curva ROC.....	82

LISTA DE SIGLAS E DEFINIÇÕES

CA	Corrente alternada
CC	Corrente contínua
CWT	<i>Continuous Wavelet Transform</i> (Transformada Wavelet Contínua)
DFT	<i>Discrete Fourier Transform</i> (Transformada Discreta de Fourier)
DWT	<i>Discrete Wavelet Transform</i> (Transformada Wavelet Discreta)
EMD	<i>Empirical Mode Decomposition</i> (Decomposição de Modo Empírico)
FFT	<i>Fast Fourier Transform</i> (Transformada Rápida de Fourier)
FGB	<i>Fiber Bragg Grating</i> (sensor FGB)
FMM	Força Magnetomotriz
HHT	<i>Hilbert-Huang Transform</i> (Transformada de Hilbert-Huang)
HT	<i>Hilbert Transform</i> (Transformada de Hilbert)
MCSA	<i>Motor Current Signature Analysis</i> (Análise de Assinatura da Corrente do Motor)
MIT	Motors de Indução Trifásicos
NBC	<i>Naive-Bayes Classifier</i> (Classificador de Naive-Bayes)
RMS	<i>Root Mean Square</i> (Valor Quadrático Médio ou Eficaz)
RMS Bandwidth	Largura de Banda Eficaz
RNA	Redes Neurais Artificiais
PLL	<i>Phase-Locked Loops</i>
PWM	<i>Pulse Width Modulation</i> (Modulação por Largura de Pulso)
PZT	Titanato Zirconato de Chumbo
ROC	<i>Receiver Operating Characteristic</i> (Característica de Operação do Receptor)
SNR	<i>Signal-to-Noise Ratio</i> (Razão Sinal-Ruído)
SRF	<i>Synchronous Reference Frame</i> (Plano de Referência Síncrona)
TC	Transformador de Corrente
TP	Transformador de Potencial

LISTA DE SÍMBOLOS

Símbolo	Descrição	Unidade
$a_j[\cdot]$	Coeficiente de aproximação wavelet	-
$A_{[\cdot]}$	Amplitude de um sinal	-
B_{rms}	Largura de Banda Eficaz	
\overline{B}_{rms}	Produtório da Largura de Banda Eficaz das correntes das fases A, B e C do motor de indução	dB
β	Ângulo de contato entre o elemento rolante e a pista de um rolamento	rad
D_b	Diâmetro das esferas de um rolamento	m
D_r	Diâmetro da gaiola de um rolamento	m
$d_j[\cdot]$	Coeficiente de detalhe wavelet	-
dv/dt	Variação da tensão nos terminais de um motor de indução	V/s
$\delta(t)$	Trem de impulsos unitários	-
E	Energia de um sinal	-
f_{dano}	Frequência dos danos nos rolamentos	Hz
f_i, f_e, f_g e f_b	Frequências correspondentes as falhas da pista interna, externa, gaiola e esfera de um rolamento, respectivamente	Hz
$f_{máx}$	Máxima frequência que compõe um sinal	Hz
f_s	Frequência fundamental da corrente do estator	Hz
f_k^j	Neurônio k da camada j de uma rede neural	-
F_s	Frequência de amostragem	Hz
$g[\cdot]$	Filtro passa-baixas	-
$h[\cdot]$	Filtro passa-altas	-
$H\{\cdot\}$	Transformada de Hilbert-Huang	-
K	Curtose de uma distribuição de dados	-
N	Número de amostras ou comprimento de um sinal	-
$p\{\cdot\}$	Valor Principal de Cauchy	-
p_j	Probabilidade para classificação (<i>softmax</i>)	-
P	Número de polos de um motor de indução	-
$P_{[\cdot]}$	Potência de um sinal	-
S	Assimetria de uma distribuição de dados	-
S_l	Índice <i>silhouette</i>	-
σ	Desvio-padrão amostral	-

T_s	Período de amostragem	s
x_i	Amostras de um sinal	-
x_{rms}	Valor eficaz de um sinal	-
\bar{x}	Valor médio de um sinal	-
$\bar{x}(t)$	Sinal amostrado	-
$x(\cdot)$	Sinal no tempo contínuo	-
$x[\cdot]$	Sinal no tempo discreto	-
$X(\cdot)$	Espectro de frequências de um sinal	-
W	Transformação wavelet	-
Ψ	Função wavelet mãe	-
ω_c	Frequência média	rad/s
ω_s	Frequência angular de amostragem	rad/s

SUMÁRIO

CAPÍTULO 1. INTRODUÇÃO	1
1.1. Motivação e Objetivos	4
1.2. Relevância Científica	5
1.3. Organização do Trabalho	5
CAPÍTULO 2. FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS	6
2.1. Falhas de Origem Mecânica.....	7
2.1.1. Rolamentos	7
2.1.1.1. Desgastes dos Rolamentos	9
2.1.1.2. Correntes de Rolamentos	10
2.1.1.3. Oxidação dos Rolamentos.....	11
2.1.1. Excentricidade	12
2.1.2. Desalinhamento	13
2.1.3. Desbalanceamento	13
2.1.4. Sobrecarga do Carregamento Mecânico.....	14
2.2. Falhas de Origem Elétrica no Estator	15
2.2.1. Curtos-circuitos	15
2.2.2. Descargas Parciais	16
2.2.3. Isolação.....	17
2.2.4. Tensões Desequilibradas	18
2.2.5. Harmônicos.....	19
2.3. Falhas de Origem Elétrica no Rotor.....	19
2.3.1. Barras Quebradas.....	19
2.3.2. Anel de Extremidade Quebrado	20
2.4. Conclusão do Capítulo	21
CAPÍTULO 3. SENSORES APLICADOS NA DETECÇÃO DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS	22
3.1. Sensores de Tensão	22
3.2. Sensores de Corrente.....	23
3.2.1. Transformadores de Corrente	24
3.2.2. Sensores Hall	24
3.2.3. Bobinas de Rogowski	26
3.3. Sensores de Fluxo	27

3.4. Sensores de Temperatura	27
3.5. Sensores de Vibração	29
3.6. Emissão Acústica	29
3.7. Torquímetros	30
3.8. Conclusão do Capítulo	31
CAPÍTULO 4. TÉCNICAS DE PROCESSAMENTO DE SINAIS NO DIAGNÓSTICO DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS	32
4.1. Aquisição de Sinais	33
4.1.1. Amostragem.....	33
4.1.2. Ruídos no Sistema de Medida	35
4.2. Processamento de Sinais no Domínio do Tempo.....	36
4.2.1. Média Aritmética e Desvio-Padrão	36
4.2.2. Valor de Pico e Valor Eficaz	37
4.2.3. Energia.....	37
4.2.4. Curtose e Assimetria.....	38
4.3. Processamento de Sinais no Domínio da Frequência	39
4.3.1. Transformada de Fourier	39
4.3.2. Largura de Banda Eficaz	40
4.4. Técnicas Avançadas de Processamento de Sinais.....	41
4.4.1. Transformada Wavelet	41
4.4.2. Transformada de Hilbert-Huang.....	44
4.5. Classificadores de Padrões.....	45
4.5.1. Algoritmo <i>k-Means</i> e <i>Índice Silhouette</i>	45
4.5.2. Redes Neurais Artificiais.....	46
4.5.3. Classificador de Naive-Bayes.....	48
4.6. Conclusão do Capítulo	49
CAPÍTULO 5. METODOLOGIA	50
5.1. Montagem Experimental.....	50
5.1.1. Montagem das Máquinas Elétricas.....	50
5.1.2. Preparação do Rolamentos e Ensaios	55
5.1.3. Sistema de Aquisição de Dados.....	58
5.2. Detecção dos Danos nos Rolamentos	60
5.2.1. Processamento dos Sinais	60
5.2.2. Treinamento de Rede Neural Artificial	62

5.3. Conclusão do Capítulo	64
CAPÍTULO 6. RESULTADOS EXPERIMENTAIS E DISCUSSÃO	65
6.1. Sinais Amostrados.....	65
6.2. Identificação dos Desgastes nos Rolamentos.....	68
6.3. Identificação dos Danos por Oxidação	73
6.4. Identificação dos Danos por Correntes de Rolamento.....	75
6.5. Considerações sobre a Abordagem Proposta	77
6.6. Análise do Desempenho da Rede Neural Artificial	78
6.7. Conclusão do Capítulo	83
CAPÍTULO 7. CONCLUSÃO	84
PUBLICAÇÕES	86
Trabalho Completo Publicado em Anais de Congresso	86
Cooperação em Trabalho Completo Publicado em Anais de Congresso	86
REFERÊNCIAS BIBLIOGRÁFICAS	87

CAPÍTULO 1

INTRODUÇÃO

Estima-se que a utilização dos motores de indução trifásicos representa 30 a 70 % do consumo energético industrial, percentual que depende do setor econômico analisado. Cerca de 300 milhões de motores elétricos são aplicados à indústria, quantidade que aumenta em 15% por ano (DEMS; KOMEZA, 2022). A justificativa pelo seu amplo emprego está relacionada, principalmente, em suas características atrativas de baixo custo, robustez, confiabilidade e disponibilidade. Entretanto, muitas vezes os motores de indução sofrem desgastes naturais e, por vezes, são utilizados para operar em condições inadequadas, como elevada taxa de umidade, alta temperatura ambiente e sobrecarga mecânica. Desta forma, o processo de deterioração da máquina pode ser acelerado, resultando em diversos tipos de defeitos que reduzem a vida útil do motor. Situação a qual levará à altos custos de manutenção e graves perdas financeiras devido aos tempos de paradas não programados nas plantas industriais (TAHKOLA *et al.*, 2022; TRACHI *et al.*, 2016; ZHANG, S. *et al.*, 2020).

Nesse contexto, os motores de indução trifásicos são suscetíveis a diversos tipos de falhas que podem ser divididas entre as de origens mecânicas e elétricas. Dentre as falhas mecânicas, diversos trabalhos destacam que os danos nos rolamentos representam cerca de 40 a 50 % dos danos nos motores (DENG *et al.*, 2018; LEITE *et al.*, 2015; YANG, D.-M., 2021). Esse tipo de falha é associada à corrosão, desgaste, contaminação e lubrificação inadequada dos rolamentos que afetam diretamente a vida útil do motor, da mesma forma que o desalinhamento do eixo e o dimensionamento inadequado (BAZAN *et al.*, 2020; WU *et al.*, 2020).

Nas últimas décadas, inúmeras técnicas foram criadas para identificar anomalias e realizar a predição dos defeitos nos motores elétricos. Como o componente principal dos sistemas rotativos, os rolamentos ajudam a reduzir as perdas rotacionais e garantem o alinhamento do rotor em relação ao estator do motor de indução. Dessa maneira, a detecção e o diagnóstico precoce dos danos nos rolamentos garantem a segurança e fornecem um suporte para o planejamento da manutenção preditiva do motor, minimizando os tempos de inatividade da máquina (LI, J. *et al.*, 2021; PANDARAKONE; MIZUNO; NAKAMURA, 2017).

Os motores de indução trifásicos são dispositivos que possuem um sistema eletromagnético altamente simétrico. Os danos nos rolamentos levam à excentricidade entre o rotor e o estator, causando um certo grau de assimetria na configuração dos campos magnéticos da máquina. Diante disso, são originadas oscilações no torque que causam distúrbios nas forças magnetomotrizes internas do equipamento (ELBOUCHIKHI *et al.*, 2017). Essas falhas refletem em

vibrações que causam perturbações no comprimento do entreferro da motor que, por sua vez, alteram as indutâncias próprias e as mútuas das fases, causando distorções ao longo do espectro de frequências da corrente do estator (OJAGHI; SABOURI; FAIZ, 2018; SINGH, SUKHJEET; KUMAR; KUMAR, 2014).

Normalmente, a condição da integridade dos rolamentos é avaliada por meio de técnicas baseadas na aquisição dos sinais de vibração (DENG *et al.*, 2018; NAYANA; GEETHANJALI, 2017; WANG, Z. *et al.*, 2017). Contudo, a principal desvantagem desse método está associada ao elevado custo dos equipamentos, fazendo com que as suas instalações só se justifiquem para máquinas de grande porte. Em algumas aplicações, o acesso direto aos motores de indução pode ser dificultado após a montagem da planta industrial. Nesse caso, o posicionamento correto do sensores de vibração torna-se um desafio para identificar as falhas nos rolamentos (DALVAND *et al.*, 2017; TOMA; PROSVIRIN; KIM, 2020).

Dentre o conjunto de técnicas voltadas para o diagnóstico e o monitoramento dos rolamentos, também se destacam os sensores de emissão acústica, as análises térmica e de termografia infravermelha (AZEER; ALKHEDHER; GADALA, 2020; GLOWACZ *et al.*, 2018), bem como a inteligência artificial aplicada na classificação das partículas originadas pelos desgastes dos rolamentos a partir do diagnóstico dos detritos presentes na lubrificação (RANJAN; GHOSH; KUMAR, 2020). Nesse contexto, uma alternativa mais econômica é o estudo da assinatura do sinal de corrente do estator do motor de indução, uma vez que é uma técnica atrativa para as situações em que os equipamentos possuem um difícil acesso nas aplicações industriais, além de apresentar baixo custo de implantação (DALVAND *et al.*, 2018; MARTINEZ-HERRERA *et al.*, 2022; OKWUOSA; AKPUDO; HUR, 2022; SOUALHI *et al.*, 2019).

Os estudos relacionados com a detecção de danos nos motores de indução trifásicos envolvem a decomposição das correntes do estator por meio de algoritmos computacionais. Aliados com as ferramentas estatísticas, as Transformadas de Fourier, Wavelets e Hilbert-Hung formam as técnicas mais aplicadas no diagnóstico das falhas nos rolamentos. Já em outros trabalhos, a Distribuição de Wigner-Ville, a Análise das Componentes Independentes e o Discriminante Linear são empregados no monitoramento dos danos nos motores de indução (SINGH; KUMAR, 2017; YANG, T. *et al.*, 2016). Além disso, o uso de técnicas de inteligência artificial também podem ser combinados com o processamento de sinais para classificar as falhas nos rolamentos (EWERT; KOWALSKI; ORLOWSKA-KOWALSKA, 2020).

Muitas publicações se concentraram na detecção dos danos do tipo localizado nos rolamentos, ou seja, um defeito de ponto único na estrutura da peça. Normalmente, essas falhas

são emuladas por um orifício nas pistas, mas também envolvem fissuras, descamações e inden- tações. Nesse caso, esses defeitos levam a um aumento na amplitude de frequências específicas na assinatura da corrente do estator e podem ser calculadas a partir da geometria do rolamento. Entretanto, se a degradação for distribuída ao longo da estrutura da peça, como desgastes abra- sivos ou oxidação, as frequências características das falhas nos rolamentos podem não ser per- ceptíveis ou existentes. Dependendo do posicionamento e da intensidade dos danos, as compo- nentes de frequência reforçam-se ou atenuam-se (JADHAV *et al.*, 2020; SCHWENDEMANN; AMJAD; SIKORA, 2021). Além disso, as falhas distribuídas podem gerar sinais com condições não-estacionárias que aumentam a complexidade da identificação e classificação das falhas nos rolamentos de motores elétricos (GONG *et al.*, 2022; LIU, Q.; WANG; XU, 2021; TINGA- RIKAR; CHOUDHURY, 2021).

Diante disso, em Santhoshi *et al.* (2021) é proposta a utilização da Transformada de Fourier de Tempo Curto (do inglês, *Short-Time Fourier Transform* – STFT) para identificar os falhas nos rolamentos de natureza não-estacionária. No entanto, Kompella, Gopala e Srinivasa (2018) é discutido que a STFT não é suficiente para fornecer uma análise completa da assinatura da corrente do estator por utilizar uma janela fixa de amostragem. Nesse caso, discutem não ser possível estabelecer uma relação adequada entre os domínios do tempo e frequência, sendo que a magnitude dos danos nos rolamentos é baixa o suficiente quando comparada como os níveis de ruído produzido pela máquina em funcionamento. Desse modo, propõem o diagnóstico dos motores de indução mediante o uso da Transformada Wavelet, no entanto restringem-se a danos localizados por meio de ranhuras nas pistas e gaiola dos rolamentos simultaneamente.

Em Elbouchikhi *et al.* (2017) é proposto o processamento das correntes do estator uti- lizando a Transformada de Hilbert-Huang e a Decomposição de Modo Empírico. A abordagem permite identificar a assinatura das falhas nos rolamentos para diferentes graus de intensidade. Em compensação, Mbo’o e Hameyer (2016) propõem que o diagnóstico dos danos seja baseado na característica do espectro da corrente do motor por meio da seleção de frequências específi- cas e da Análise do Discriminante Linear. Já em Toma, Prosvirin e Kim (2020), a corrente do estator é monitorada por uma rede neural artificial que classifica os danos nos rolamentos.

Nesses cenários, as técnicas enumeradas limitam-se aos defeitos localizados por meio de orifícios na estrutura dos rolamentos e não tratam da degradação geral da peça que ocorrem nas aplicações industriais. Assim sendo, devido à relevância das técnicas baseadas no monito- ramento do sinal da corrente do estator, a presente pesquisa desenvolve um método que permite identificar a deterioração dos rolamentos quando as falhas são distribuídas. Além disso, a aqui-

sição da corrente é feita por meio de sensores de Efeito Hall devido a facilidade de serem encontrados no ambiente industrial, além de permitirem o monitoramento da máquina de indução sem a necessidade de interação física, isto é, dispensando modificações na planta.

1.1. Motivação e Objetivos

Em virtude da relevância dos motores de indução trifásicos nas aplicações industriais, a manutenção preditiva permite prolongar a vida útil da máquina e o processo produtivo, reduzindo quaisquer tempos de paradas não programadas que poderiam levar a perdas financeiras. Por conseguinte, o diagnóstico das falhas nos rolamentos do motor de indução permite a realização de um reparo previamente agendado do equipamento.

Considerando o contexto exposto, que apresenta as questões e os desafios relacionados ao estudo e diagnóstico das falhas em motores elétricos, esta tese propõe uma nova metodologia para localizar e identificar os danos nos rolamentos de motores de indução trifásicos. A proposta deste trabalho é utilizar um conjunto de técnicas computacionais para caracterizar as falhas nos rolamentos de acordo com a suas origens e intensidades abordadas nesta tese, tendo como base a corrente do estator obtida por meio de sensores de Efeito Hall. A análise consiste em resumir as informações que são coletadas em grupos de dados para diferenciá-los em elementos semelhantes ou distintos. A partir de uma representação tridimensional (3D), os agrupamentos são aplicados aos sistemas inteligentes para classificar os padrões observados referentes aos danos emulados nos rolamentos da máquina.

As falhas implementadas nesse trabalho são do tipo distribuído e simulam os desgastes nos rolamentos devido ao uso excessivo, falta de lubrificação e carga mecânica acoplada superior ao valor nominal, bem como os danos provocados pela oxidação por meio da deterioração da superfície metálica e o fenômeno das correntes de rolamento (modo comum), causadas pelo acionamento dos motores de indução por inversores de frequência. Nesse caso, os agrupamentos de dados são formados pela combinação das técnicas da energia dos coeficientes de detalhe wavelet, a frequência média e a largura de banda eficaz. Para classificar os resultados, o método de aprendizagem bayesiano foi utilizado por fornecer uma abordagem probabilística às falhas nos rolamentos. Dessa forma, foi comparado o desempenho de um algoritmo fundamentado em redes neurais artificiais (RNA) por permitir este tipo de análise.

A metodologia proposta foi analisada para diferentes graus do carregamento do motor. A finalidade é demonstrar que técnica desenvolvida não depende do torque, podendo ser aplicada com a máquina de indução em funcionamento sem a interrupção da planta industrial. Além

disso, o *índice silhouette* foi utilizado como uma validação estatística da qualidade dos agrupamentos utilizados no treinamento da rede neural artificial, obtidos a partir do conjunto de falhas nos rolamentos abordados neste trabalho.

1.2. Relevância Científica

Conforme observado em Gong *et al.* (2022), Liu, Wang e Xu (2021), Schwendemann, Amjad e Sikora (2021), Tingarikar e Choudhury (2021) e Jadhav *et al.* (2020), diversas técnicas têm sido propostas para a identificação das falhas nos rolamentos. Apesar disso, a maioria dos trabalhos focam apenas em danos localizados nos rolamentos por meio de orifícios e ranhuras. Perante o exposto, as falhas distribuídas acabam sendo pouco abordadas na literatura e, quando investigadas, normalmente envolvem a análise por meio de sensores de vibração. Além disso, essas abordagens não levam em consideração o efeito do carregamento do motor.

O presente trabalho contemplou a identificação das falhas distribuídas nos rolamentos de um motor de indução a partir da análise da assinatura da corrente do estator, que consiste em uma variável fácil de ser medida em um processo industrial. Além disso, também foi examinado o efeito do carregamento da máquina na metodologia proposta.

1.3. Organização do Trabalho

No Capítulo 2 apresenta-se uma revisão bibliográfica das falhas que os motores de indução trifásicos podem estar expostos, sendo que será dada uma contextualização maior as causas dos danos nos rolamentos, tema central deste trabalho.

No Capítulo 3 aborda-se os principais sensores empregados nos diversos trabalhos de identificação de falhas em máquinas elétricas, com foco nos sensores de corrente.

No Capítulo 4 discute-se as técnicas de processamento de sinais mais utilizadas a respeito do tema desta tese. Serão detalhadas algumas ferramentas no domínio do tempo e da frequência, bem como os classificadores de padrões explorados na literatura.

No Capítulo 5 descreve-se a metodologia e os conceitos aplicados no presente trabalho, o desenvolvimento da técnica proposta e a montagem experimental.

No Capítulo 6 discute-se os resultados experimentais obtidos a partir dos ensaios realizados com a metodologia proposta, com intuito de validar a técnica.

Por fim, no Capítulo 7 trata-se das conclusões relativas a esta tese e as perspectivas para pesquisas futuras.

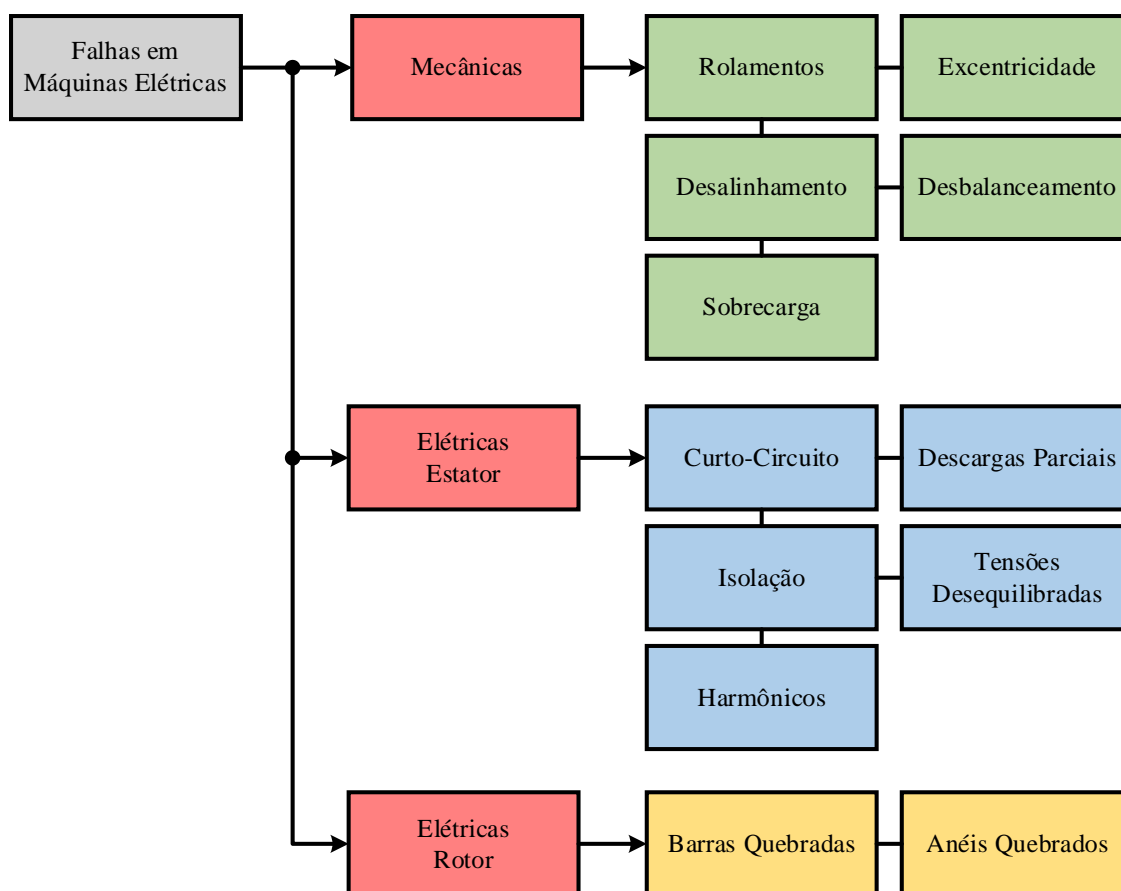
CAPÍTULO 2

FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

Os motores de indução trifásicos (MIT) formam o conjunto de dispositivos eletromecânicos mais utilizados nas aplicações industriais devido à alta capacidade de potência, desempenho robusto, baixo custo de fabricação e adaptabilidade. No entanto, a ação térmica, mecânica, elétrica e ambiental sobre o estator, rotor, rolamentos e eixo reduzem o desempenho da máquina por meio de falhas que podem comprometer o equipamento como um todo. O desgaste prematuro do motor poderá provocar tempos de paradas não programadas e perdas monetárias devido às manutenções corretivas (GANGSAR; TIWARI, 2017; KHOUALDIA; LAKEHAL; CHELLI, 2020).

As falhas nos motores de indução podem ser divididas entre origens mecânicas e elétricas, sendo que a natureza elétrica pode ocorrer no estator e/ou rotor da máquina. Na Figura 1 é mostrado os principais tipos de falhas presentes nos motores elétricos, de modo que a listagem apresentada será abordada nos próximos subcapítulos.

Figura 1 – Principais tipos de falhas em máquinas elétricas



Fonte: autoria própria

2.1. Falhas de Origem Mecânica

Neste subcapítulo serão apresentadas algumas falhas de origem mecânica que ocorrem nos motores de indução trifásicos.


2.1.1. Rolamentos

Dentre os tipos de rolamentos mais utilizados no mercado, normalmente os rolamentos de esferas, rolos cilíndricos, cônicos e autocompensadores são empregados para apoiar o rotor de uma máquina elétrica na sua carcaça, além de minimizar o atrito nos motores que estão sob rotação. Nesse caso, a dissipação de energia devido a fricção torna-se relevante nos parâmetros de eficiência do motor (HASAN; ISLAM; KIM, 2019; WANG, Z. *et al.*, 2017).

Os rolamentos são os elementos responsáveis por 40 a 50 % das falhas nos motores de elétricos (DENG *et al.*, 2018; LEITE *et al.*, 2015). Por estarem sujeitos a cargas contínuas ou esforços devido a desalinhamentos do eixo, muitas vezes se deterioram e acabam apresentando desgastes abrasivos nas pistas e esferas, fissuras, descamações e indentações que podem comprometer o desempenho da máquina (LIU, Z.; ZHANG, 2020). Nessa situação, os danos nos rolamentos são divididos em duas categorias: localizados, isto é, quando ocorrem em locais específicos da peça, como rachaduras e lascas; e distribuídos, que envolvem toda superfície do rolamento, como abrasão e oxidação (ZHANG, S. *et al.*, 2020).

Os danos nos rolamentos geram perturbações específicas no espectro de frequências da corrente do estator (BOUDINAR *et al.*, 2016; NATH *et al.*, 2020). As falhas distribuídas podem afetar todo o espectro da corrente e são muito difíceis caracterizá-las com base em uma análise comparativa de frequências. No entanto, os danos localizados são mais fáceis de identificar pois estão associados a um defeito de ponto único (PANDARAKONE; MIZUNO; NAKAMURA, 2017). Os elementos dos rolamentos são divididos entre pista externa, pista interna, elemento rolante e gaiola, como mostrado na Figura 2:

Figura 2 – Elementos de um rolamento



Fonte: adaptado de Boudinar *et al.* (2016)

Durante a operação, cada elemento do rolamento vibrará em sua frequência natural devido a defeitos locais fabricação e possíveis irregularidades em sua estrutura. A frequência natural dos elementos dos rolamentos está associada, principalmente, à banda de alta frequência, podendo variar de alguns kHz até dezenas de kHz. Este valor depende do material, formato e qualidade dos componentes utilizados em sua construção, sendo afetada pelas condições de montagem, independentemente da velocidade de operação. Por outro lado, durante a operação do motor, quando o rolamento encontra um defeito, impulsos são gerados alterando o padrão vibratório da máquina. Nessa situação, os sinais produzidos pelos impactos dependem da velocidade de rotação do motor (SHAO; KANG; LIU, 2020).

Sob outra perspectiva, a intensidade das falhas nos rolamentos está relacionada com o carregamento do motor de indução. Como a mudança no padrão vibratório da máquina provoca ondulações no torque do motor, carregamentos mais baixos evidenciam as frequências associadas aos danos nos rolamentos. Se o motor de indução operar com o carregamento nominal, a componente contínua do torque torna-se mais significativa que a amplitude das falhas, mascarando a magnitude dos danos nos rolamentos. Alguns estudos mostram o carregamento da máquina desloca as frequências características das falhas. As componentes de frequência observadas aumentam ou diminuem em função do torque solicitado ao motor (HWANG; LEE; CHA, 2018; IRFAN, 2019; KIA; HENAO; CAPOLINO, 2009).

As assinaturas das falhas nos rolamentos também dependem dos aspectos construtivos dos mesmos. As frequências características dos danos podem ser calculadas a partir geometria dos rolamentos, como mostrado nas equações (1)-(4) (BOUDINAR *et al.*, 2016; JATHURSAJAN; WIJETHUNGE, 2022; NATH *et al.*, 2020):

$$f_i = \frac{f_s N_b}{2P} \left(1 + \frac{D_b}{D_r} \cos \beta \right) \quad (1)$$

$$f_e = \frac{f_s N_b}{2P} \left(1 - \frac{D_b}{D_r} \cos \beta \right) \quad (2)$$

$$f_g = \frac{f_s}{2P} \left(1 - \frac{D_b}{D_r} \cos \beta \right) \quad (3)$$

$$f_b = \frac{f_s D_b}{D_r} \left[1 - \left(\frac{D_b}{D_r} \cos \beta \right)^2 \right] \quad (4)$$

em que f_i , f_e , f_g e f_b são as frequências correspondentes as falhas da pista interna, externa, gaiola e esfera, respectivamente; f_s a frequência fundamental da corrente do estator; N_b o número de elementos rolantes; D_b o diâmetro dos elementos rolantes; D_r o diâmetro da gaiola ou

rolamento; P o número de polos do motor; e β o ângulo de contato entre o elemento rolante e as pistas, que geralmente varia de 15 a 45° para rolamentos de esferas (AI, 2013).

As vibrações excitadas no mancal pelo rolamento afetam perfil vibratório da máquina e levam à excentricidade do rotor no estator. Esse fenômeno varia o comprimento do entreferro da máquina, perturbando a corrente do estator. Desse modo, a amplitude da frequência fundamental é modulada, gerando harmônicos no espectro de frequências da corrente. As componentes de frequência resultantes dos danos são obtidas pela expressão (5) (BOUDINAR *et al.*, 2016; NATH *et al.*, 2020):

$$f_{\text{dano}} = f_s \pm kf_n \quad (5)$$

em que $k = 1, 2, \dots$ e $f_n \in \{f_i, f_e, f_g, f_b\}$.

Quando as falhas nos rolamentos são do tipo localizadas, as expressões (1)- (5) podem ser para auxiliar na identificação dos danos. No entanto, se a degradação na peça for distribuída, as frequências características das falhas nos rolamentos podem ser mascaradas e deixam de ser perceptíveis. Dependendo do posicionamento e intensidade dos danos, as componentes de frequência das falhas reforçam-se ou atenuam-se (JADHAV *et al.*, 2020; SCHWENDEMANN; AMJAD; SIKORA, 2021).

2.1.1.1. Desgastes dos Rolamentos

Os rolamentos consistem nos componentes chave do sistema de transmissão mecânica do motor e são empregados para reduzir o efeito do atrito no rotor. Devido às forças radiais, o desgaste superficial do rolamento entre as pistas e esferas é frequentemente negligenciado devido à lenta degradação. O acúmulo dos desgastes leva a uma crescente folga radial, provocando a excentricidade dinâmica do rotor, que por sua vez deteriora as condições de trabalho da máquina (LIU, Y. *et al.*, 2022; MACHADO, T. H.; ALVES; CAVALCA, 2019).

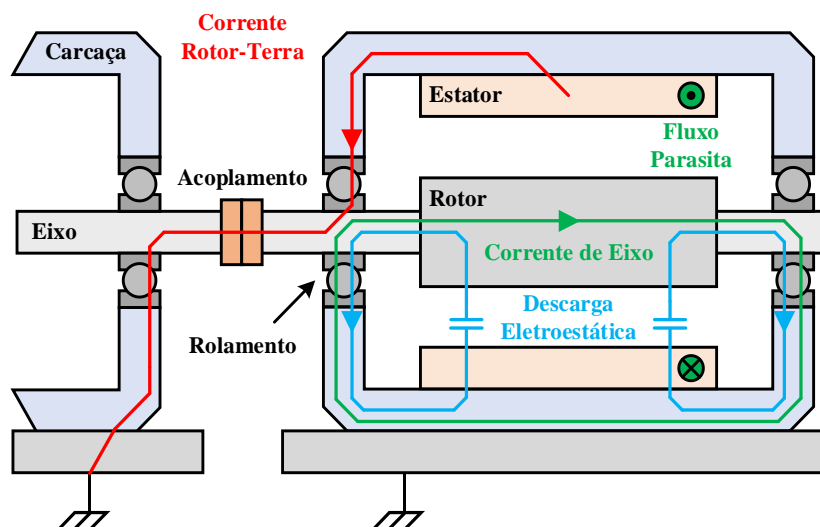
Nesse contexto, os desgastes abrasivos ocorrem naturalmente com o uso contínuo dos rolamentos. No entanto, efeitos secundários influenciam os desgastes, como a intrusão de partículas estranhas nos rolamentos (poeiras, grãos abrasivos e limalhas) e as falhas na lubrificação (falta, excesso ou lubrificante inadequado). Como consequência, o atrito no rolamento aumenta e pode resultar em problemas de pontuação, indentação e abrasão da peça. Desse modo, o desempenho do rolamento devido aos desgastes diminuirá com o passar do tempo, aumentando a excentricidade do rotor no estator. Nesse caso, problemas de aquecimento, oscilações na velocidade e torque instantâneos do motor serão acentuados (KUMAR N.; VINOOTHRAJ C.; ISHA T. B., 2018; LIU, Z.; ZHANG, 2020).

2.1.1.2. Correntes de Rolamentos

No entanto, a degradação dos rolamentos dos motores de indução pode ser acelerada devido ao efeito do fluxo de uma corrente parasita que circula no mancal da máquina. Nesse caso, está associada ao aparecimento de uma tensão de modo comum, resultante da operação da modulação PWM (do inglês, *Pulse Width Modulation*) de um inversor de frequência. Se o rolamento for exposto a uma corrente de modo comum elevada, a longo prazo poderá exceder as especificações dos corpos rolantes e destruí-los completamente. Uma densidade de corrente de $0,1 \text{ A/mm}^2$ não tem um impacto perceptível no rolamento, mas uma densidade de $0,7 \text{ A/mm}^2$ é suficiente para encurtar significativamente a sua vida útil (ABU-RUB; MALINOWSKI; AL-HADDAD, 2014; BRITO; FILHO; CHRISTOFORO, 2011).

Os possíveis caminhos de circulação das correntes modo comum são apresentados na Figura 3 (PLAZENET *et al.*, 2018):

Figura 3 – Possíveis caminhos da corrente em rolamentos



Fonte: adaptado de Plazenet *et al.* (2018)

a) Corrente Rotor-Terra: ocorre se a impedância do rotor for menor que a impedância estator à terra. Nesse caso, parte da corrente de modo comum à terra atravessa o rolamento em direção ao eixo, que pode atingir níveis elevados na faixa de 1 a 35 A (BUSSE *et al.*, 1997; PLAZENET *et al.*, 2018);

b) Tensão de Eixo: quando as capacitâncias parasitas entre o estator e a carcaça do motor são excitadas por um alto dv/dt nos seus terminais pelos inversores, um fluxo circular é estabelecido ao redor do rotor, induzindo tensões no eixo. Se a rigidez dielétrica do lubrificante no rolamento for rompida, uma corrente entre 0,5 e 20 A circulará pelo o mancal, sendo espelhada a corrente de modo comum da entrada (MUETZE; BINDER, 2007);

c) Descarga Eletroestática: frequentemente ocorrem em situações de baixas velocidades e temperaturas elevadas quando o rolamento do motor espelha tensões de modo comum. Assim, quando a camada de lubrificante é fina o suficiente, um contato ôhmico é estabelecido entre as pistas e as esferas. Por meio de descargas eletroestáticas, a corrente estabelecida é da ordem de 0,5 a 3 A (PLAZENET *et al.*, 2018).

Os danos causados pelas correntes de rolamento são difíceis de se detectar nos estágios iniciais sem desmontar o rolamento. A nível microscópico, as falhas aparecem como crateras, descamações ou soldagens, e geralmente são difíceis de se detectar por meio da análise de vibração, principalmente se forem distribuídas ao longo da peça. Se já visíveis, os danos infligidos aos rolamentos devido às correntes de modo comum diferem de outros defeitos mecânicos que podem ser encontrados em rolamentos defeituosos e diminuem o desempenho do motor de indução (KUDELINA *et al.*, 2021).

2.1.1.3. Oxidação dos Rolamentos

O desgaste corrosivo é típico dos rolamentos que operam com uma má vedação ou em máquinas expostas a altas temperaturas e elevadas taxas umidade. Nesse caso, a corrosão se manifesta com revestimentos de óxido de diferentes espessuras e cores nos rolamentos, como mostrado na Figura 4: as camadas finas ($< 40 \mu\text{m}$) são relativamente brilhantes; as camadas médias ($< 500 \mu\text{m}$) são do tipo marrom claro, alaranjando e tons de cinza; e as camadas grossas ($> 500 \mu\text{m}$) que possuem tonalidades mais escuras (LIN, C.-L.; MEEHAN, 2021; VASIĆ; STOJANOVIĆ; BLAGOJEVIĆ, 2020).

Figura 4 – Exemplo de oxidação nos rolamentos



Fonte: Vasić, Stojanović e Blagojević (2020)

Embora os rolamentos possuam uma película protetora contra a corrosão, as tensões cíclicas entre as pistas e esferas provocam microsoldagens e desgastes no revestimento de proteção dos rolamentos. Em ambiente corrosivos, a oxidação ocorre com facilidade e forma uma camada mais espessa, criando fissuras na superfície do rolamento. Desse modo, grãos de óxido

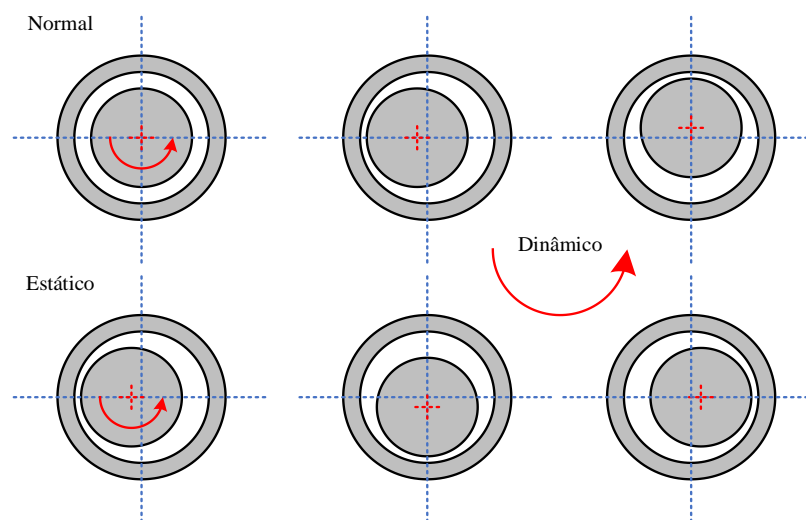
são liberados e contaminam a película lubrificante, aumentando a abrasividade e a deterioração da peça (PELEGRIN *et al.*, 2020; UPADHYAY; KUMARASWAMIDHAS, 2018).

2.1.1. Excentricidade

A excentricidade da máquina é a condição de entreferro desigual que acontece quando a distância entre o estator e o rotor não é uniforme. Quando esse fenômeno ocorre, indutâncias variáveis causam um fluxo magnético desequilibrado que cria harmônicos de falha na corrente de linha, que podem ser identificados no espectro de frequências. Existem dois tipos de falhas de excentricidade: estática e dinâmica (TOLIYAT *et al.*, 2013).

A excentricidade estática pode ser causada pela ovalização do núcleo magnético do estator ou pelo posicionamento incorreto do rotor ou estator no estágio de comissionamento. Nesse caso, o comprimento do entreferro radial mínimo é fixado no espaço. Se o conjunto rotor-eixo for suficientemente rígido, o nível de excentricidade estática não muda. No caso de excentricidade dinâmica, o centro do rotor não está no centro da rotação e a posição mínima do entreferro gira com o movimento do eixo. Esse efeito pode ser causado devido a vários fatores, como torção no eixo do rotor, desgaste ou desalinhamento do rolamento, ressonância mecânica em velocidade crítica, etc. Na Figura 5 são mostradas as excentricidades de um motor (NANDI; TOLIYAT, 1999):

Figura 5 – Tipos de excentricidades em um motor



Fonte: adaptado de Saad, Irfan e Ibrahim (2018)


As excentricidades dinâmica e estática existem mutuamente em um motor, uma vez que nunca se pode presumir que exista uma condição central ideal. Além disso, uma não uniformidade no entreferro é prevista em qualquer máquina real. Nesse caso, a combinação de excentricidades é conhecida como excentricidade mista (SAAD; IRFAN; IBRAHIM, 2018).

2.1.2. Desalinhamento

O desalinhamento é definido como uma condição na qual o eixo do motor e do dispositivo acionado não se alinham com o referencial de centro do sistema. Um alinhamento de eixo adequado reduz as forças axiais e radiais excessivas nas partes mais vulneráveis da estrutura da máquina, como rolamentos, vedações e acoplamentos. Embora se possa garantir um alinhamento preciso com o uso de equipamentos para ajustes, como relógios comparadores e níveis a laser, na prática é difícil sustentá-lo por longos períodos de tempo (LIN *et al.*, 2010; OMITA-OMU *et al.*, 2007; WANG, Y. *et al.*, 2020).

Os desalinhamentos provocam ondulações no torque do motor e são causados por variações na tolerância de fabricação, como a conformação, usinagem e acabamento das peças, falhas de operação em caixas de engrenagens ou correias, fixação do motor e posicionamento inadequado do conjunto eixo-acoplamento. Nesse caso, podem ocorrer de duas formas distintas: deslocamento paralelo ou angular, como demonstrado na Figura 6 (PARK, S.-H. *et al.*, 2020):

Figura 6 – Tipos de desalinhamentos em um motor



Fonte: adaptado de Park *et al.* (2020)

Para reduzir os efeitos do desalinhamento, geralmente emprega acoplamentos elásticos. Este tipo elemento é capaz de suportar pequenos níveis de desalinhamentos e amortecer distúrbios que ocorrem na transmissão de energia entre os eixos. Com o uso desses acoplamentos, é possível reduzir as vibrações e tensões indesejadas em outros elementos da instalação. Embora melhorem significativamente o comportamento do sistema, grandes desalinhamentos causam uma redução significativa da vida útil do motor. Além disso, reduzem a eficiência da máquina devido ao aumento das perdas provocadas pela elevação da temperatura do acoplamento por causa do atrito gerado nas conexões (VERUCCHI *et al.*, 2020).


2.1.3. Desbalanceamento

O desbalanceamento de massa em um sistema rotativo produz forças síncronas excessivas que reduzem a vida útil de vários componentes mecânicos de um motor. Uma pequena quantidade de desequilíbrio pode causar graves problemas em altas velocidades e as vibrações

causadas por este efeito podem danificar os principais componentes da máquina, como rolamentos, eixos, engrenagens e acoplamentos (MOOSAVIAN *et al.*, 2014).

O desbalanceamento ocorre quando existe um desequilíbrio no rotor, em que a linha do centro de massa não coincide com o centro geométrico, como apresentado na Figura 7. Na prática, os rotores nunca podem ser balanceados com precisão devido a erros de fabricação, como valores de tolerância, porosidade na fundição e densidade não-uniforme do material. Além disso, a expansão térmica afeta o desalinhamento interno ou a flexão do eixo, podendo levar ao mesmo efeito (AMBUR; RINDERKNECHT, 2018; RAHMAN; UDDIN, 2015).

Figura 7 – Desbalanceamento de massa



Fonte: adaptado de Karmakar *et al.* (2016)

Um desbalanceamento no rotor também pode se originar pela adição de uma massa ou sua remoção por efeito de erosões ao longo do eixo rotativo. Nesse caso, o desequilíbrio pode ser compensado por meio de pesos de balanceamento, restando apenas um pequeno erro residual dentro dos limites de vibrações da máquina (AMBUR; RINDERKNECHT, 2018; GOHARI; EYDI, 2020).

2.1.4. Sobrecarga do Carregamento Mecânico

A sobrecarga ocorre devido ao aumento do carregamento mecânico do motor acima do seu valor nominal. Como a carga no eixo torna-se excessiva, o rotor perde rotação e pode ficar bloqueado; situação equivalente a um curto-circuito. Embora a máquina de indução seja projetada para suportar sobrecargas por certos períodos de tempo, a persistência desta condição

faz com que a corrente se eleve acima do valor nominal. Nesse caso, há um aumento considerável do estresse térmico sobre o motor, reduzindo sua vida útil e causando danos na isolamento do enrolamento do estator. Os efeitos da sobrecarga são minimizados normalmente, por relés de sobrecorrente ou fusíveis de proteção conectados na alimentação da máquina (GONZALEZ-CORDOBA *et al.*, 2017; KARMAKAR *et al.*, 2016).

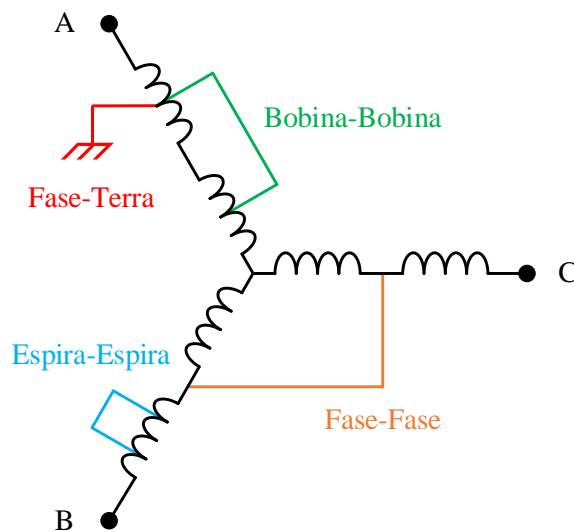
2.2. Falhas de Origem Elétrica no Estator

Neste subcapítulo serão apresentadas algumas falhas de origem elétrica que ocorrem no enrolamento do estator dos motores de indução trifásicos.

2.2.1. Curtos-circuitos

Para os motores de indução trifásicos, assim como para as outras máquinas elétricas, os curtos-circuitos representam sérios riscos para o seu funcionamento, podendo levar a desligamentos não programados e altas despesas com manutenções. Geralmente, as falhas no estator podem aparecer entre espiras, bobina-bobina, fase-fase e fase-terra, como mostrado na Figura 8, sendo que a principal causa é a quebra do isolamento do enrolamento por eventos com origens elétricas ou mecânicas, além da degradação do esmalte isolante. Em caso de falhas entre espiras da mesma fase, o motor pode continuar operando, no entanto não é capaz de funcionar nos casos de curto-circuito entre duas fases distintas. Uma espira em curto ou espiras na bobina levará, inevitavelmente, a máquina a uma falta fase à terra ou fase a fase e na rebobinagem do estator (SADEGHI; SAMET; GHANBARI, 2019; THOMSON; CULBERT, 2017).

Figura 8 – Origens dos curtos-circuitos no estator de um motor de indução



Fonte: adaptado de Adouni, J. Marques e Cardoso (2021)

As falhas no estator causam um aumento na densidade de corrente dos enrolamentos sem contribuir para a produção do torque do motor, podendo ultrapassar as especificações nominais, causando uma área com temperatura elevada ao redor e através da bobina com defeito. Essa situação é uma das principais fontes de degradação e envelhecimento do esmalte isolante, podendo progredir e causar danos irreversíveis à máquina. Em geral, os principais motivos de geração das falhas são (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017):

a) Tensões Térmicas: geradas pelo envelhecimento térmico ou sobrecargas. Normalmente, um aumento de 10 °C reduz a vida útil do isolamento do motor por um fator de dois. Um isolamento de melhor classe é recomendado se a máquina for usada em um ambiente altamente estressante;

b) Tensões Elétricas: produzidas por rupturas no isolamento do motor. Quando um dv/dt elevado é aplicado em seus terminais, os isolamentos estão sujeitos a um risco de quebra e destruição. Geralmente, esse efeito ocorre quando a magnitude da tensão ultrapassa 5 kV;

c) Tensões Mecânicas: ocorrem por várias operações de partidas e desligamentos da máquina, causando aquecimentos e resfriamentos frequentes nos isolamentos. Como resultado, rachaduras são produzidas e se tornam maiores se as operações persistirem;

d) Estresses Ambientais: substâncias externas e poluentes podem atrapalhar o funcionamento do motor. Nesse caso, uma troca térmica inadequada com o ambiente pode ocorrer e levar ao aumento da temperatura da máquina, aumentando o risco de falhas elétricas nos enrolamentos e bobinas.

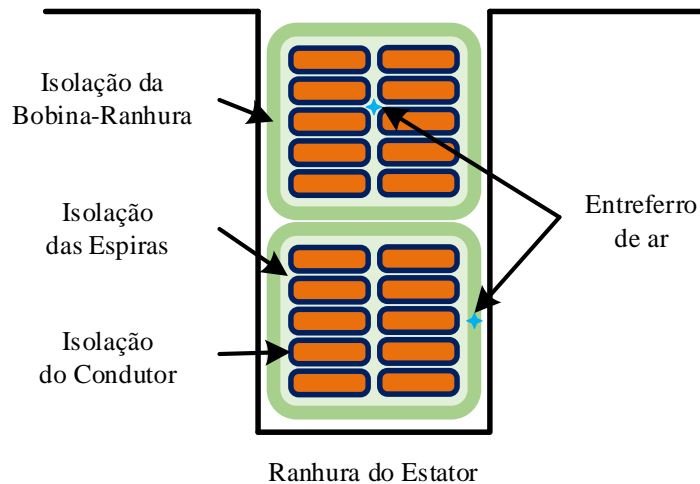
2.2.2. Descargas Parciais

As descargas parciais ocorrem devido ao efeito das imperfeições em dielétricos gasosos, líquidos ou sólidos, causando um aumento do campo elétrico local, que por sua vez pode exceder a intensidade do campo intrínseco do material e, assim, induzir uma avalanche de elétrons. Podem provocar a deterioração do material isolante e são comuns em aplicações de alta tensão (SCHUBERT; PALO; SCHLECHTER, 2018).

Nos motores elétricos, as descargas parciais são sintomas de vários processos que indicam o envelhecimento gradual e falhas no isolamento das bobinas do estator em máquinas com tensões de acionamento acima de 6 kV. Defeitos no projeto e fabricação dos enrolamentos podem causar a ocorrência de descargas significativas e, eventualmente, danificar a isolação. Além disso, as descargas parciais sempre acontecem quando há um pequeno entreferro de ar entre dois condutores de cobre ou entre uma bobina e sua ranhura no estator do motor de indução, como mostrado na Figura 9. Se o campo elétrico exceder o valor de 3 kV/mm, haverá uma

descarga parcial no interior da isolação que, com o passar do tempo, pode a destruir e evoluir para uma corrente de curto-circuito (STONE; SEDDING; CHAN, 2018).

Figura 9 – Exemplo de origem de descargas parciais



Fonte: autoria própria

O fenômeno das descargas parciais também pode estar associado ao envelhecimento térmico da isolação do enrolamento do estator, bobinas soltas nas ranhuras ao efeito corona nas terminações dos enrolamentos. Nesse contexto, muitos trabalhos buscar identificar as fontes das descargas para fornecer um diagnóstico precoce do processo de deterioração no interior do motor, a fim de determinar a taxa de degradação do isolamento e garantir a manutenção preditiva (NAIR; VISHWANATH, 2019).


2.2.3. Isolação

O isolamento utilizado no enrolamento do estator dos motores de indução está sujeito à degradação devido à contaminação, descargas parciais no material isolante, tensões mecânicas e sobrecargas térmicas. Na prática, a elevação da temperatura é a principal causa da deterioração do isolamento, porém outros fatores contribuem para sua degradação: rolamentos defeituosos, barras quebradas no rotor, vibrações da máquina, bobinas soltas nas ranhuras, desalinhamento no eixo e a excentricidade do entreferro. Além disso, materiais estranhos, como poeira e graxa nos mancais, podem causar contaminações no isolamento do estator que pode causar a redução da dissipação de calor do enrolamento (SAAD; IRFAN; IBRAHIM, 2018).

Os motores de indução podem ter sistemas de isolamento com características diferentes que dependem, por exemplo, do projeto, da potência nominal e da tensão de trabalho. Nesse caso, as duas principais topologias são os enrolamentos com fios esmaltados e barras de cobre. No primeiro caso, a metodologia é recomendada para motores de baixa tensão, uma vez que a

acomodação das espiras ocorre aleatoriamente e o estresse entre as bobinas é baixo. Se a tensão for significativamente maior, os enrolamentos com barras de cobre são necessários para minimizar o campo elétrico entre as espiras. Além disso, em máquinas acionadas por inversores de frequência, a forma de onda da tensão PWM pode causar uma distribuição desigual do potencial ao longo do enrolamento, de modo que a maior parte da queda de tensão fica sujeita somente em uma parte do isolamento. Além disso, a capacitância parasita entre as espiras e o núcleo do estator pode gerar uma queda de tensão alta nas primeiras espiras da bobina, principalmente se o dv/dt de entrada for elevado. Na Figura 10 é apresentada um exemplo da estrutura da isolação de um motor de alta tensão (CAVALLINI; FABIANI; MONTANARI, 2010):

Figura 10 – Estrutura da isolação de um motor de alta tensão



Fonte: adaptado de Cavallini, Fabiani e Montanari (2010)

2.2.4. Tensões Desequilibradas

Os desequilíbrios de tensão provocam a circulação de correntes de sequência negativa nos motores de indução, elevando as perdas de ôhmicas nos enrolamentos da máquina, produzindo oscilações no torque, potência e velocidade. Nesse caso, o aumento da energia dissipada no cobre leva a um acréscimo da temperatura das bobinas, acelerando a degradação do isolamento estator. No entanto, maiores perdas não são acompanhadas por elevações significativas da corrente de entrada, deixando de serem detectadas por algumas proteções contra sobrecorrente. Além disso, o desequilíbrio de tensão no estator altera a resistência de sequência negativa do modelo matemático do rotor do motor, causando aquecimentos localizados em curtos períodos de tempo. Para as máquinas do tipo gaiola de esquilo, a resistência de sequência negativa é da ordem de cinco vezes maior que a resistência de sequência positiva (DONOLO; BOSSIO; DE ANGELO, 2011).

A natureza dos desequilíbrios inclui magnitudes de tensão desiguais na frequência fundamental do sistema, isto é, subtensões e sobretensões, além de desvios no ângulo de fase. Um dos principais motivos desse fenômeno é a distribuição desigual de cargas monofásicas na rede, que podem mudar continuamente em um sistema trifásico. Causas adicionais envolvem assimetrias nas impedâncias dos enrolamentos dos transformadores, operações delta-abeto, linhas de transmissão desbalanceadas, fusíveis queimados em bancos de capacitores trifásicos e mau contato em condutores elétricos (JOUANNE, VON; BANERJEE, 2001).

2.2.5. Harmônicos

As componentes harmônicas na tensão de alimentação das máquinas de indução causam a circulação de correntes harmônicas, inter-harmônicas e sub-harmônicas no enrolamento do estator, resultando em fenômenos nocivos como as pulsações de torque, vibrações, aumento das perdas e temperatura do motor (GNACIŃSKI *et al.*, 2019; SAPENA-BANO *et al.*, 2018). Nesse caso, existem níveis aceitáveis para distorções harmônicas na alimentação fornecida aos motores de indução, sendo que o funcionamento contínuo nessas condições leva a degradação da isolamento da máquina (IEEE STD 519-2014, 2014).

2.3. Falhas de Origem Elétrica no Rotor

Neste subcapítulo serão apresentadas algumas falhas de origem elétrica que ocorrem no rotor dos motores de indução trifásicos.


2.3.1. Barras Quebradas

Um rotor bobinado pode ser afetado pelos mesmos tipos de falhas do estator do motor de indução trifásico. No entanto, na configuração gaiola de esquilo, a barra quebrada do rotor (Figura 11) é um tipo de dano que produz oscilações nas correntes e no torque eletromagnético da máquina. Para valores de inércia no eixo elevados, as pulsações do conjugado tornam-se mais evidentes, enquanto que para grandezas mais baixas, oscilações na velocidade e na amplitude da corrente do estator são mais perceptíveis (TRIGEASSOU, 2011).

As falhas do rotor podem ser causadas por uma combinação de diferentes tensões que atuam no rotor da máquina devido a aspectos eletromagnéticos, térmicos, dinâmicos, ambientais e mecânicos. As principais causas das barras quebradas são: forças eletromagnéticas desequilibradas, ruídos e vibrações na máquina; superaquecimento da gaiola de esquilo, causando a dilatação térmica das barras; cargas mecânicas pulsantes, flutuações de tensão e oscilações no torque; lâminas do núcleo soltas, peças desgastadas e falhas nos rolamentos; imperfeições no

processo de fabricação; contaminação e abrasão do material do rotor devido a produtos químicos ou exposição à umidade (HASSAN *et al.*, 2018).

Figura 11 – Barras quebradas




Fonte: adaptado de Trigeassou (2011)

As barras quebradas no rotor também podem causar faíscas, tornando-se uma preocupação séria em áreas de trabalho com grandes periculosidades. Se uma ou mais barras forem quebradas, as saudáveis serão forçadas a transportar correntes adicionais, reduzindo a sua vida útil, bem como a do material do núcleo devido às altas temperaturas nos pontos de quebra. Se a detecção precoce não for feita, outras falhas poderão surgir no motor, como os rolamentos, excentricidade, enfraquecimento da isolamento (HASSAN *et al.*, 2018; TRIGEASSOU, 2011).

2.3.2. Anel de Extremidade Quebrado

Assim como as barras quebradas, a quebra da seção do anel do rotor (Figura 12) é uma falha frequente no motor de indução. Normalmente, as principais causas são as bolhas de ar na fundição ou os diferentes graus de dilatação térmica entre as barras e os anéis, que estão submetidos a correntes maiores que os condutores do rotor. Devido a esse fenômeno, o mau dimensionamento do anel leva a deterioração das condições de operação ou uma sobrecarga de torque e corrente da máquina, podendo levar a outros tipos de falhas (TRIGEASSOU, 2011):

Figura 12 – Anel de extremidade quebrado



Fonte: adaptado de Trigeassou (2011)

2.4. Conclusão do Capítulo

Neste capítulo foram apresentados os principais tipos de falhas que acometem as máquinas elétricas. Os danos relacionados aos rolamentos variam de 40 a 50 % de todos os defeitos apresentados por um motor de indução trifásico, principal equipamento das aplicações industriais. Com a revisão destacada, foi exposto o comportamento dos principais tipos de falhas nos rolamentos, que envolvem os desgastes abrasivos, a oxidação e os danos originados pela circulação das correntes de modo comum devido ao acionamento por inversores de frequência. Além disso, verifica-se que se os danos forem do tipo localizados, componentes de frequências podem ser calculadas em função da origem dos defeitos: pistas, gaiola e esferas. Todavia, se as falhas ocorrem de forma distribuída, componentes de frequência podem se reforçar ou atenuar, dificultando a análise da assinatura dos danos. O próximo capítulo descreve os principais sensores utilizados na detecção das falhas em motores de indução trifásicos.

CAPÍTULO 3

SENSORES APLICADOS NA DETECÇÃO DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

A detecção de falhas é um processo vital para identificar o desenvolvimento de defeitos nos motores de indução trifásicos. A partir do monitoramento da máquina, é possível acompanhar a integridade dos seus elementos, observando a formação ou progresso de danos. Nesse contexto, é possível agendar a manutenção preditiva e garantir o mínimo tempo de inatividade nos processos industriais, reduzindo os tempos de paralizações. Conseqüentemente, o sistema de monitoramento permite reduzir os custos de manutenção, prever com exatidão o tipo de falha no motor, aumentar a sua confiabilidade, otimizar a mão de obra e o uso das peças sobressalentes, maximizando o desempenho do processo industrial (POPESCU; AIORDACHIOAIE; CULEA-FLORESCU, 2022; SAAD; IRFAN; IBRAHIM, 2018).

Embora existam uma variedade de técnicas desenvolvidas e aprimoradas para o monitoramento e a detecção das falhas nos motores de indução, os sensores constituem um dos principais elementos para a aquisição dos dados e posterior processamento dos sinais em função do método empregado (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017). Nesse capítulo será abordado os principais sensores utilizados na identificação de falhas em motores elétricos.


3.1. Sensores de Tensão

Um dos sinais mais conhecidos e de grande importância para os motores de indução é a tensão, responsável em fornecer a quantidade de torque necessária para a rotação da máquina. Embora nas aplicações que envolvam conexão direta à rede, a tensão normalmente não é utilizada no diagnóstico das falhas nos rolamentos, mas sim no monitoramento da alimentação dos motores. Já em máquinas acionadas por drivers, como inversores de frequência, o uso dos sensores de tensão é opcional, uma vez que o dispositivo de acionamento fornece o perfil da tensão aplicada por meio do próprio hardware. Nos casos de partidas diretas ou quando não há acesso às interfaces dos drivers, os transdutores de tensão nos terminais dos motores são necessários. Nesse caso, os transformadores de potencial (TP's – Figura 13) se destacam por serem ferramentas promissoras para medir e reproduzir a tensão dos terminais da máquina. Os TP's fornecem isolamento galvânica entre o motor de indução, que está sujeito às altas tensões, e os sistemas de aquisição de dados, que operam com valores menores de potenciais (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017).

Os TP's são dispositivos que sofrem com os erros de relação de transformação e ângulo de fase devido a magnetização e a impedância de dispersão dos seus enrolamentos. Geralmente

não permitem transitórios curta duração ou de alta frequência, no entanto os harmônicos são medidos com precisão satisfatória (NAIDU; KAMARAJU, 2013). Normalmente, operam com uma ampla gama de amplitudes e frequências, que devido as limitações do núcleo, podem se estender a poucos kHz. Para frequências mais elevadas, os efeitos das capacitâncias parasitas tornam-se significativos. Na prática, os TP's são empregados para instrumentações de sinais com frequências da ordem da 50ª harmônica da tensão fundamental (CROTTI *et al.*, 2017; TAHIR; TENBHOLEN; MIYAZAKI, 2021).

Figura 13 – Transformadores de potencial (TP)
(a) Baixa tensão (b) Média tensão (c) Trifásico



Fonte: Mitsubishi Electric (2018)

Uma das principais aplicações que envolvem o uso dos sensores de tensão é a detecção de falhas de curto-circuito no enrolamento do estator. Embora específica, essa técnica consiste em detectar harmônicos na tensão durante a etapa de desligamento do motor. Devido ao fluxo residual da máquina, a corrente ainda flui pelas barras do rotor e nas bobinas em curto-circuito do estator, sendo que as tensões induzidas pelas falhas induzem harmônicos na tensão terminal que dependem da frequência decrescente da corrente do estator e da desaceleração do motor até a parada (TOLIYAT *et al.*, 2013).


3.2. Sensores de Corrente

Diferente da tensão, a corrente dos motores de indução é o sinal mais abordado e útil nos procedimentos de diagnósticos de falhas. Tanto na análise no domínio do tempo quanto no domínio da frequência, a Análise de Assinatura da Corrente do Motor (do inglês, *Motor Current Signature Analysis – MCSA*) tem sido objeto de várias pesquisas. Nesse contexto, a detecção dos danos nos rolamentos com base na corrente do estator tem sido tendência das investigações atuais. A vantagem desse tipo de técnica é que o sinal da corrente reflete o comportamento das falhas nas máquinas e pode ser facilmente amostrada. Além disso, diferente da tensão terminal, que possui riscos de segurança se medidas preventivas não forem consideradas, a aquisição da corrente é segura (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017; TANG; DAI; DU, 2022).

3.2.1. Transformadores de Corrente

Os transformadores de corrente (Figura 14) são amplamente utilizados para a detecção de correntes alternadas, possuindo uma largura de banda poucos Hz até alguns kHz. Esta técnica fornece um isolamento galvânico e consome pouca energia, sendo que normalmente não requer circuitos adicionais de acionamento. Se o núcleo for sólido, a saturação magnética tem que ser levada consideração durante o projeto, principalmente na presença de componentes nas baixas frequências ou níveis CC, levando a um aumento do tamanho e do custo. Além disso, a histerese do material do núcleo diminui a precisão da medição e as correntes parasitas nas altas frequência comprometem o seu desempenho (XIAO *et al.*, 2003).

Figura 14 – Transformador de corrente (TC)
(a) Baixa tensão (b) Média tensão (c) Núcleo toroidal




Fonte: Mitsubishi Electric (2018)

3.2.2. Sensores Hall

Quando um elemento condutor de corrente é submetido a um campo magnético, uma diferença de potencial é manifestada perpendicularmente à corrente e ao campo. Esse princípio é conhecido como de efeito Hall, ilustrado na Figura 15, descoberto em 1.879 pelo físico Edwin Herbert Hall (WIELGOS; DOLEZALEK; MIN, 2020).

Na Figura 15a é apresentada uma placa fina de material condutor, percorrida por uma corrente elétrica fornecida por uma bateria. Um par de pontas de provas é conectado a um voltmetro, sendo opostas uma à outra ao longo das laterais da placa, de forma que a tensão medida seja nula. Quando um campo magnético perpendicular é aplicado, o fluxo de corrente sofre uma distorção, como mostrado na Figura 15b, e uma pequena tensão é induzida. Esse fenômeno é chamado de efeito Hall e tem como vantagem a ocorrência em condições de estado estacionário, isso é, a diferença de potencial na placa persiste mesmo quando a corrente e o campo magnético são constantes ao longo do tempo (POPOVIC, 2004; RAMSDEN, 2006).

Figura 15 – Efeito Hall



Fonte: adaptado de Ramsden (2006)

O fenômeno observado na Figura 15 mostra que os elétrons se concentram em apenas uma extremidade da placa condutora, o que torna a outra desprovida de cargas e estabelece uma diferença de potencial. Em contrapartida, as aplicações que envolvem os materiais semicondutores são mais vantajosas, pois permitem uma concentração de portadores positivos na periferia da placa por meio de lacunas, aumentando a tensão induzida quando comparada com as situações que envolvem somente os metais (POPOVIC, 2004).

Os sensores Hall são dispositivos isolados e não-invasivos que podem ser utilizados tanto na detecção de corrente contínua (CC) quanto alternada (CA) da ordem centenas de kHz com alta precisão. Devido à sua estrutura simples e compatibilidade com os dispositivos microeletrônicos, podem ser encapsulados em uma única estrutura, aumentando à sua aplicabilidade, como mostrado na Figura 16. Cerca de 90 % das aplicações que envolvem campos magnéticos e medições de correntes utilizam sensores baseados no efeito Hall (RIPKA; ARAFAT, 2019; XIAO *et al.*, 2003).

Figura 16 – Sensor Hall de corrente



Fonte: LEM (2017)

3.2.3. Bobinas de Rogowski

A bobina de Rogowski (Figura 17) consiste em um enrolamento de núcleo de ar com formato toroidal, sendo instalada ao redor do condutor no qual se deseja medir a corrente. Nesse caso, a área de seção transversal da bobina é constante e a tensão induzida é proporcional à taxa de variação da corrente no tempo. Portanto, um circuito integrador se faz necessário para medir o sinal original da corrente (IBRAHIM; ABD-ELHADY, 2021; LI, Z. *et al.*, 2020).

Figura 17 – Bobina de Rogowski



Fonte: LEM (2020)

A precisão da medição da bobina de Rogowski depende, principalmente, da técnica de integração utilizada. Os integradores passivos são mais simples de serem implementados e são compostos apenas por um resistor e capacitor. Operam com constantes de tempo elevadas para garantirem que componentes de baixa frequência não sejam distorcidas. Contudo, a capacidade de atuar na alta frequência é deteriorada por comportarem como filtros passa-baixas. Diferente dos integradores passivos, os circuitos ativos utilizam os amplificadores operacionais para estender a largura de banda, todavia o ganho do circuito pode amplificar ruídos de medição que possuem componentes de baixa frequência (TAN *et al.*, 2022).

As principais características da bobina de Rogowski são (XIAO *et al.*, 2003):

- Facilidade de uso, alta compactação e baixo peso;
- Ampla faixa de medição para bobinas do mesmo tamanho;
- Permitem a medição de transientes de curta duração;
- Linearidade, uma vez que não há saturação magnética devido ao núcleo de ar;
- Isolamento e medição não-invasiva entre o circuito instrumentado e o sensor;


Nas bobinas de Rogowski, a principal dificuldade em conseguir uma largura de banda ampla são as restrições conflitantes nas operações de alta e baixas frequências. No entanto, uma combinação de integradores ativos e passivos tem sido aplicada para resolver esse tipo de problema (LI, H. *et al.*, 2021; TAN *et al.*, 2022).

3.3. Sensores de Fluxo

A densidade do fluxo magnético é o principal elemento para a transferência de energia entre os enrolamentos do estator e do rotor da máquina de indução. Apesar da tensão terminal ser o sinal original da alimentação do motor, a rotação é controlada pelo torque desenvolvido pelo fluxo magnético. Nesse contexto, vários estudos mostram que as falhas das máquinas refletem, de alguma forma, na sua assinatura magnética. Assim, os fluxos de dispersão e de entreferro podem ser utilizados para obter as informações sobre a localização dos danos (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017; LIU, X. *et al.*, 2019).

A exigência dos sensores de fluxo no entreferro é bastante restritiva e pode reduzir a confiabilidade do monitoramento, sendo recomendada o uso para baixas velocidades. Uma alternativa é o emprego de bobinas extremamente finas alocadas em torno das ranhuras do estator ou enrolamentos especiais junto com as bobinas principais (Figura 18a). Já na aquisição dos fluxos de dispersão, a leitura pode ser realizada no exterior da máquina ou no final dos anéis do enrolamento do estator por meio de transdutores de efeito Hall (Figura 18b). Nesse caso, circuitos amplificadores devem ser utilizados para melhorar a sensibilidade da medição do fluxo magnético no interior da máquina (DORRELL, 2005; KUMAR, P. S. *et al.*, 2021; LAMIM FILHO; PEDERIVA; BRITO, 2014; RASHID, 2018).

Figura 18 – Sensores de fluxo
(a) Enrolamento especial (b) Efeito Hall



Fonte: Lamim Filho; Pederiva; Brito (2014) e Texas Instruments (2015)

3.4. Sensores de Temperatura

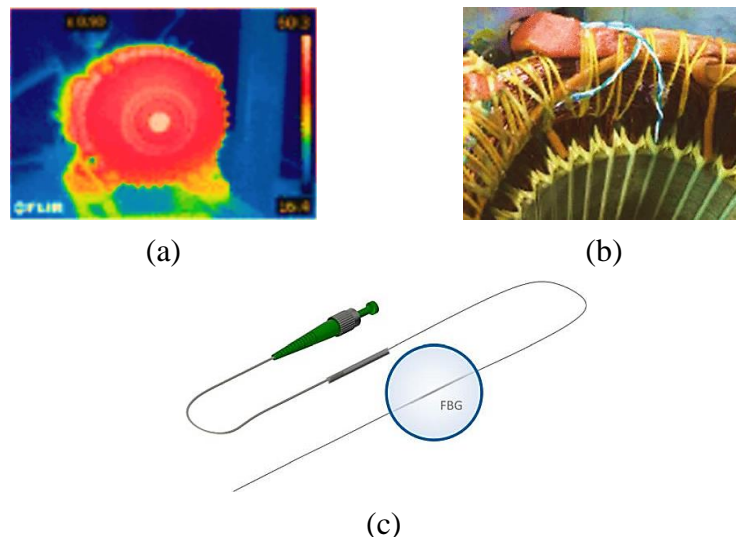
A detecção de temperatura é uma das técnicas mais comuns no monitoramento de motores elétricos. Dependendo do tipo de falha, diferentes partes da máquina são submetidas as tensões térmicas. Em um motor de indução saudável, o final dos anéis do enrolamento é altamente aquecido devido ao fluxo de dispersão, enquanto que em uma máquina com defeito, cada peça apresenta um nível de saturação térmica. Assim, quando há existência de barras quebradas

ou falhas de curtos-circuitos no estator, a área vizinha à região de dano revela uma temperatura consideravelmente alta, desequilibrando a distribuição térmica do motor. No caso de falhas por excentricidades, assim como outros tipos de danos, há um aumento geral da temperatura da máquina (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017).

Nesse contexto, a alta temperatura resultante degrada o isolamento dos enrolamentos do motor, prejudicando a saúde das espiras saudáveis. Nos casos dos curtos-circuitos entre espiras no estator, se as falhas não forem detectadas e corrigidas nos estágios iniciais, o processo se propaga em torno do ponto de alta densidade térmica, deteriorando a isolamento até danos mais significativos, como faltas fase-fase ou fase-terra que, em última análise, levam à perda e parada total da máquina (MOHAMMED; MELECIO; DJUROVIĆ, 2019).

Diferentes técnicas de medição de temperatura podem ser empregadas na análise das falhas nos motores de indução. Nesse caso, os sensores infravermelhos (Figura 19a) podem ser utilizados como método não-invasivo e na identificação de falhas no estator e nos rolamentos da máquina. Já os termopares (Figura 19b), por sua vez, são uma ferramenta invasiva, pois devem ser posicionados diretamente na carcaça do motor ou internamente, como no final dos anéis do enrolamento do estator. Diante disso, uma alternativa para o sensoriamento térmico no interior da máquina entre o rotor e o estator é a tecnologia de grades de Bragg em fibras ópticas, também conhecida como sensor FGB (do inglês, *Fiber Bragg Grating* – Figura 19c), que apresenta tamanho reduzido, elevada robustez, flexibilidade, vida útil longa e imunidade eletromagnética (BOGLIETTI *et al.*, 2018; CHOUDHARY; GOYAL; LETHA, 2021; MOHAMMED; DJUROVIĆ, 2018).

Figura 19 – Sensores de temperatura
(a) Infravermelho (b) Termopar (c) Sensor FGB



3.5. Sensores de Vibração

Os motores de indução, quando em operação, geram vibrações que dependem de forças radiais originadas pelo fluxo do entreferro, mantendo relações com a força magnetomotriz (FMM) e a relutância magnética do circuito. Na presença de assimetrias no rotor, a FMM sofre distorções e a relutância do núcleo se modifica com o entreferro, alterando o padrão de vibração da máquina. Pela análise desse tipo de sinal, danos nos rolamentos, excentricidades, desalinhamentos e desbalanços podem ser identificados (KARMAKAR *et al.*, 2016). Além disso, as falhas de natureza elétrica, como curtos-circuitos no enrolamento do estator, também produzem oscilações que alteram a assinatura da vibração da máquina, uma vez que tendem a distorcer o fluxo magnético do entreferro (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017).

A força da vibração está linearmente relacionada com a aceleração da oscilação. Nesse caso, os acelerômetros (Figura 20) são os sensores típicos no monitoramento desse efeito. Constituem uma técnica invasiva, podendo ser montados magneticamente e posicionados pelo usuário ao redor do motor para capturar o padrão de vibração em diferentes localidades. Normalmente são adequados para máquinas de pequeno porte, uma vez que o custo associado ao sensor tem relação com a técnica de identificação de falhas utilizada e pode ser elevado (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017; SAAD; IRFAN; IBRAHIM, 2018).

Figura 20 – Acelerômetro industrial



Fonte: Hansford Sensors (2020)

3.6. Emissão Acústica

As vibrações geradas pelos motores elétricos produzem ruídos acústicos que possuem um espectro de frequências característico. Na presença de falhas, como danos nos rolamentos ou excentricidades no entreferro, esse espectro se altera. Nesse caso, a técnica da emissão acústica pode ser realizada com a utilização de microfones, no entanto a localização dos danos não pode ser determinada com muita exatidão. Na prática, em um ambientes barulhentos, como as plantas industriais nas quais várias outras máquinas estão operando, dependendo das faixas de

frequência dos sons de interesse, a ferramenta acústica não é recomendada (GLOWACZ, 2018; KARMAKAR *et al.*, 2016).

Para motores de pequeno porte, a emissão acústica é medida por meio de transdutores piezoelétricos (Figura 21), que são dispositivos que produzem eletricidade a partir do estresse mecânico (som) submetido. Esses transdutores podem ser caros, limitando a técnica de análise acústica na identificação das falhas. Entretanto, diversos trabalhos tem focado em sensores de baixo custo, como os transdutores piezoelétricos de titanato de zirconato de chumbo (PZT), que são finos e baratos (BATAL *et al.*, 2020; KARMAKAR *et al.*, 2016; LUCAS, G. B. *et al.*, 2020; PAPATHANASOPOULOS *et al.*, 2021).

Figura 21 – Sensores piezoelétricos
(a) Industrial (b) Cerâmico



Fonte: Multicomp PRO (2019) e Shinkawa (2015)

3.7. Torquímetros

A maioria das falhas nos motores de indução produzem frequências harmônicas específicas no entreferro. Como o torque eletromagnético não pode ser medido diretamente, a alternativa é medir esse valor no eixo da máquina, mesmo que não corresponda ao conjugado real no entreferro. Nesse contexto, alguns trabalhos utilizam a assinatura do torque para classificar as falhas nos motores em regime permanente, enquanto que outros focam nos dados coletados durante as partidas da máquina a vazio para determinar a existência de barras ou anéis de extremidade quebrados (KARMAKAR *et al.*, 2016).

Os sensores de torque podem ser conectados diretamente no eixo do motor, como mostrado na Figura 22a. Esse método consiste em uma técnica invasiva e o acoplamento mecânico pode alterar a dinâmica do motor, permitindo que os sinais utilizados na identificação das falhas possam ser afetados. Outra opção, embora pouco empregada, envolvem os sensores baseados no efeito Hall (Figura 22b), que compõem um método não-invasivo (FAIZ; GHORBANIAN; JOKSIMOVIĆ, 2017).

Figura 22 – Sensores de torque
(a) Acoplamento mecânico (b) Efeito Hall



Fonte: Honeywell (2014) e TT Electronics (2019)

3.8. Conclusão do Capítulo

Neste capítulo foram apresentados os principais tipos de sensores empregados na detecção dos danos em motores de indução trifásicos. Com base na revisão abordada, os sensores de corrente, vibração e emissão acústica são amplamente utilizados no monitoramento das falhas nos rolamentos. Nesse contexto, embora existam vários estudos na literatura, os sensores de vibração e emissão acústica constituem uma técnica invasiva, pois exigem o acesso direto à máquina, que pode ser dificultado de acordo com a configuração da planta industrial. Por outro lado, os sensores de corrente se mostram uma alternativa mais econômica, uma vez que é uma variável não-invasiva e fácil de ser amostrada. Por apresentar um baixo custo de implantação, consiste em uma metodologia atrativa para as situações que envolvem equipamentos de difícil acesso. O próximo capítulo descreve as principais técnicas de processamento de sinais utilizadas na detecção das falhas nos rolamentos.

CAPÍTULO 4

TÉCNICAS DE PROCESSAMENTO DE SINAIS NO DIAGNÓSTICO DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

Nos últimos anos, diversas técnicas para o monitoramento das condições operacionais dos motores de indução foram desenvolvidas para auxiliar no prolongamento de sua vida útil. Algumas dessas metodologias incluem diversos tipos de sensores, como a medição de corrente, torque, temperatura, vibração e densidade de fluxo magnético. Assim sendo, o processamento digital de sinais é uma abordagem matemática e computacional que permite obter as informações necessárias a partir das grandezas medidas para identificar as falhas presentes nas máquinas elétricas (AMIRAT *et al.*, 2018; WEI *et al.*, 2019).

Os métodos do diagnóstico e classificação das falhas utilizam recursos no domínio do tempo, domínio da frequência ou ambos, simultaneamente, a partir dos dados adquiridos. Nesse caso, muitos trabalhos buscam características no domínio do tempo, como valor de pico, eficaz, média, desvio padrão e outros parâmetros estatísticos. Dependendo da característica da falha, a análise no domínio da frequência fornece mais informações para o monitoramento da máquina por meio do espectro de frequências, gráficos de densidade espectral, periodogramas, entre outros. Contudo, sinais com natureza não-estacionária dependem de técnicas mais avançadas por meio de recurso híbridos entre o tempo-frequência, como as Transformadas Wavelets e Hilbert-Hung. Além disso, muitos pesquisadores aliam as ferramentas de processamento sinais com os algoritmos de inteligência artificial e classificadores de padrões (DUQUE-PEREZ *et al.*, 2019; NAYANA; GEETHANJALI, 2017).

As falhas nos rolamentos de ponto único podem ser detectadas por técnicas de processamento de sinais nos domínios do tempo ou frequência por apresentarem características estacionárias. No entanto, quando os danos presentes são distribuídos, os elementos dos rolamentos vibram mais aleatoriamente à medida que as falhas se espalham, desenvolvendo folgas radiais maiores que influenciam a excentricidade dinâmica conforme a deterioração da peça aumenta. Assim, a máquina rotativa opera sob condições não-estacionárias, exigindo métodos de análise e interpretação com recursos no tempo e frequência (DING *et al.*, 2022; KASIM; MOHAMED; NUAWI, 2022).

Considerando o contexto exposto, o presente capítulo apresenta as principais ferramentas de processamento de sinais que podem ser utilizadas no diagnóstico de falhas nos motores de indução, em especial para os danos nos rolamentos, bem como uma breve introdução a respeito de alguns pontos-chaves sobre a aquisição de sinais.

4.1. Aquisição de Sinais

A maioria dos sinais encontrados nas aplicações que envolvem a engenharia possuem uma natureza analógica e são dependentes de uma variável contínua, como o tempo ou espaço. Esses sinais podem ser processados diretamente por sistemas analógicos para alterar suas características ou extrair alguma informação desejada. Nesse cenário, o processamento digital de sinais fornece um método alternativo para analisar o sinal analógico por meio de uma interface conhecida como conversores analógico-digital. Esses dispositivos permitem transformar os sinais contínuos em digitais para que possam ser manipulados por microprocessadores. Assim, os sinais digitais são discretos tanto no tempo quanto na amplitude amostrada (PROAKIS; MANOLAKIS, 2014; THYAGARAJAN, 2019).

4.1.1. Amostragem

A amostragem é o procedimento que permite converter o sinal contínuo em sua versão discreta como uma sequência de dados. O conversor analógico-digital lê a magnitude instantânea do sinal de tempo contínuo em intervalos constantes que são múltiplos inteiros de um período específico de amostragem. A representação matemática é dada por (KIM, 2021):

$$x[n] = x(nT_s) \quad (6)$$

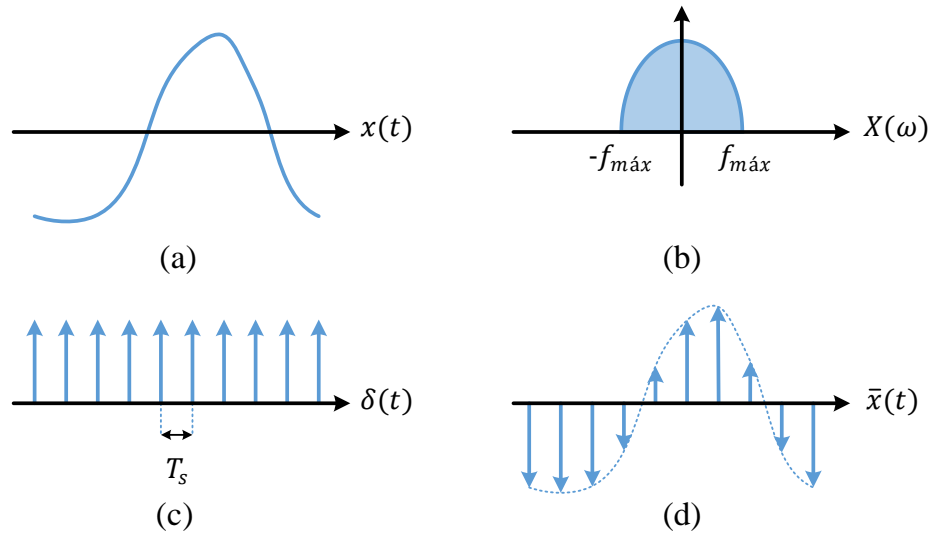
em que $x(\cdot)$ é sinal no tempo contínuo, $x[\cdot]$ o sinal no tempo discreto ou amostrado, n o número de amostras e T_s o período de amostragem.

Para que um sinal no tempo contínuo possa ser processado no tempo discreto a partir das suas amostras, a taxa de amostragem deve ser suficientemente alta para permitir a reconstrução do sinal original sem erros. Na prática, o Teorema de Nyquist-Shannon postula que ela deve ser no mínimo o dobro da máxima frequência a ser adquirida (LATHI, 2006; PROAKIS; MANOLAKIS, 2014).

Para provar o Teorema da Amostragem, considere o sinal $x(t)$ da Figura 23a, cujo o espectro $X(\omega)$ é limitado pela frequência máxima $f_{m\acute{a}x}$ na Figura 23b. A amostragem $\bar{x}(t)$ pode ser realizada multiplicando $x(t)$ pelo trem de pulsos $\delta(t)$, que é constituído por impulsos unitários periodicamente repetidos a cada T_s segundos, como exibido na Figura 23c. O sinal amostrado $\bar{x}(t)$ é mostrado na Figura 23d (LATHI, 2006; OPPENHEIM; WILLSKY, 2010).

Sabendo que o trem de pulsos é um sinal periódico, na equação (7) é mostrada a decomposição na série de Fourier de $\delta(t)$, em que F_s é a frequência de amostragem (HAYKIN; VEEN, 2001; LATHI, 2006; OPPENHEIM; WILLSKY, 2010):

Figura 23 – Princípio de amostragem



Fonte: adaptado de Lathi (2006)

$$\delta(t) = \frac{1}{T_s} [1 + 2 \cos(\omega_s t) + 2 \cos(2\omega_s t) + 2 \cos(3\omega_s t) + \dots] \quad (7)$$

$$\omega_s = 2\pi F_s = \frac{2\pi}{T_s} \quad (8)$$

Portanto, o sinal amostrado $\bar{x}(t)$ é dado por:

$$\bar{x}(t) = x(t)\delta(t) \quad (9)$$

$$\bar{x}(t) = \frac{x(t)}{T_s} [1 + 2 \cos(\omega_s t) + 2 \cos(2\omega_s t) + 2 \cos(3\omega_s t) + \dots] \quad (10)$$

Como a transformada de Fourier de $x(t)$ é $X(\omega)$, por propriedades no deslocamento da frequência, tem-se que:

$$x(t) \cos(n\omega_s t) \leftrightarrow X(\omega - n\omega_s) + X(\omega + n\omega_s) \quad (11)$$


Desse modo, a transformada de Fourier do sinal amostrado em (10) passa ser definida pela expressão (12):

$$\bar{X}(\omega) = \frac{1}{T_s} \sum_{n=-\infty}^{\infty} X(\omega - n\omega_s) \quad (12)$$

A equação (12) mostra que o espectro em frequências do sinal amostrado corresponde a réplicas da resposta em frequência original deslocadas e centradas em valores múltiplos da

taxa de amostragem (Figura 24). O resultado obtido expressa que o processamento de sinais no tempo discreto limita a frequência mais alta que pode ser adquirida para um dado intervalo de amostragem T_s . Isso significa que a largura do espectro deve ser no máximo metade da frequência de aquisição F_s para evitar a superposição das réplicas do espectro e a distorção ou mascaramento das informações obtidas por meio do sinal de entrada. Nesse caso, o fenômeno é conhecido como efeito *aliasing* e impede a reconstrução correta do sinal adquirido, podendo ser evitado pelo Teorema de Nyquist-Shannon, que postula que a frequência de amostragem deve ser no mínimo o dobro do maior componente da grandeza que pode ser adquirida, como indicado em (13) (HAYKIN; VEEN, 2001; LATHI, 2006; OPPENHEIM; WILLSKY, 2010).

Figura 24 – Espectro de Fourier do sinal amostrado



Fonte: adaptado de Lathi (2006)

$$F_s \geq 2f_{máx} \quad (13)$$

Se a taxa de amostragem não satisfizer a condição de (13) ocorrerá o efeito *aliasing*, fazendo com que as frequências acima de $f_{máx}$ sejam mascaradas como frequências menores, corrompendo o espectro do sinal original. Esse problema é contornado se os valores a serem amostrados foram submetidos a um filtro *anti-aliasing* (passa-baixas) com banda de passagem de $F_s/2$ antes da etapa da amostragem (LATHI, 2006).

4.1.2. Ruídos no Sistema de Medida

No campo da amostragem, nem sempre o que é adquirido é a grandeza de interesse. Na prática, os valores adquiridos podem conter uma parcela indesejada que contamina as amostras denominada de ruído. O parâmetro mais utilizado para definir a relação entre a magnitude do sinal original e a do ruído é a razão sinal-ruído SNR (do inglês, *Signal-to-Noise Ratio*). A SNR é calculada na escala logarítmica em *dB*, sendo definida por (SAMANI, 2020):

$$SNR = 10 \log \left(\frac{P_{sinal}}{P_{ruído}} \right) = 20 \log \left(\frac{A_{sinal}}{A_{ruído}} \right) \quad (14)$$

em que $P_{[.]}$ é potência do sinal e $A_{[.]}$ amplitude medida em volts ou ampères.

As principais fontes de ruído são (BOYLESTAD; NASHELSKY, 2013):

- **Ruído térmico:** gerado por efeitos térmicos resultantes de uma interação entre elétrons livres de um material em condução. Esse ruído é chamado também de ruído de Johnson ou ruído branco, pois possui uma densidade espectral constante;
- **Ruído rosa:** também conhecido como *flicker* (cintilação) ou ruído $1/f$, ocorre devido à variação no tempo de trânsito de portadores que cruzam diversas junções em dispositivos semicondutores. Sua magnitude decai com o aumento da frequência e seu impacto normalmente é o mais drástico em frequências abaixo de 1 kHz;
- **Ruído shot:** associado aos portadores em dispositivos semicondutores que atravessam as barreiras de potencial em taxas desiguais. A densidade espectral é constante e está associado ao fluxo de corrente, independente da temperatura;

4.2. Processamento de Sinais no Domínio do Tempo

Neste subcapítulo serão apresentadas algumas ferramentas utilizadas na literatura para o monitoramento de máquinas elétricas baseadas no domínio do tempo. Apesar de serem bastante utilizadas em outras aplicações, esse tipo de técnica não é suficiente para análises complexas no diagnóstico de motores, uma vez que poucos pesquisadores extraíram resultados significativos na identificação das falhas (NAYANA; GEETHANJALI, 2017).

4.2.1. Média Aritmética e Desvio-Padrão

A média de um conjunto de dados que demonstra a concentração dos valores em torno de um ponto de equilíbrio e pode ser conhecida como medida de tendência central. A média é calculada para reduzir a quantidade e a complexidade dos dados. Nesse caso, toda a distribuição é diminuída a um único número, que pode ser considerado típico de uma característica importante da população analisada. Pode ser utilizada para realizar comparações e examinar relações com outros conjuntos de dados. Diante disso, a média aritmética pode ser definida por (MARIAPPAN, 2013; MORETTIN; BUSSAB, 2017):

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (15)$$

em que \bar{x} é a média, n o número de amostras e x_i os valores analisados.

A média fornece um valor representativo que é considerado único para todo o conjunto de dados, no entanto, não revela se as amostras estão agrupadas ou espalhadas em torno do seu

valor. Desse modo, o desvio-padrão é uma medida de dispersão que indica o quanto a distribuição dos dados se afasta da medida central. Quanto mais próximo for de zero, mais homogêneo serão os dados analisados. O desvio-padrão amostral é definido por (MARIAPPAN, 2013; MORETTIN; BUSSAB, 2017):

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (16)$$

em que σ é desvio-padrão do conjunto de dados.

4.2.2. Valor de Pico e Valor Eficaz

O valor de pico de um sinal digital pode ser utilizado como um valor limiar no monitoramento de máquinas, principalmente na proteção dos dispositivos em função dos valores que são pré-estabelecidos por normas. Uma vez que uma grandeza como a corrente, tensão ou vibração exceda o máximo permitido, isso é, o valor considerado saudável, podem existir indícios da presença falhas no equipamento (LUCAS, G. B, 2020).

Tradicionalmente, para análises realizadas no domínio do tempo, um dos parâmetros físicos mais utilizados para descrever os sinais é o valor RMS (do inglês, *Root Mean Square*) ou valor eficaz, que corresponde a um parâmetro estatístico que mede a magnitude de uma grandeza variável. Nesse contexto, vários trabalhos utilizam essa métrica para caracterizar os danos nas máquinas elétricas por meio dos sinais de vibração para detecção de falhas em rolamentos ou a corrente do estator para identificação de curtos-circuitos nas espiras. O valor RMS para sinais discretos poder ser calculado por (CHEN, Z. *et al.*, 2017; DINARDO; FABBIANO; VACCA, 2018; MEJIA-BARRON *et al.*, 2018):

$$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (17)$$

em que x_{rms} é o valor eficaz, n o número de amostras e x_i os valores analisados.

4.2.3. Energia

A energia é a métrica mais utilizada na identificação de falhas em máquinas elétricas. Embora seja uma técnica concebida no domínio do tempo, diversos trabalhos a utilizam junto com ferramentas no domínio da frequência. Tem como vantagem o estudo de sinais não-estacionários, sendo definida por (BOASHASH, 2016):

$$E = \sum_{i=1}^n x_i^2 \quad (18)$$

em que E é a energia, n o número de amostras e x_i os valores analisados.

Na prática, quando um motor de indução apresenta falhas, a energia dos sinais adquiridos pelos sensores de vibração ou de corrente sofrem variações. Por esse motivo, inúmeros trabalhos utilizam a energia como ferramenta na identificação de danos nos rolamentos, descargas parciais e curtos-circuitos entre espiras no enrolamento do estator (LIANG *et al.*, 2018; LUO *et al.*, 2016; ZHAO; WANG, 2019).

4.2.4. Curtose e Assimetria

A distribuição normal é a distribuição de probabilidade mais utilizada em estatística. A estrutura de sua curva tem a propriedade de se parecer com um formato de sino, sendo simétrica em torno da média. Nesse caso, as medidas de posição como a média, mediana e moda serão exatamente iguais. Qualquer diferença nos três valores indica que a distribuição correspondente é distorcida (MARIAPPAN, 2013).

Diante disso, a curtose é uma propriedade que mede o grau de achatamento ou a compressão de uma distribuição de probabilidade. Conceitualmente, é associada ao pico da distribuição, sendo igual a três se for uma curva normal. Pode ser definida por (HAHS-VAUGHN; LOMAX, 2020; KARMAKAR *et al.*, 2016):

$$K = \left[\frac{1}{(n-1)\sigma^4} \sum_{i=1}^n (x_i - \bar{x})^4 \right] - 3 \quad (19)$$

em que K é a curtose, n o número de amostras, x_i os valores analisados, \bar{x} a média da distribuição e σ o desvio-padrão.

O valor da curtose pode ser dividido em três tipos gerais (Figura 25a): leptocúrtica, que corresponde a uma distribuição muito pontiaguda ($K > 0$); platicúrtica, em que a distribuição é relativamente plana ($K < 0$); e mesocúrtica, no qual a distribuição está em algum ponto intermediário em relação as demais, como o caso da distribuição normal ($K = 0$) (HAHS-VAUGHN; LOMAX, 2020; KARMAKAR *et al.*, 2016).

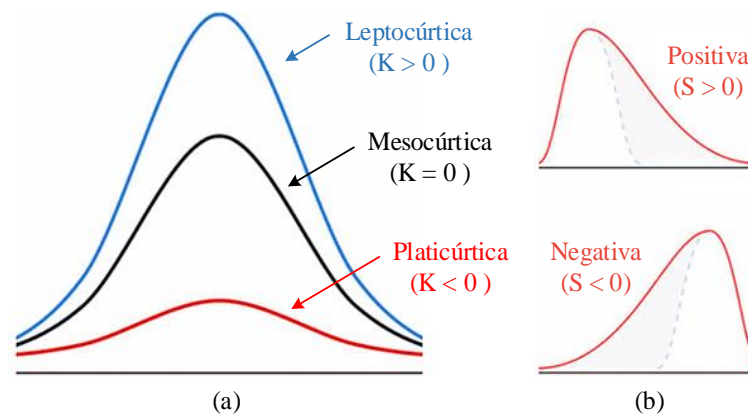
Embora a curtose analisa o achatamento da distribuição, as curvas ainda são simétricas em relação ao valor médio. No entanto, raramente as distribuições guardam essa característica quando envolvem as amostras reais. Nesse caso, a assimetria é um parâmetro que mede o deslocamento para esquerda ou para direita do pico da distribuição normal. Pode ser definida pela expressão (HAHS-VAUGHN; LOMAX, 2020; KARMAKAR *et al.*, 2016):

$$S = \frac{1}{(n-1)\sigma^3} \sum_{i=1}^n (x_i - \bar{x})^3 \quad (20)$$

em que S é o medida da assimetria.

Uma distribuição assimétrica é conhecida como enviesada e pode ser dividida em dois tipos gerais (Figura 25b): negativa ($S < 0$), no qual o peso das amostras se aproximam da extremidade superior da tendência central pela esquerda; e positiva ($S > 0$), quando o fenômeno ocorre pela direita. Na condição em que $S = 0$, a distribuição é simétrica (HAHS-VAUGHN; LOMAX, 2020; KARMAKAR *et al.*, 2016).

Figura 25 – Representação das distribuições de probabilidade
(a) Curtose (b) Assimetria



Fonte: adaptado de Bonyár (2015)

Diversos trabalhos utilizam a curtose e a assimetria no monitoramento de falhas dos motores de indução trifásicos. Essas técnicas também podem ser utilizadas no domínio da frequência e alguns trabalhos exploraram a detecção de danos nos rolamentos utilizando a corrente do estator e curtos-circuitos entre espiras a partir do fluxo magnético do entreferro (CUNHA; TEODORO DA SILVA; MEDEIROS, 2021; SAIDI *et al.*, 2017).

4.3. Processamento de Sinais no Domínio da Frequência

Neste subcapítulo serão apresentadas algumas ferramentas utilizadas para o monitoramento de máquinas elétricas baseadas no domínio da frequência. Pela análise do espectro dos sinais adquiridos, pode-se identificar a assinatura de falhas específicas pelas frequências que já são conhecidas na literatura desse tema (TALHAOUI *et al.*, 2018).

4.3.1. Transformada de Fourier

Qualquer forma de onda pode ser decomposta em uma série infinita de senoides com frequências ascendentes, cada uma possuindo magnitude e fase características. A ferramenta

matemática que permite essa transformação é Transformada de Fourier, que pode ser aplicada em sinais periódicos e aperiódicos, dos quais os últimos são muito mais comuns na natureza e no campo da engenharia. É utilizada para formas de onda tanto no tempo contínuo e quanto no discreto (GAYDECKI, 2004).

A Transformada Discreta de Fourier (do inglês, *Discrete Fourier Transform – DFT*) é uma das técnicas de processamento de sinais mais utilizadas. No entanto, possui uma resposta em frequência contínua, o que inviabiliza suas aplicações em sistemas embarcados. Para contornar esse problema, diversos algoritmos computacionais foram desenvolvidos para fornecer uma saída diretamente amostrada. Para aumentar a eficiência dos algoritmos, a Transformada Rápida de Fourier (do inglês, *Fast Fourier Transform – FFT*) é aplicada, sendo que o método mais conhecido é o Cooley e Tukey (radix-2). A DFT é calculada por (OSGOOD, 2019; SALIH, 2012; SEROV, 2017):

$$X(k) = \sum_{n=0}^{N-1} x[n]e^{-j\frac{2\pi kn}{N}}, \quad k = 0, 1, 2, \dots, N-1 \quad (21)$$

em que $X(k)$ é a DFT, $x[n]$ o sinal discreto de entrada e N o número total de amostras.

Devido ao processo de amostragem sobre o sinal de tempo contínuo, os valores resultantes da DFT podem não representar exatamente o espectro original, uma vez que o sinal de entrada é truncado (corte nas extremidades). Esse efeito gera o fenômeno do vazamento espectral e pode ser reduzido com o uso de janelas de tempo especiais, como a de Hamming, Blackman, Dolph-Chebyshev e Kaiser-Bessel (ABOOD, 2020; SALIH, 2012).

Nos motores de indução, os algoritmos de FFT já foram empregados para identificação de falhas nos rolamentos, excentricidade, curtos-circuitos no enrolamento do estator e barras quebradas na gaiola do rotor (AMEID *et al.*, 2017; PIETROWSKI, 2017; SINHA *et al.*, 2020). No entanto, se os danos apresentarem natureza não-estacionária ou transitória, a DFT não é suficiente para estabelecer uma relação adequada entre tempo e frequência, sendo necessário o uso de técnicas mais avançadas de processamento de sinais, como a Transformada Wavelet e a de Hilbert-Hung (KOMPELLA; GOPALA RAO; SRINIVASA RAO, 2018).

4.3.2. Largura de Banda Eficaz

A largura de banda é uma medida que fornece o intervalo de frequências que a energia de um sinal ocupa dentro do seu espectro. No caso do sinal ser estritamente limitado, o cálculo é fácil se realizar, diferente de quando não apresenta largura definida, que geralmente ocorre na prática (CHUI, 1997; HAYKIN; MOHER, 2007). A Largura de Banda Eficaz (do inglês, *RMS*

Bandwidth) mostra-se como uma ferramenta útil para esse problema e consiste no segundo momento da densidade espectral das amostras, definido por (ARDILA-REY *et al.*, 2018; MONRO; SHERLOCK, 1997; STAROSIELEC; HÄGELE, 2014):

$$B_{rms} = \sqrt{\frac{1}{E} \sum_{k=0}^{N-1} [\omega(k) - \omega_c]^2 |X(k)|^2} \quad (22)$$

$$\omega_c = \frac{1}{2\pi E} \sum_{k=0}^{N-1} \omega(k) |X(k)|^2 \quad (23)$$

$$E = \frac{1}{2\pi} \sum_{k=0}^{N-1} |X(k)|^2 \quad (24)$$

em que B_{rms} é a largura de banda eficaz, ω_c a característica angular da frequência ou frequência média, $\omega(k)$ a frequência angular, E a energia do sinal e $X(k)$ sua DFT.

Esta técnica torna-se atrativa por se prestar à avaliação matemática quando comparada com outros tipos de definições de largura de banda. Embora não seja medida tão facilmente em laboratório, é fácil de se implementar digitalmente (HAYKIN; MOHER, 2007).

4.4. Técnicas Avançadas de Processamento de Sinais

Neste subcapítulo serão apresentadas algumas ferramentas utilizadas para o monitoramento de máquinas elétricas baseadas em técnicas avançadas de processamento de sinais. Dependendo do comportamento da falha, muitas vezes é difícil de detectá-la somente pelo espectro de frequências. Nesse caso, quando os sinais analisados são variantes no tempo ou não-estacionários, outros algoritmos são necessários para suprir as deficiências da FFT no monitoramento dos motores de indução (TALHAOUI *et al.*, 2018).

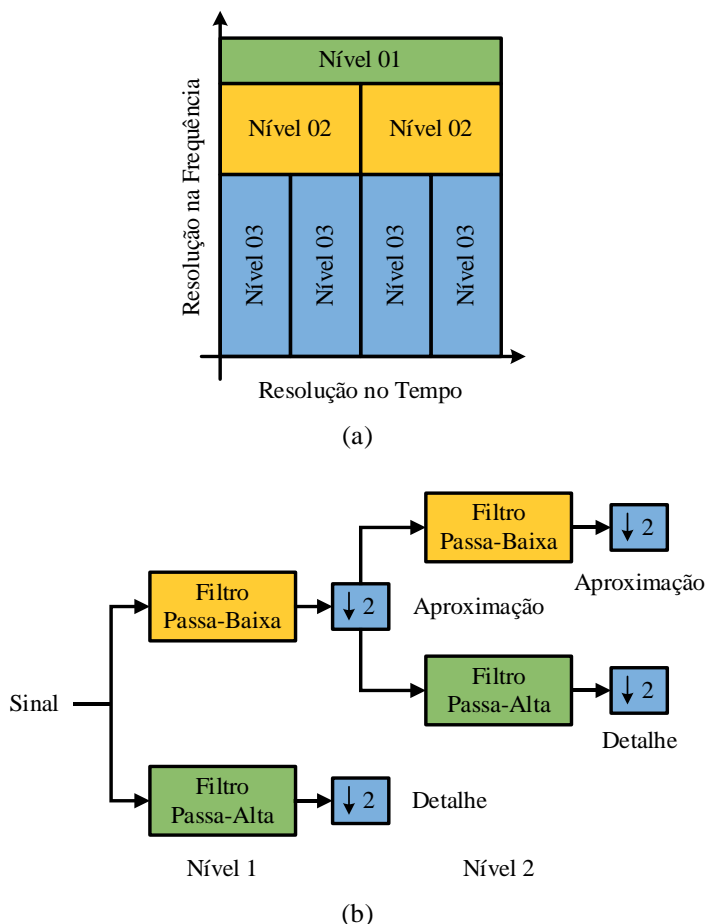
4.4.1. Transformada Wavelet

As componentes transitórias dos motores de indução contêm características abundantes que podem revelar a existência de falhas no interior dos equipamentos. Embora a FFT seja uma técnica fácil de ser implementada, sua resolução é baixa para a análise de sinais variantes no tempo e com curta duração. Nesse contexto, a Transformada Wavelet pode ser utilizada para superar essa desvantagem, uma vez que utiliza uma janela de amostragem variável. Tem como principal objetivo detalhar pontos específicos de um sinal, permitindo uma observação da forma de onda no domínio da frequência para cada instante de tempo. Desse modo, permite observar

a periodicidade de eventos em diferentes escalas de variabilidade temporal sem necessitar de séries estacionárias (IMORU *et al.*, 2017; ZANDI; POSHTAN, 2019).

A ideia central da Transformada Wavelet é a decomposição de multiresolução dos sinais analisados. A abordagem geral consiste em criar uma componente de aproximação usando uma função de escalonamento (filtro passa-baixa) e componentes de detalhe utilizando funções específicas chamadas de wavelets (filtro passa-alta). Nesse caso, uma série de aproximações do sinal é criada, sendo que cada uma difere em resolução por um fator de dois, como apresentado na Figura 26a. Os coeficientes de detalhe contêm a diferença entre as aproximações adjacentes, que dependem da quantidade de decomposições utilizadas, também chamada de níveis. O procedimento é mostrado na Figura 26b (SUNDARARAJAN, 2016).

Figura 26 – Decomposição Wavelet
 (a) Resolução tempo-frequência (b) Decomposição



Fonte: adaptado de Sundararajan (2016)

Semelhante à análise de Fourier, a decomposição wavelet pode ocorrer tanto no tempo contínuo quanto discreto. Por definição, a Transformada Wavelet Contínua (do inglês, *Continuous Wavelet Transform – CWT*) pode ser descrita como uma função de duas variáveis, isso é, de escala e deslocamento no tempo, definida por (SANTOS *et al.*, 2020):

$$W(a, b) = \int_{-\infty}^{\infty} x(t) \Psi_{a,b}(t) dt \quad (25)$$

sendo $W(a, b)$ é a transformação wavelet, $x(t)$ o sinal de entrada no tempo contínuo, a e b os coeficientes de escalonamento e deslocamento no tempo, respectivamente, e $\Psi_{a,b}$ a função wavelet, que é determinada pela expressão:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (26)$$

em que Ψ representa a função wavelet mãe.

As wavelets mães podem ser definidas como funções contínuas que podem ser reais ou complexas, geralmente designadas por meio de expressões analíticas. Quando discretas, são representadas por filtros digitais, obtidos por processos iterativos. Existem várias funções que podem ser utilizadas como wavelets mães, que dependem de fatores de escala e deslocamento, do qual se destacam as wavelets de *Haar*, *Shanon*, *Mexicana*, *Gaussiana*, *Morlet*, *Daubechies*, *Symlet* e *Coiflet* (PATHAK, 2009; SOARES, 2006).

Na Transformada Wavelet Discreta (do inglês, *Discrete Wavelet Transform – DWT*) os coeficientes de detalhe e aproximação são obtidos por meio dos coeficientes de filtros digitais, semelhante a decomposição da Figura 26b. Nesse caso, os coeficientes de aproximação permitem a análise do sinal em baixas frequências com amplitudes elevadas, enquanto que os níveis de detalhes apresentam as componentes para altas frequências e amplitudes mais baixas. A DWT pode ser definida por (ADDISON, 2017; CHENG *et al.*, 2019).

$$a_{j+1}[p] = \sum_{n=-\infty}^{\infty} h[n-2p] a_j[n] \quad (27)$$

$$d_{j+1}[p] = \sum_{n=-\infty}^{\infty} g[n-2p] d_j[n] \quad (28)$$

sendo a e d os coeficientes de aproximação e detalhes, respectivamente, g e h os filtros passa-baixas e passa-altas, nesta ordem, e j o nível wavelet.

Muitos trabalhos utilizam a DWT na detecção de falhas em máquinas elétricas. Muitos dos danos costumam produzir sinais transientes e não-estacionários, principalmente nos estágios iniciais. Desse modo, essa ferramenta pode ser aplicada no monitoramento dos rolamentos, excentricidade, curto-circuito entre espiras no estator e barras quebradas (AMEID *et al.*, 2018; BESSOUS *et al.*, 2018; CHATTERJEE, 2018; DEHINA; BOUMEHRAZ; KRATZ, 2018; VAIMANN *et al.*, 2018; VERMA; RADHIKA; PADMANABHAN, 2018).

4.4.2. Transformada de Hilbert-Huang

A Transformada de Hilbert-Huang (do inglês, *Hilbert-Huang Transform* – HHT) é uma metodologia para análise de sinais tanto no domínio do tempo quanto da frequência. Por ser baseada na técnica da Decomposição de Modo Empírico (do inglês, *Empirical Mode Decomposition* – EMD) e na Transformada de Hilbert (HT), mostra-se muito eficiente no estudo de sinais não-estacionários. Desse modo, é adequada na detecção de falhas em máquinas elétricas, uma vez que não é afetada por condições transitórias (ALVAREZ-GONZALEZ; GRIFFO; WANG, 2019).

A principal vantagem da HHT está na decomposição do sinal no domínio do tempo em componentes que possuem o mesmo comprimento do sinal original. Essa ferramenta permite visualizar as variações instantâneas das frequências que possam estar associadas às falhas em máquinas elétricas. Como resultado, apresenta bom desempenho na análise de sinais variantes no tempo, além de possuir aplicações comparáveis às wavelets. A Transformada de Hilbert-Huang baseia-se em um algoritmo empírico e adaptativo, não exigindo conhecimento prévio do sinal analisado (ANTONINO-DAVIU *et al.*, 2009).

A Transformada de Hilbert não altera o domínio da função à qual é aplicada. No entanto, a função a ser analisada é formada por uma parte real idêntica ao sinal de entrada e outra imaginária, que é expressa pela própria HHT, sendo definida por (BOASHASH, 2016; HUANG; ATTOH-OKINE, 2005; HUANG; SHEN, 2014):

$$H\{x(t)\} = \frac{1}{\pi} p \left\{ \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \right\} \quad (29)$$

em $H\{\cdot\}$ é a Transformada de Hilbert-Huang, $x(\cdot)$ o sinal analisado e $p\{\cdot\}$ o Valor Principal de Cauchy para integrais impróprias. O sinal analítico $z(t)$ é desenvolvido por (PENG; TSE; CHU, 2005; YAN; GAO, 2006):

$$z(t) = x(t) + jH\{x(t)\} = a(t)e^{j\theta(t)} \quad (30)$$

$$a(t) = \sqrt{x(t)^2 + H\{x(t)\}^2} \quad (31)$$

$$\theta(t) = \tan^{-1} \left(\frac{H\{x(t)\}}{x(t)} \right) \quad (32)$$

$$\omega(t) = \frac{d\theta(t)}{dt} \quad (33)$$

sendo $a(t)$, $\theta(t)$ e $\omega(t)$ as amplitudes, fases e frequências instantâneas do sinal analítico, respectivamente.

Se o sinal de entrada for amostrado, a Transformada de Hilbert-Huang é obtida pela manipulação da equação (29) no tempo discreto (KAK, 1970; PHELAN *et al.*, 2019):

$$H\{x(kT_s)\} = \sum_{n=-\infty}^{\infty} x(nT_s) \left[\frac{1 - \cos \pi(k-n)}{\pi(k-n)} \right] \quad (34)$$

em que T_s é o período de amostragem e k o índice das amostras.

Devido às vantagens no estudo de sinais não-estacionários, a HHT é uma ferramenta que tem sido empregada no diagnóstico de máquinas elétricas, principalmente no monitoramento de descargas parciais no enrolamento estator, saúde dos rolamentos e barras quebradas no rotor (CHEN, X.; YANG, 2018; ELBOUCHIKHI *et al.*, 2017; HOSEINZADEH; KHADDEM; SADOOGHI, 2019; SABBAGHIAN-BIDGOLI; POSHTAN, 2018).

4.5. Classificadores de Padrões

Neste subcapítulo serão apresentadas algumas ferramentas utilizadas para a classificação de falhas nas máquinas elétricas. Embora muitos trabalhos de pesquisa apresentem diversas ferramentas no processamento de sinais e índices estatísticos específicos, geralmente os motores de indução podem conter mais de um tipo de dano simultaneamente. Nesse caso, os algoritmos para classificação de padrões são instrumentos úteis que permitem simplificar o processo de identificação das falhas (ALSHORMAN *et al.*, 2020; OUACHTOUK *et al.*, 2016).

4.5.1. Algoritmo *k-Means* e *Índice Silhouette*

A clusterização é uma ferramenta utilizada em análise de dados para aglomerar um determinado conjunto de informações em grupos, também conhecidos como *clusters*, que apresentam maior ou menor similaridade. Do ponto de vista estatístico, os métodos de agrupamento são divididos em modelos de probabilidade ou métodos não-paramétricos. Nesse último caso, os métodos particionais são os mais usados e supõem que o conjunto de dados possa ser representado por protótipos de agrupamento finitos com suas associações de particionamento. Dentre os métodos de partição, o algoritmo *k-means* é o mais antigo e comumente utilizado (YANG, M.; SINAGA, 2019).

Nesse contexto, o *k-means* é um método heurístico que tenta agrupar pontos que estão mutuamente próximos pelo critério da distância euclidiana em relação ao seu centroide. Desse modo, considerando o conjunto de dados analisados como $X = \{x_1, \dots, x_N\} \in \mathbb{R}^n$ e definindo

os *clusters* como $C = \{ c_1, \dots, c_M \}$, sendo $C_T = \{ m_1, \dots, m_M \}$ os respectivos centroides, o algoritmo *k-means* é definido por (LIKAS; VLASSIS; J. VERBEEK, 2003):

$$E(C_T) = \sum_{i=1}^N \sum_{k=1}^M I(x_i \in c_k) \|x_i - m_k\|^2 \quad (35)$$

sendo $E(C_T)$ o erro a ser minimizado pelo algoritmo e $I(x_i \in c_k) = 1$ se o ponto x_i pertencer ao *cluster* c_k ou zero, caso contrário.

O algoritmo *k-means* permite determinar os centroides de cada *cluster*, o que permite realizar o diagnóstico e a análise estatística dos resultados, não dependendo de aprendizagem supervisionada. A qualidade dos *clusters* é obtida pelo método do *silhouette* que avalia a distância de um ponto em relação aos seus vizinhos quando comparado com a distância do mesmo em relação aos outros *clusters* (LUCAS, G. B. *et al.*, 2021).

O *silhouette* fornece um índice de desempenho que varia entre $-1,0$ e $1,0$, sendo que, quanto mais elevado ou próximo da unidade, indica que o ponto está fortemente correlacionado com o *cluster* analisado, enquanto que um valor mais baixo ou negativo aponta correlação fraca. O *silhouette* é definido por (ALVAREZ *et al.*, 2020):

$$S_l(i) = \frac{a(i) - b(i)}{\max \{ a(i), b(i) \}} \quad (36)$$

em que a é a distância média calculada do ponto i aos demais pontos do mesmo *cluster*; e b é a distância média mínima calculada do ponto i aos demais pontos dos outros *clusters*.

4.5.2. Redes Neurais Artificiais

Várias pesquisas têm mostrado que os sistemas baseados em inteligência artificial têm forte capacidade em classificar os danos observados em máquinas elétricas. Nesse contexto, as Redes Neurais Artificiais (RNA) é uma das ferramentas mais utilizadas no diagnóstico inteligente das falhas. As diversas técnicas de processamento digital de sinais podem ser utilizadas como informação de entrada para alimentar topologias de redes neurais (SADDAM *et al.*, 2017; VERMA *et al.*, 2021).

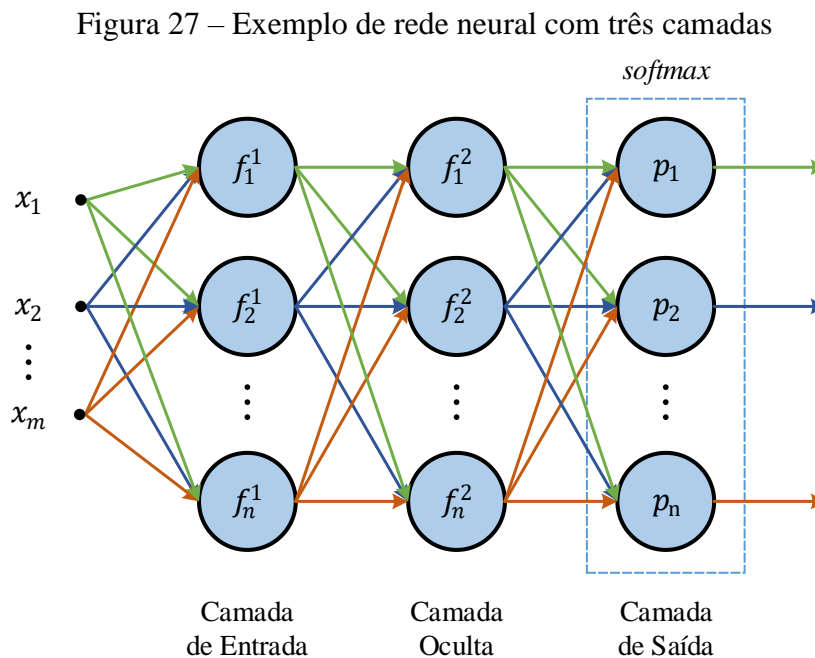
Em comparação com outros algoritmos de aprendizado de máquina, as redes neurais têm melhor precisão para grandes conjuntos de dados. O conceito de RNA foi estabelecido ao simular a operação do cérebro humano, no qual os neurônios compartilham informações em toda a conexão neural para tomar uma decisão. Nesse caso, várias camadas são interconectadas para mapear a relação entre a entrada e a saída desejada. Basicamente, existem três camadas na

arquitetura de uma RNA: a de entrada, que recebe as informações a serem analisadas; a oculta, que processa os dados após alguns cálculos com pesos numéricos; e saída, que pondera os dados e os mapeia com neurônios-alvo para as tomadas de decisão. Os pesos internos podem ser otimizados para melhorarem o mapeamento implícito dos dados (SHIFAT; HUR, 2021).

Quando as redes neurais são aplicadas na classificação de dados, normalmente o valor de saída é uma resposta binária ou um valor probabilístico. Diante disso, uma estrutura típica é apresentada na Figura 27. Cada neurônio aplica uma transformação determinística que corresponde a somatório dos valores de entrada multiplicados por pesos somados a um *offset* global. O resultado é submetido a uma função de ativação, gerando uma grandeza escalar de saída. O neurônio pode ser definido por (LEI *et al.*, 2020; LIU, R. *et al.*, 2018; SIMEONE, 2018):

$$f_k^j = \sigma \left(\sum_{i=1}^m w_i x_i + b_k \right) \quad k = 1, \dots, n \quad (37)$$

sendo x_i os valores de entrada, m a quantidade de entradas, n é o número de neurônios de cada camada, j a camada analisada, w_i os pesos sinápticos de cada entrada, b_k o valor do *offset* do neurônio e $\sigma(\cdot)$ a função de ativação (linear, tangente hiperbólica ou sigmoide).



Na Figura 27, os valores de entrada da RNA são processados pelo vetor $f_{1,\dots,n}^1$ da primeira camada. Cada n -ésimo neurônio produz um valor escalar que é processado pela camada oculta em função de sua característica f_n^2 . Os valores calculados na camada oculta são avaliados na de saída por meio de um algoritmo de regressão *softmax*, que é corresponde a uma função

estatística-bayesiana. Nesse caso a probabilidade p_n para classificação de cada saída é determinada por (BLANCHARD; HIGHAM; HIGHAM, 2019; SIMEONE, 2018):

$$p_j = \frac{e^{f_k^j}}{\sum_{k=1}^n e^{f_k^j}} \quad j = 1, \dots, n \quad (38)$$

O método de regressão *softmax* tem sido utilizado junto com as RNA's para a classificação de falhas em máquinas elétricas. Diversos trabalhos aplicam os sistemas inteligentes para monitorar danos em rolamentos e curtos-circuitos entre espiras no enrolamento do estator da motor de indução (TAO *et al.*, 2015; VERMA *et al.*, 2021).

4.5.3. Classificador de Naive-Bayes

O problema de classificação de dados é um tópico conhecido no campo do aprendizado de máquinas e da estatística. A classificação serve para identificar a qual categoria uma determinada observação pertence com base nos conjuntos de treinamento. Nesse caso, os métodos heurísticos tradicionais têm sido empregados em diversas aplicações. Dentre eles, diversos trabalhos mostram que o Classificador de Naive-Bayes (do inglês, *Naive-Bayes Classifier* – NBC) possui um desempenho competitivo quando comparado com outras ferramentas que envolvam situações complexas (KUMAR, P.; HATI, 2021; ZHANG, Y.-C.; SAKHANENKO, 2019).

O NBC é um método de classificação supervisionado baseado no pressuposto de independência condicional entre os grupos analisados. No entanto, muitas aplicações têm mostrado que o algoritmo é eficiente para os dados que apresentem uma forte dependência correlacional. Por apresentar uma formulação matemática simples, o Classificador de Naive-Bayes exibe três vantagens sobre outras topologias (FENG *et al.*, 2018):

- Possui uma estrutura pré-definida, o que dispensa o aprendizado da arquitetura;
- É adequado para lidar com grandes conjuntos de dados;
- Requer uma pequena quantidade de dados durante o treinamento;

Matematicamente, o NBC utiliza o Teorema de Bayes, sendo definido por (RANGA-NATHAN *et al.*, 2019; SAINI; AGGARWAL, 2018):

$$P(C_k | x_1, x_2, \dots, x_n) = \frac{P(C_k) \prod_{i=1}^n P(x_i | C_k)}{\sum_{j=1}^m [P(C_j) \prod_{i=1}^n P(x_i | C_j)]} \quad (39)$$

em que x é o conjunto dos dados a ser analisado, C as classes a serem classificadas, $P(C_k)$ o grau de crença inicial em C_k (probabilidade), $P(x_i | C_k)$ o grau de crença de x_i se a preposição

C_k for verdadeira, que é estimado durante a etapa de treinamento; e $P(C_k | x_1, x_2, \dots, x_n)$ o grau de crença da classe C_k se as amostras analisadas pertencerem a ela.

No campo das máquinas elétricas, o Classificador de Naive-Bayes facilita o processo de aprendizagem por utilizar o Teorema de Bayes. Combina as informações anteriores (dados do treinamento) com as informações obtidas a partir dos valores de teste para produzir a distribuição necessária para classificar as falhas (SAINI; AGGARWAL, 2018).

4.6. Conclusão do Capítulo

Neste capítulo foram apresentadas as principais técnicas de processamento de sinais aplicadas na detecção dos danos em motores de indução trifásicos. As falhas relacionadas aos rolamentos, quando pertencem à categoria dos danos localizados, normalmente são identificadas por meio das ferramentas no domínio da frequência, sendo que, eventualmente podem ser analisadas diretamente no domínio do tempo. Quando os defeitos nos rolamentos são distribuídos, o reforço ou a atenuação das componentes de frequências podem produzir condições não-estacionárias. Nesse contexto, o uso de técnicas que complementem as deficiências da Transformada Rápida de Fourier torna-se essencial. Com base na revisão abordada, as Transformadas Wavelets e de Hilbert-Huang vêm sendo empregadas no monitoramento das máquinas elétricas. Dependendo das características e quantidade de danos, essas ferramentas são combinadas com os classificadores de padrões para simplificar o processo de identificação das falhas. O próximo capítulo apresenta os aspectos gerais relativos ao desenvolvimento e implementação da metodologia proposta, bem como a aplicação de algumas das técnicas de processamento de sinais aqui abordadas.

CAPÍTULO 5

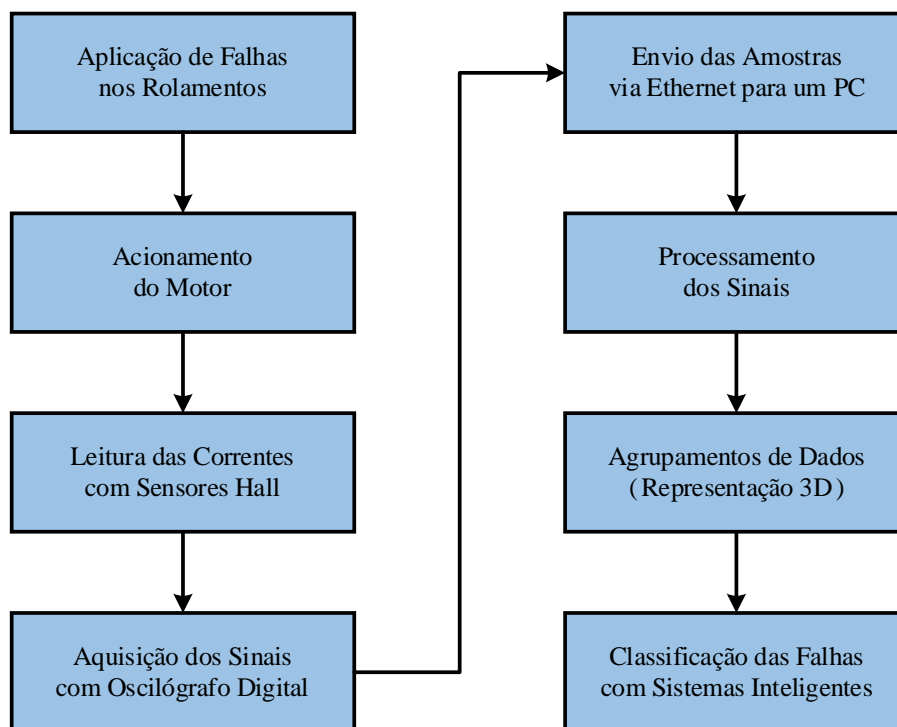
METODOLOGIA

Nesse capítulo será abordado os processos envolvidos no procedimento experimental para criação do banco de dados para o processamento de sinais, assim como a metodologia utilizada na detecção das falhas nos rolamentos. Primeiramente, será descrita a montagem experimental, detalhando suas particularidades. Em seguida, é apresentado o algoritmo aplicado para classificar os padrões dos danos em regime permanente.

5.1. Montagem Experimental

Os subcapítulos que se seguem descrevem os procedimentos adotados na preparação da bancada de ensaios, a elaboração das falhas nos rolamentos do motor de indução, a aquisição da corrente trifásica do estator e a técnica desenvolvida para detecção dos danos. Na Figura 28 é apresentada a organização geral da metodologia proposta:

Figura 28 – Organização geral da metodologia proposta



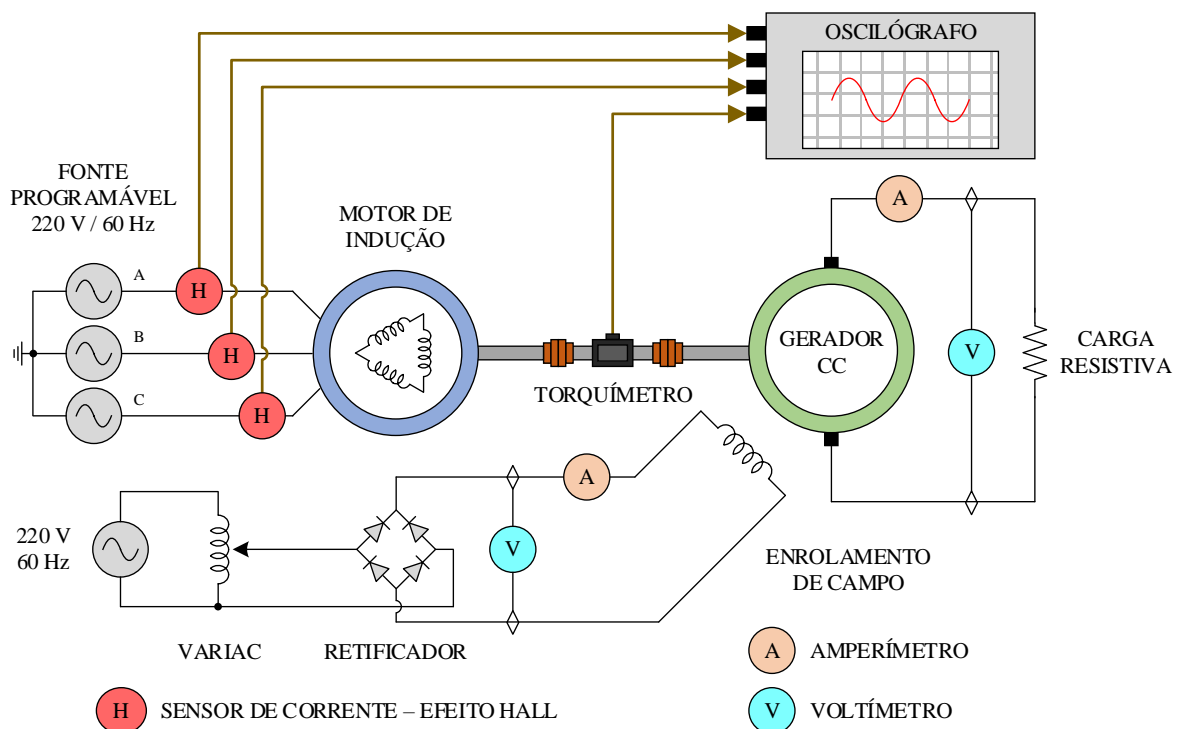
Fonte: autoria própria

5.1.1. Montagem das Máquinas Elétricas

O motor de indução trifásico, cujo os rolamentos são o objeto de estudo desse trabalho, foi acoplado a um gerador de corrente contínua por meio de um acoplamento industrial elástico, a fim de simular uma carga real conectada no seu eixo. Na Figura 29 é apresentada a visão geral

da bancada de ensaios, sendo que a máquina de indução é acionada por uma fonte trifásica senoidal controlada por software. O circuito de campo do gerador CC é interligado a um regulador de tensão alternada (VARIAC) mediante a uma ponte retificadora e o enrolamento da armadura é conectado diretamente a uma carga resistiva. Quando a tensão do campo for incrementada, a corrente do circuito da armadura é elevada, o que provoca o aumento no carregamento do motor. Um torquímetro é acoplado entre as máquinas para monitorar o valor do conjugado.

Figura 29 – Bancada experimental: diagrama das ligações



Fonte: autoria própria

O motor de indução trifásico utilizado neste trabalho possui seis terminais. Para que o acionamento seja compatível à fonte programável, a ligação das bobinas do estator é realizada em triângulo, como indicado na Figura 29. Dessa maneira, a máquina é energizada por partida direta e os sensores de corrente de efeito Hall são conectados no alimentador do equipamento para medir a corrente de linha do motor. Como o torque da máquina é ajustado pela excitação do gerador CC, multímetros foram posicionados após o retificador para auxiliar no controle do enrolamento de campo, que é feito manualmente no VARIAC. A tensão e a corrente do circuito de armadura também foram medidas para monitorar a potência entregue à carga.

Os principais dados de placa do motor de indução trifásico e gerador de corrente contínua são mostrados nas Tabelas 1 e 2, respectivamente. A descrição dos demais equipamentos utilizados é apresentada na Tabela 3:

Tabela 1 – Parâmetros do motor de indução trifásico

Item	Parâmetro
Tensão de Alimentação	220/380 V
Marca	WEG
Potência	3 kW / 4 CV
Frequência / Polos	60 Hz / 4 polos
Velocidade Nominal	1.725 rpm
Rendimento	83,5 %
Fator de Potência	0,80
Rotor	Gaiola de Esquilo
Rolamento Dianteiro	6206-ZZ
Rolamento Traseiro	6205-ZZ

Fonte: autoria própria

Tabela 2 – Parâmetros do gerador de corrente contínua

Item	Parâmetro
Tensão de Armadura	440 V
Tensão de Campo	330 V
Marca	SICME MOTORI
Potência	10,1 kW
Velocidade Nominal	2.770 rpm
Corrente de Armadura	26,7 A
Corrente de Campo	0,9 A

Fonte: autoria própria

Tabela 3 – Equipamentos utilizados


Equipamento	Modelo / Descrição
Fonte Programável	Pacific Power 360-AMX / 12 kW
Carga Resistiva	4 resistores de 1,5 kW / 220 V
Torquímetro	Sodmax MT-10
VARIAC	Monofásico de 0 a 440 V

Fonte: autoria própria

Na Figura 30 é apresentada a vista geral dos componentes da bancada experimental, montada no laboratório de pesquisas:

Figura 30 – Bancada experimental

BANCADA
Gerador de Corrente Contínua – Torquímetro – Motor de Indução Trifásico – VARIAC (campo)



FONTE PROGRAMÁVEL
Sensores de Corrente de Efeito Hall




CARGA RESISTIVA
Circuito de Armadura

Fonte: autoria própria

O carregamento do motor de indução trifásico foi caracterizado a partir das curvas de performance obtidas dos catálogos da WEG para uma máquina com as mesmas especificações nominais. Desse modo, na Figura 31 o comportamento do conjugado em função da corrente do estator é exibido com destaque a operação nominal de 100 %:

Figura 31 – Curva de torque vs. corrente do motor de indução



Fonte: adaptado de WEG (2020)


Durante os experimentos, o carregamento do motor de indução foi ajustado no intervalo entre 50 e 100 % do valor nominal em etapas de 10 %. Além disso, foram realizadas coletas de dados com a máquina a vazio. Utilizando a condição do motor com os rolamentos saudáveis e a curva característica na Figura 31, foram determinados os valores RMS da tensão no torquímetro para cada ponto de operação. Dessa forma, para qualquer experimento realizado, o sinal do torquímetro é lido para auxiliar o conjugado a permanecer constante. Assim, se o torque do motor sofrer alguma alteração, a tensão de excitação do campo do gerador CC será ajustada manualmente para igualá-lo ao valor de referência obtido inicialmente.

A máquina de indução operou sob temperatura constante. Nesse caso, o motor foi acionado à plena carga durante uma hora para que houvesse a estabilização térmica. Desse modo, o valor médio obtido nos experimentos foi de 48 °C. O termômetro utilizado é o do tipo infravermelho é da fabricante Minipa, modelo MT-320A. O alinhamento do eixo motor-torquímetro-gerador (Figura 30) ocorreu com a máquina a vazio e com a leitura instantânea do torque. Nessa situação, a suporte do torquímetro foi ajustada de forma manual até que não fossem observadas distorções na forma de onda do conjugado.

5.1.2. Preparação do Rolamentos e Ensaio

As falhas de rolamento foram reproduzidas para simular o desgaste relacionado ao uso excessivo, falta de lubrificação e sobrecarga no eixo do motor. O procedimento adotado é baseado nos trabalhos de Bazan *et al.* (2020) e Guedes (2019). Para a simulação das falhas, a lubrificação dos rolamentos foi removida com o auxílio de solventes, sendo substituída por uma pasta abrasiva fina, responsável em promover a degradação das peças (Figura 32a). Nesse caso, foram utilizados ao todo seis rolamentos, sendo três dianteiros e três traseiros, no qual cada par operou intermitentemente por 15, 30 e 60 minutos com velocidade constante de 500 rpm, o que resultou em três níveis de severidade (Figura 32b). Posteriormente, cada componente foi limpo e recebeu uma lubrificação com graxa azul à base de sabão de lítio (Figura 32c).


Figura 32 – Procedimento do desgaste abrasivo dos rolamentos



Fonte: autoria própria

O efeito da oxidação nos rolamentos foi emulado pela deterioração de suas superfícies metálicas. Após a limpeza da lubrificação original dos rolamentos, as peças foram mergulhadas em uma solução de ácido nítrico (HNO_3 – 25% volume) por 30 minutos (Figura 33a). Em seguida, os rolamentos foram lavados e expostos a umidade por 24 horas para a formação de uma camada de óxido nas pistas, esferas e gaiola (Figura 33b).


Figura 33 – Procedimento da oxidação dos rolamentos



Fonte: autoria própria

O fenômeno das correntes de rolamento foi simulado para representar os danos causados nos rolamentos devido ao acionamento do motor por sinais de PWM. Nesse caso, um rolamento saudável com a lubrificação original foi submetido a uma corrente controlada de 100 A durante um segundo por meio de uma máquina de solda. Logo após, rotacionou-se a pista interna do rolamento em um ângulo de 60° e aplicou-se novamente o dano; o procedimento foi repetido até ser completada uma volta, como exibido no diagrama na Figura 34. Além disso, para evitar a deposição de solda na estrutura do rolamento, a pista interna foi conectada a um metal de sacrifício para que o mesmo recebesse a deposição dos materiais no tempo do arco elétrico. A circulação da alta corrente resultou em danos nos contatos das esferas com as pistas interna e externa do rolamento em vários pontos peça, isto é, de forma distribuída.

Figura 34 – Simulação dos danos por correntes de rolamento



Fonte: autoria própria

Uma vez que as peças foram preparadas, realizou-se combinações entre os rolamentos dianteiro e traseiro para alterar o tipo de dano e intensidade. Assim sendo, ocorreram 22 ensaios, conforme a disposição mostrada na Tabela 4. Nesse caso, o experimento 01 corresponde a base de dados de referência, isto é, quando ambos os rolamentos do motor estão na condição íntegra ou saudável. O arranjo dos experimentos de 02 a 16 consiste na aplicação dos danos devido aos desgastes abrasivos para as intensidades de 15, 30 e 60 minutos. Os ensaios de 17 a 19 caracterizam as falhas devido a oxidação, enquanto que os experimentos de 20 a 22 os danos provocados pelo fenômeno das correntes de rolamento.


Tabela 4 – Ensaios realizados: combinação das falhas nos rolamentos

Ensaio	Combinação dos Danos		Ensaio	Combinação dos Danos	
	Rolamento Dianteiro	Rolamento Traseiro		Rolamento Dianteiro	Rolamento Traseiro
01	Saudável	Saudável	12	60 min	30 min
02	15 min	Saudável	13	Saudável	60 min
03	30 min	Saudável	14	15 min	60 min
04	60 min	Saudável	15	30 min	60 min
05	Saudável	15 min	16	60 min	60 min
06	15 min	15 min	17	Oxidado	Saudável
07	30 min	15 min	18	Oxidado	Oxidado
08	60 min	15 min	19	Saudável	Oxidado
09	Saudável	30 min	20	Corrente	Saudável
10	15 min	30 min	21	Corrente	Corrente
11	30 min	30 min	22	Saudável	Corrente

Fonte: autoria própria


Em função da ordem adotada para as falhas na Tabela 4, o motor de indução trifásico foi desmontado diversas vezes para que os rolamentos fossem removidos e substituídos em cada experimento. O procedimento é descrito na Figura 35, em que o rotor da máquina é removido pela parte traseira do equipamento e posteriormente, com auxílio de um saca-polia de três garas, os rolamentos são retirados. A Figura 36 destaca o rotor da máquina trifásica, ressaltando os rolamentos traseiro (6205zz) e dianteiro (6206zz).

Figura 35 – Detalhe da remoção dos rolamentos



Fonte: autoria própria

Figura 36 – Rolamentos



Fonte: autoria própria

5.1.3. Sistema de Aquisição de Dados

Nesse trabalho, os sinais da corrente do estator da máquina de indução foram obtidos por meio de três sensores de corrente que são baseados no efeito Hall, sendo um para cada fase. O modelo utilizado é a Ponteira CA/CC A622 de 100 A da fabricante Tektronix, capaz de realizar leituras de sinais com frequências de até 100 kHz. Como os condutores de saída da fonte programável correspondem ao alimentador do motor de indução, para uma melhor acomodação dos sensores de corrente, as aquisições de cada fase foram feitas diretamente na sua saída, como apresentado na Figura 37:

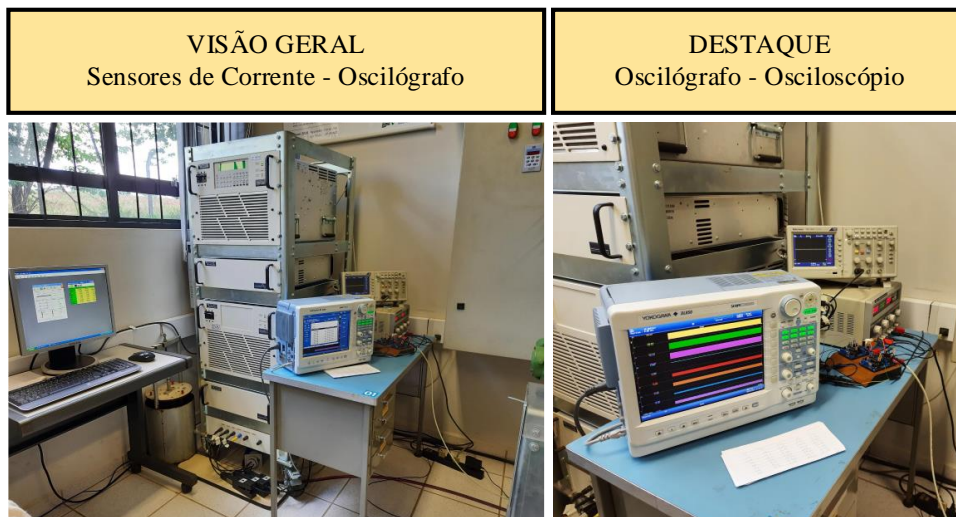
Figura 37 – Sensores de corrente



Fonte: autoria própria

Os sinais obtidos pelos sensores de corrente possam ser ajustados para uma sensibilidade de 10 mV/A ou 100 mV/A, não há necessidade de um circuito de condicionamento de sinais externo. Como as ponteiros podem ser conectadas diretamente a um osciloscópio, a aquisição de dados foi realizada pelo Oscilógrafo Digital Yokogawa DL850 – 100 MS/s, como destacado na Figura 38. Para evitar o efeito *aliasing*, a frequência de amostragem foi ajustada para 200 kS/s. Esse valor satisfaz o Teorema de Nyquist-Shannon, já que as ponteiros de corrente realizam leituras de até 100 kHz. Os dados adquiridos foram transferidos para um computador pessoal (PC) por meio de uma rede ethernet, enquanto que o processamento dos sinais foi feito no software MATLAB/Simulink®.

Figura 38 – Aquisição dos dados



Fonte: autoria própria

Para cada ensaio realizado na Tabela 4, o conjugado do motor foi ajustado no intervalo entre 50 % e 100 % do valor nominal em etapas de 10 % por experimento; também foram realizadas coletas de dados com a máquina a operando a vazio. Desse modo, foram efetuados 175 ensaios, enquanto que o torquímetro foi utilizado para verificar o carregamento do motor. Nesse caso, o osciloscópio digital da Tektronix, modelo TBS-1062 (Figura 38), foi utilizado para monitorar o valor eficaz do sinal do torquímetro, enquanto que o controle é realizado pela modificação da tensão de excitação do enrolamento de campo do gerador CC.

Para garantir a repetibilidade e fornecer um banco de dados amplo no treinamento dos sistemas inteligentes, foram realizadas dez coletas de dados para cada combinação das falhas e carregamentos aplicados no motor de indução, sendo que em cada uma foram obtidas amostras de 100 janelas de 200 ms da corrente do estator.

5.2. Detecção dos Danos nos Rolamentos

Para a identificação e classificação das falhas pela metodologia proposta, foram extraídos dados de corrente do estator do motor de indução trifásico. As seções seguintes apresentam o funcionamento dos algoritmos utilizados no processamento de sinais.

5.2.1. Processamento dos Sinais

As falhas nos rolamentos levam à excentricidade do rotor no estator provocando variações no comprimento do entreferro do motor de indução. Por conseguinte, a corrente do estator sofre distorções que podem ser difíceis de identificar somente com análises no domínio da frequência, principalmente se as características dos danos forem distribuídas, situação que é abordada neste trabalho.

Com base nas considerações anteriores, a corrente do estator é decomposta para determinar a largura de banda eficaz e a frequência média das fases de entrada. Para identificar as características no domínio tempo-frequência, a Transformada Wavelet Discreta é aplicada para obter a energia dos coeficientes de detalhe. Todas as combinações foram avaliadas para escolher o melhor nível capaz de detectar os danos nos rolamentos. A energia é determinada por:

$$E_w = \sum_{n=1}^N |W_c[n]|^2 \quad (40)$$

em que E_w é a energia dos coeficientes wavelets e $W_c[n]$ o coeficiente wavelet.

Após a realização de diversos testes, a função wavelet mãe que apresentou os melhores resultados é a *Daubechies-2* (db2), adotada neste trabalho. Assim, o número máximo de níveis

wavelets foi determinado como $j_{m\acute{a}x} = 12$, sendo que esse limite depende de calculos realizados com a quantidade das amostras do vetor da corrente de 200 ms, obtida a uma taxa de 200 kS/s no oscilografo digital.

A partir da decomposiao da corrente do estator, os parametros obtidos visam formar um mapa de agrupamento de dados tridimensional, que pode ser identificavel do ponto de vista cromatico. As informaoes calculadas permitem separar as condioes dos rolamentos e podem ser utilizadas no diagnostico das falhas a partir dos sistemas inteligentes. Nesse caso, um algoritmo computacional obtem a largura de banda eficaz, frequencia media e energia dos coeficientes de detalhe wavelets da corrente das fases A, B e C do motor. Em seguida, o produtorio entre as fases e determinado para cada grandeza envolvida. Para melhorar a visualizaao dos resultados, as coordenadas dos agrupamentos de dados sao expressas em decibeis, como mostrado nas equaoes (41)-(43):

$$\overline{B}_{rms} = 20 \log (B_{rms}^A B_{rms}^B B_{rms}^C) \quad (41)$$

$$\overline{\omega}_c = 20 \log (\omega_c^A \omega_c^B \omega_c^C) \quad (42)$$

$$\overline{E}_W = 20 \log (E_W^A E_W^B E_W^C) \quad (43)$$

em que \overline{B}_{rms} , $\overline{\omega}_c$ e \overline{E}_W sao o produtorio, em decibeis, da largura de banda eficaz, frequencia media e energia dos coeficientes wavelets das fases A, B e C, respectivamente.

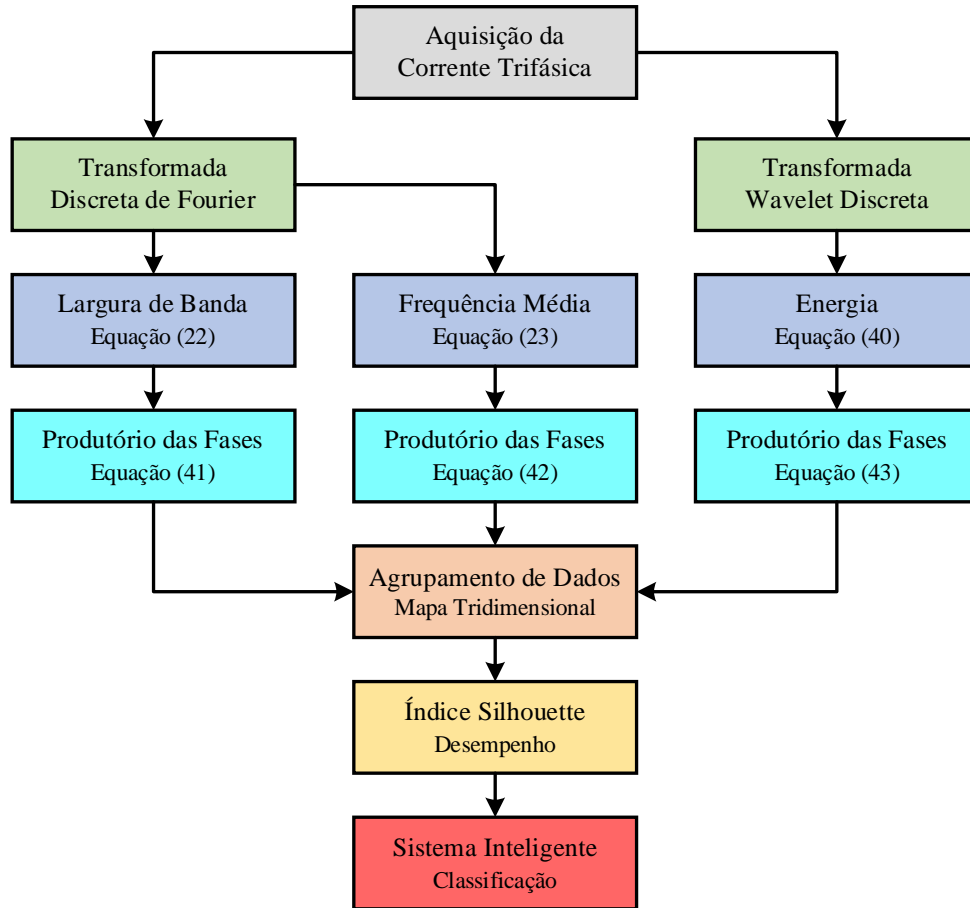
Como a condiao ıntegra ou danificada dos rolamentos pode ser descrito por meio de padroes ou diferentes estruturas tridimensionais de dados, esta tese propoe a aplicaao de uma tecnica cromatica para se agrupar e caracterizar o comportamento dos rolamentos na presena ou ausencia das falhas considerando os efeitos do carregamento do motor. A ideia principal e formar um mapa de cores que se relaciona com a condiao estrutural dos danos, permitindo que um sistema inteligente seja capaz de identificar e classificar a assinatura das falhas.

Cada agrupamento de dados se comporta como uma estrutura tridimensional. Diante disso, o centro geometrico ou centroide e calculado para analisar os resultados obtidos e o *ndice silhouette* e utilizado como validaao estatistica da qualidade dos agrupamentos para diferentes valores do conjugado da maquina. Como o *silhouette* retorna um ponto para cada amostra, ao todo existem 100 ındices, que correspondem a quantidade de janelas aquisitadas. Assim, calculou-se um valor medio para cada agrupamento, como mostrado por (44):

$$S_m = \frac{1}{N} \sum_{i=1}^N S(i) \quad (44)$$

em que S_m e $S(i)$ são os *silhouettes* médio e de cada ponto, respectivamente; e N o número de pontos. A metodologia apresentada é descrita na Figura 39:

Figura 39 – Processamento dos sinais



Fonte: autoria própria

5.2.2. Treinamento de Rede Neural Artificial

Para estimar o tipo de dano e a intensidade das falhas nos rolamentos, foi treinada uma rede neural do tipo *perceptron multicamadas* com as entradas obtidas pelas métricas calculadas na Figura 39. A aprendizagem da rede é do tipo supervisionado, sendo que o algoritmo utilizado foi o *resilient backpropagation* para um critério de parada de 1.500 épocas.

Na Tabela 5 é apresentada o método de classificação dos danos da RNA. O processo de identificação das falhas nos rolamentos dianteiro e traseiro é similar a uma busca matricial: se a rede neural identificar um determinado grupo de ensaios (saídas 8 a 13), o experimento a ser selecionado (saídas 14 a 17) deve pertencer ao grupo que já foi identificado. Nesse caso, se a RNA indicar a maior probabilidade nas saídas 9 e 16, simultaneamente, o dano correspondente pertence ao experimento 07 da Tabela 4, por exemplo. Além disso, as saídas 1 a 7 são utilizadas para verificar o carregamento do motor de indução.

Tabela 5 – Saídas da rede neural

Saída da RNA	Tipo de Saída	Descrição
1		Vazio
2		50 %
3		60 %
4	Carregamento do Motor	70 %
5		80 %
6		90 %
7		100 %
8		01 ao 04
9		05 ao 08
10	Grupos de Ensaios (Tabela 4)	09 ao 12
11		13 ao 16
12		17 ao 19
13		20 ao 22
14		01, 05, 09, 13, 17, 20
15	Experimentos (Tabela 4)	02, 06, 10, 14, 18, 21
16		03, 07, 11, 15, 19, 22
17		04, 08, 12, 16

Fonte: autoria própria

O número de saídas da RNA é igual a 17 (Tabela 5), sendo que o valor fornecido para cada uma corresponde à probabilidade da ocorrência das falhas nos rolamentos e ao conjugado do motor de indução. Desse modo, a função de ativação da camada de saída é baseada no algoritmo *softmax*, enquanto que o parâmetro de performance *crossentropy* foi utilizado. A escolha dessa topologia deve-se ao fato de que a RNA utilizada é probabilística e a estatística Bayesiana é adequada à inferência dos agrupamentos de dados obtidos.

Uma vez que foi definida o comprimento da camada de saída da RNA, recomenda-se que a camada que antecede a *softmax* possua a mesma quantidade de neurônios (KOURETAS; PALIOURAS, 2020; SADOON; ALI, 2021). Desse modo, na Tabela 6 é ilustrada as combinações dos neurônios utilizados na implementação da rede neural para um total de três camadas. As funções de ativação das camadas de entrada e oculta são do tipo tangente hiperbólica, que se mostrou mais eficiente durante as etapas do aprendizado e classificação dos resultados no desenvolvimento deste trabalho.

Tabela 6 – Topologias testadas de RNA

Topologia	Camada		
	Entrada	Oculto	Saída
1	0		
2	5		
3	10		
4	15		
5	20	17	17
6	25		
7	30		
8	35		
9	40		

Fonte: autoria própria

A apresentação dos resultados se deu apenas para a rede que apresentou o melhor treinamento a partir dos parâmetros fornecidos pelo MATLAB/Simulink®, como o Parâmetro de Performance, Histograma de Erros, Característica de Operação do Receptor (do inglês, *Receiver Operating Characteristic* – ROC) e Área sob a Curva ROC (do inglês, *Area Under the ROC Curve* – AUC).

5.3. Conclusão do Capítulo

Neste capítulo foram detalhados os aspectos gerais relacionados à metodologia proposta para identificação e classificação de falhas nos rolamentos de um motor de indução trifásico. Para isso, apresentou-se a bancada experimental e o procedimento da emulação dos danos de desgastes abrasivos, oxidação e correntes de rolamento, bem como a caracterização do carregamento do motor de indução. Além disso, foi descrita a combinação das técnicas de processamento de sinais utilizadas para formação dos mapas cromáticos referentes às falhas e a estrutura de uma rede neural artificial para a classificação dos danos. O próximo capítulo apresenta e discute os resultados obtidos nesta tese.

CAPÍTULO 6

RESULTADOS EXPERIMENTAIS E DISCUSSÃO

Neste trabalho, as ferramentas de processamento de sinais foram aplicadas aos sinais da corrente do estator de um motor de indução trifásico. A largura de banda eficaz e a transformada wavelet discreta foram calculadas com a finalidade de detectar as condições dos rolamentos por meio de um método de agrupamento de dados. Uma rede neural artificial foi implementada para identificar as falhas nos rolamentos a partir dos mapeamentos obtidos.

Neste capítulo, resultados experimentais e a aplicação das técnicas de processamento de sinais serão apresentados. As classificações das falhas foram executadas em um computador pessoal com processador Intel® Core i7-3632QM @ 2,2 GHz, memória RAM de 16 GB e unidade de estado sólido SSD de 480 GB.

6.1. Sinais Amostrados

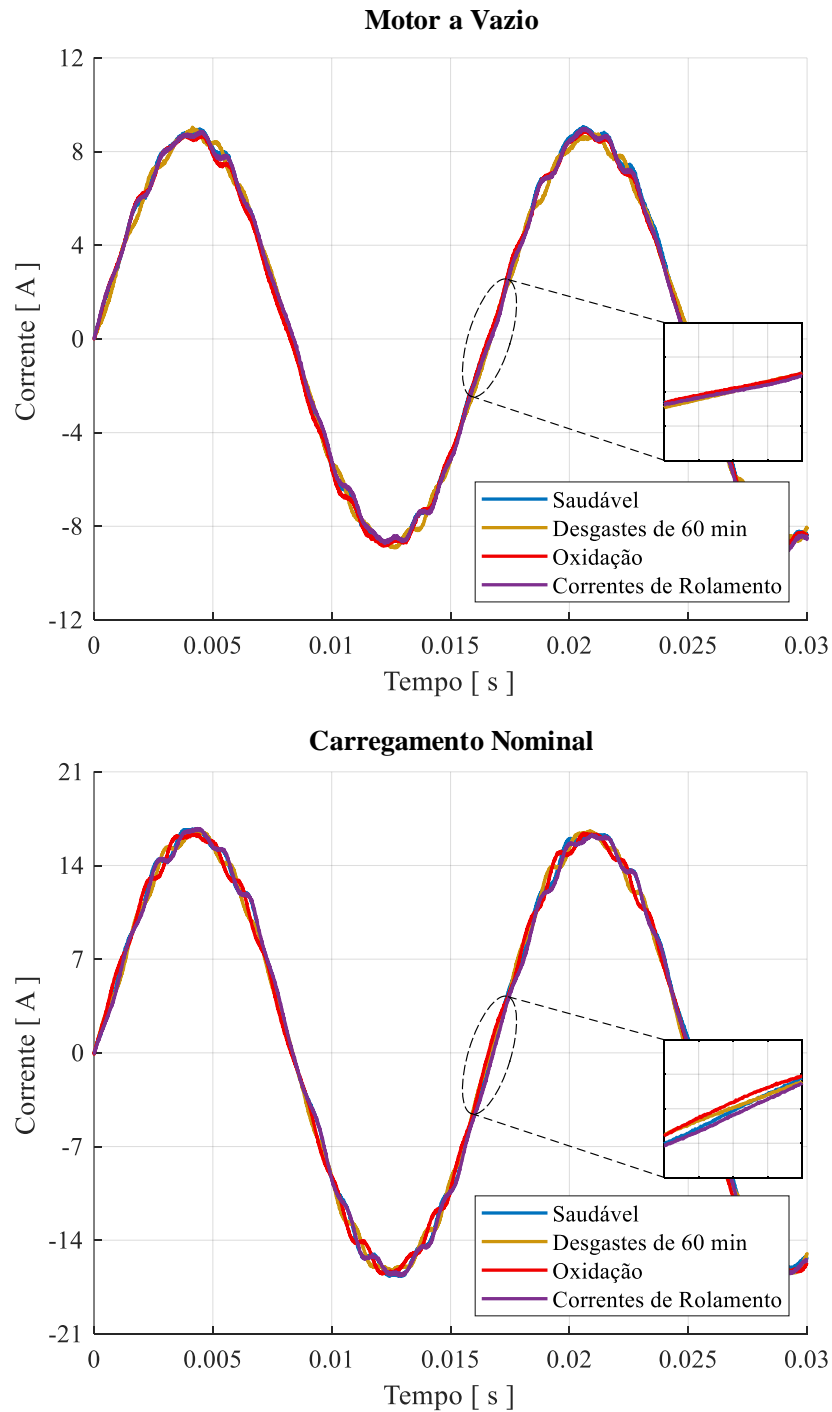
Os sinais com as falhas nos rolamentos foram obtidos por meio dos ensaios realizados com pasta abrasiva, emulando os desgastes ocorridos nas aplicações industriais. Além disso, a oxidação e o fenômeno das correntes de eixo também foram explorados por meio da degradação da superfície metálica do rolamento com ácido e danos causados por correntes de curto-circuito de uma máquina de solda. Para ampliar o espaço amostral, foram realizados diversos arranjos entre os rolamentos dianteiro e traseiro do motor de indução para variações no torque entre 50 a 110 % do valor nominal, além da máquina a vazio.

Na Figura 40 são mostradas as correntes do estator para os ensaios nº. 16, 18 e 21 na Tabela 4, que consistem nos piores cenários das falhas nos rolamentos, comparados com a condição íntegra do experimento 01. Para melhor visualização, somente é apresentada uma amostra de 30 ms da Fase A para o motor a vazio e carregamento nominal. Diante da análise gráfica, as medidas da corrente da máquina de indução possuem um comportamento senoidal semelhante entre as situações nas quais os rolamentos são submetidos às falhas com maior severidade em relação à condição saudável. Nessa situação, é possível observar que os danos nos rolamentos não revelam um comportamento bem definido, ou seja, nenhum padrão é observado no sinal da corrente quando comparada à amplitude e defasagem angular de cada falha. Além disso, o carregamento do motor não modificou os efeitos observados nas características das correntes medidas quando o conjugado no eixo foi alterado da condição a vazio ao valor nominal.

As correntes mostradas na Figura 40 possuem pequenas distorções nas proximidades dos picos das senoides para quaisquer danos nos rolamentos implementados. Nesse caso, como

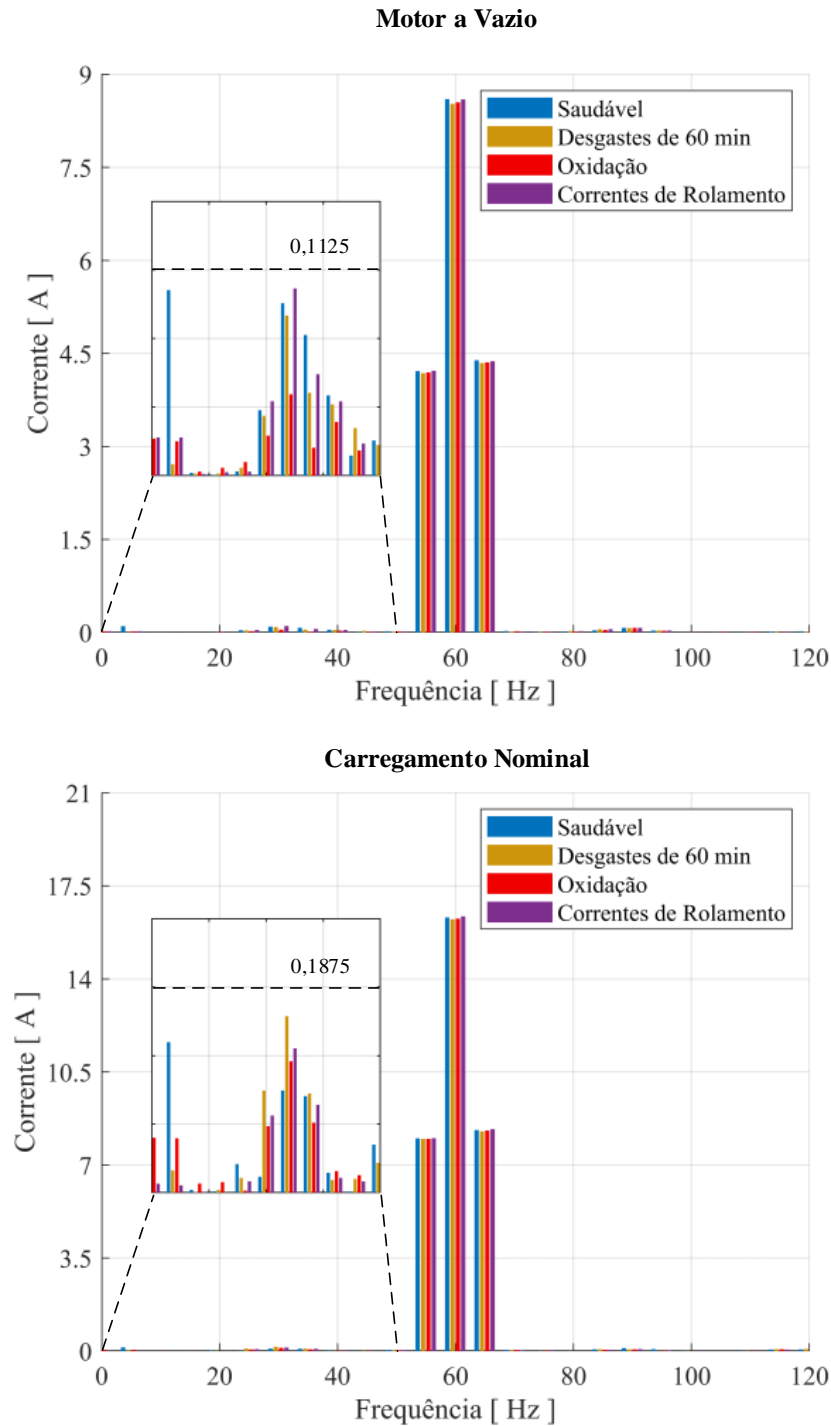
as perturbações observadas são comuns para todas as amostras (sinal de referência e falhas nos rolamentos), o fenômeno não interfere na classificação dos danos. As perturbações na corrente do estator podem ser verificadas nos espectros de frequências apresentados na Figura 41, obtidos por meio da FFT dos experimentos realizados.

Figura 40 – Falhas nos rolamentos: corrente da Fase A



Fonte: autoria própria

Figura 41 – Falhas nos rolamentos: espectro de frequências – Fase A



Fonte: autoria própria

A análise das FFT's mostradas na Figura 41 indica que as distorções mais significativas nos sinais das correntes ocorrem nas bandas laterais da frequência fundamental de 60 Hz. Independentemente do tipo de falha aplicada nos rolamentos, não é observado padrões nas componentes de frequência que indiquem a presença de danos. Mesmo com as janelas auxiliares que permitem ampliar a resolução nas baixas frequências na Figura 41, as amplitudes das correntes

não exibem um comportamento bem-definido e aumentam apenas devido às mudanças no carregamento do motor. Desse modo, os resultados observados comprovam que as equações (1) a (4) não são capazes de identificar as falhas nos rolamentos, sobretudo quando os danos abordados apresentam características distribuídas, que são o foco deste trabalho.

Os comportamentos observados nas Figuras 40 e 41 indicam que as falhas distribuídas não evidenciam os danos nos rolamentos. Embora existam diferenças na assinatura da corrente e no espectro de frequências, as falhas produzem perturbações discretas que não são facilmente observáveis. Além disso, de modo algum é possível distinguir a origem do dano entre os desgastes, oxidação e defeitos por correntes de rolamento somente pela inspeção da curva de magnitude da Transformada de Fourier.

A técnica proposta neste trabalho utiliza um mapeamento cromático para caracterizar as falhas nos rolamentos. Como será apresentado, um agrupamento de dados baseado na largura de banda eficaz, frequência média e energia dos coeficientes wavelets da corrente do estator é utilizado para distinguir a condição dos rolamentos. Após serem testadas todas as combinações dos níveis wavelets, o coeficiente de detalhe $j = 6$ mostrou-se sensível em detectar falhas distribuídas com o efeito do carregamento do motor.

6.2. Identificação dos Desgastes nos Rolamentos

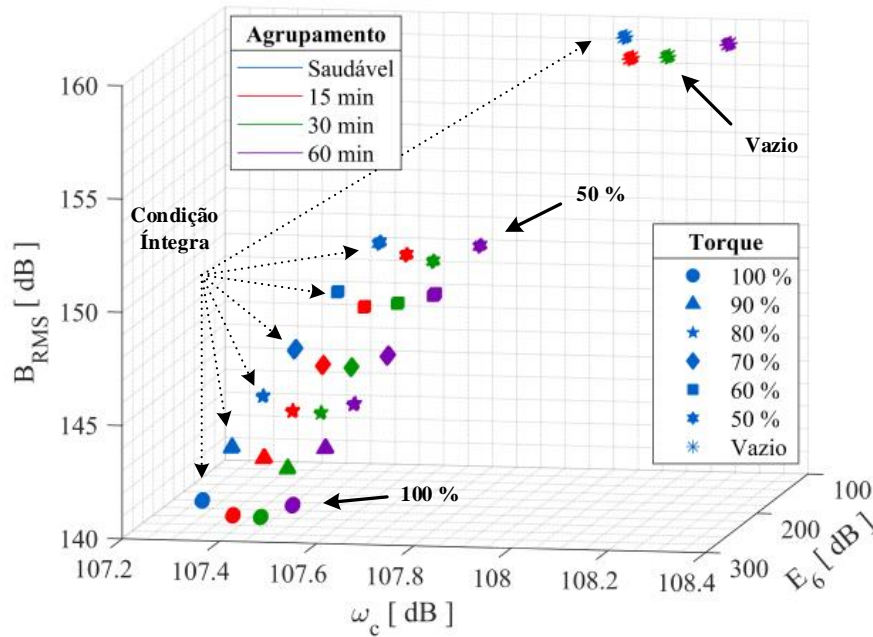
A visão geral dos resultados da metodologia proposta nos desgastes abrasivos é apresentada na Figura 42, para os experimentos nº. 01, 02, 03 e 04 na Tabela 4: rolamento traseiro na condição íntegra e dianteiro submetido as deteriorações de 15, 30 e 60 minutos.

Conforme observado na Figura 42, a abordagem proposta apresentou quatro mapas de cores distintos para cada carregamento do motor de indução. Os agrupamentos de dados obtidos mostram que a frequência média é o parâmetro com mais sensibilidade no monitoramento dos desgastes dos rolamentos. Quando a intensidade da abrasão aumenta, as perturbações no espectro de frequências da corrente, mesmo que não visíveis na análise da FFT, deslocam a massa de dados, incrementando a frequência característica do sistema em relação a condição íntegra dos rolamentos.

A largura de banda eficaz possui uma sensibilidade menor na identificação do desgaste abrasivo dos rolamentos. Como visualizado na Figura 42, o avanço da severidade da falha provoca ondulações suaves na frequência de banda da corrente do estator, revelando um deslocamento linear dos agrupamentos de dados para um conjugado constante. Por outro lado, a largura de banda permite distinguir o mapeamento cromático nos diferentes carregamentos da máquina de indução trifásica. Conforme o torque diminui, a corrente do estator decresce e os percentuais

do ruído introduzido pelo equipamento em funcionamento tendem a aumentar. Diante disso, a largura de banda reflete o fenômeno por meio de incrementos, movimentando os agrupamentos semelhante a um nível CC. Desse modo, conforme o carregamento do motor se altera, o comportamento observado das falhas nos rolamentos permanece constante.

Figura 42 – Agrupamento de dados: técnica cromática; Desgastes no rolamento dianteiro; rolamento traseiro íntegro




Fonte: autoria própria

Semelhante a largura de banda eficaz, a energia do nível de detalhe wavelets se altera conforme o carregamento é modificado. À medida que o torque aumenta, o parâmetro de energia cresce na mesma proporção que a corrente do estator. Nessa situação, a combinação das três métricas utilizadas levam os mapeamentos dos desgastes a se movimentar no espaço tridimensional, o que permite distinguir as falhas nos rolamentos sem a dependência do valor de conjugado da máquina, uma vez que os padrões observados para cada severidade abrasiva permanecem os mesmos em cada situação.

A análise realizada na Figura 42 mostra que a técnica proposta é sensível para detectar variações nos agrupamentos de dados em função da intensidade dos desgastes nos rolamentos. Nesse caso, para avaliar a qualidade dos mapeamentos obtidos, o *índice silhouette* foi calculado como validação estatística. Um valor médio foi determinado envolvendo os quatro mapeamentos cromáticos de cada conjugado do motor, como apresentado na Figura 43. O comportamento obtido mostra que independente do torque do motor, o *silhouette* é próximo da unidade. A média global dos experimentos é igual a 0,995, apontando que as observações são independentes,

isto é, cada falha corresponde ao seu respectivo agrupamento de dados, comprovando a eficácia da metodologia proposta em distinguir os danos nos rolamentos.

Figura 43 – *Índice silhouette*: desgastes no rolamento dianteiro; rolamento traseiro íntegro



Fonte: autoria própria


Para avaliar os efeitos dos danos no rolamento traseiro do motor, na Figura 44 é apresentado os experimentos n.º 01, 05, 09 e 13 na Tabela 4, em que o rolamento dianteiro é mantido na condição íntegra e traseiro submetido as deteriorações de 15, 30 e 60 minutos.

Conforme observado na Figura 44, a abordagem proposta manteve quatro mapas para cada carregamento do motor de indução, que está associado com os valores de energia do nível wavelet utilizado. No entanto, os agrupamentos de dados mostram que as falhas no rolamento traseiro estão associadas à largura de banda da corrente do estator. Embora o ruído da máquina possa variar a frequência de banda em relação ao conjugado, como discutido na Figura 42, os desgastes abrasivos intensificaram o efeito observado, tornando nítido os defeitos implementados no rolamento.

Como visualizado na Figura 44, a variação na largura de banda com base nos mapeamentos obtidos são quase que lineares, exceto por pequenas ondulações provocadas pelo parâmetro de energia. Entretanto, o progresso dos danos não mostrou um comportamento bem definido, pois o desgaste de 15 minutos reduziu a frequência de banda da corrente, enquanto que as abrasividades de 30 e 60 minutos levaram ao seu aumento quando comparadas com as condições íntegras do rolamento. Como as falhas abordadas são do tipo distribuídas, componentes de frequência podem atenuar ou reforçar em função do posicionamento dos danos. Nesse caso,

a geometria resultante das deteriorações das pistas e esferas dos rolamentos podem intensificar ou reduzir a largura de banda calculada, uma vez que os desgastes nem sempre ocorrem uniformemente sobre a peça.

Figura 44 – Agrupamento de dados: técnica cromática;
Desgastes no rolamento traseiro; rolamento dianteiro íntegro

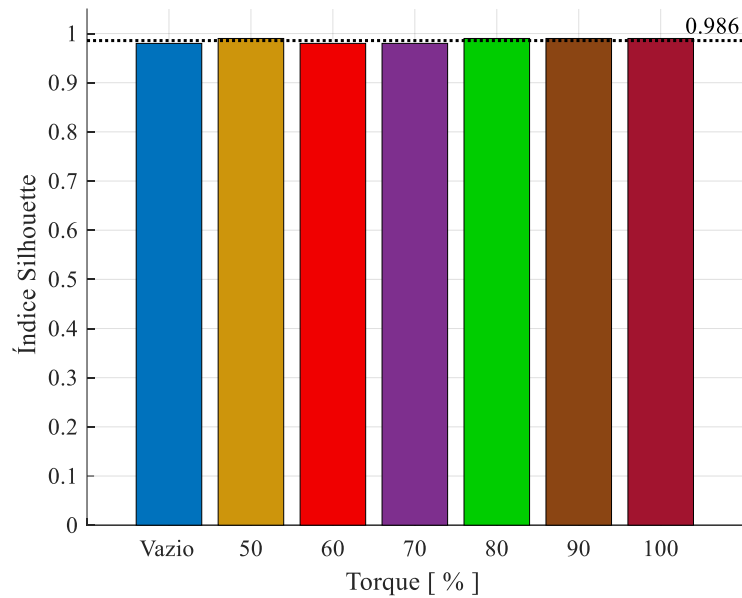


Fonte: autoria própria

Diferente das falhas no rolamento dianteiro, a frequência média mostrou menor sensibilidade aos danos no rolamento traseiro e permaneceu constante durante a aplicação das falhas. Nesse caso, a largura de banda eficaz é mais perceptível aos defeitos aplicados, sendo que o padrão observado é similar para cada conjugado do motor. Para verificar o desempenho dos agrupamentos de dados, o *índice silhouette* é exibido na Figura 45 em função do torque da máquina. O valor global obtido é igual a 0,986, apontando que cada mapeamento possui sua individualidade e pode caracterizar a falha do rolamento. Desse modo, o resultado comprova a eficácia da metodologia proposta em distinguir os danos referentes aos desgastes abrasivos.

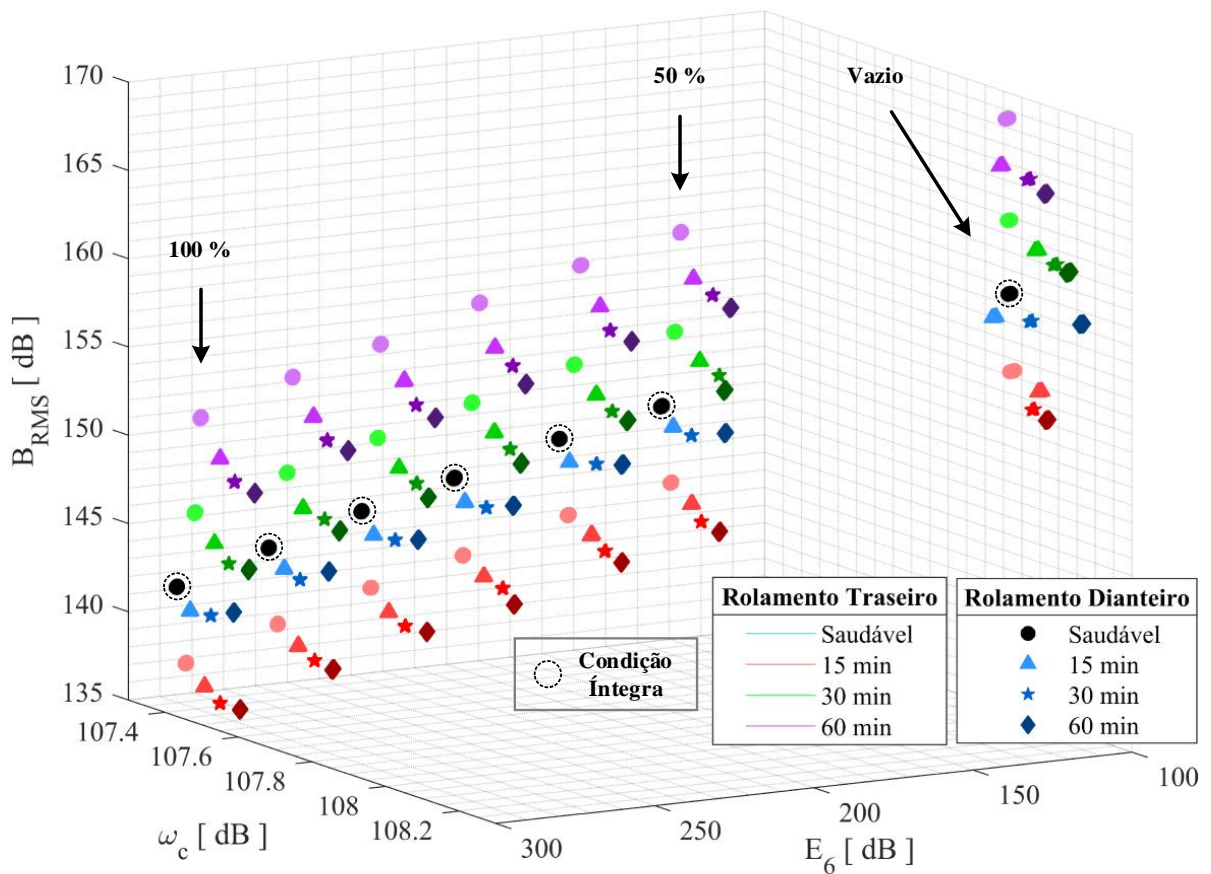
Combinando os efeitos observados nas Figuras 42 e 44, na Figura 46 são apresentados os agrupamentos de dados dos desgastes dos rolamentos dianteiro e traseiro do motor de indução trifásico. Os experimentos correspondentes são os n.º 01 ao 16 na Tabela 4. Como pode ser visualizado, os defeitos no elemento dianteiro deslocam a frequência média, enquanto que os danos na peça traseira a largura de banda eficaz. Além disso, a energia dos coeficientes wavelets permite que o mapeamento tenha o mesmo comportamento para qualquer conjugado analisado. Logo, há uma soma dos resultados discutidos, que passam a ocorrer simultaneamente.

Figura 45 – *Índice silhouette*: desgastes no rolamento traseiro; rolamento dianteiro íntegro



Fonte: autoria própria


Figura 46 – Agrupamento de dados: técnica cromática; Desgastes nos rolamentos dianteiro e traseiro simultaneamente



Fonte: autoria própria

Os agrupamentos de dados na Figura 46 mostram que o padrão dos 16 experimentos realizados é similar para os carregamentos de 50 a 100 % do motor. Por outro lado, o comportamento observado para a máquina a vazio é semelhante, porém o ruído introduzido pelo equipamento em funcionamento foi suficiente para modificar o modo com que a frequência média e a largura de banda se deslocavam em relação aos demais conjugados. Contudo, a metodologia proposta distinguiu as falhas nos rolamentos nessas condições. Além disso, o *índice silhouette* mostrado na Figura 45 garante os mapas são bem agrupados e que as amostras das falhas estão atribuídas corretamente aos seus respectivos grupos, já que o valor médio calculado foi de 0,976 e está próximo da unidade.

Figura 47 – *Índice silhouette*: desgastes nos rolamentos dianteiro e traseiro



Fonte: autoria própria

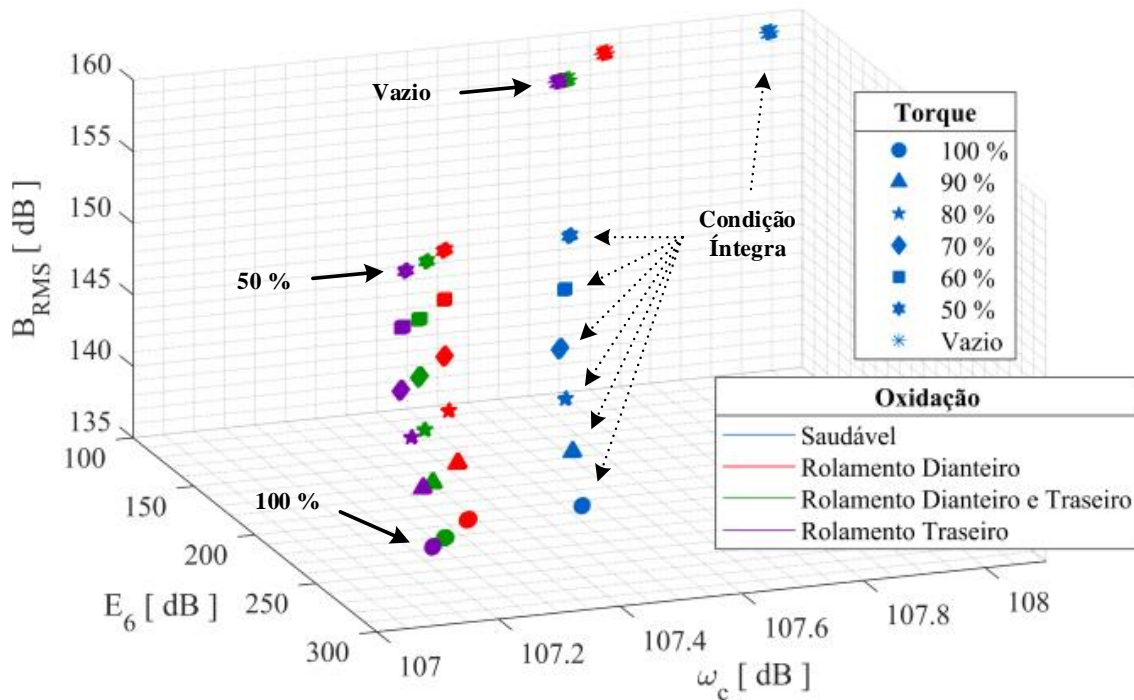
6.3. Identificação dos Danos por Oxidação

A metodologia apresentada para a identificação dos desgastes nos rolamentos também foi aplicada nos danos causados pela oxidação. Nesse caso, na Figura 48 é apresentado os experimentos n°. 17, 18, e 19 na Tabela 4, em que um dos rolamentos é mantido na condição íntegra enquanto o outro é submetido às deteriorações devido à oxidação, e em seguida, ambas as peças com as falhas emuladas.

Conforme observado na Figura 48, a abordagem proposta apresentou quatro mapas de cores distintos para cada carregamento do motor de indução. Os agrupamentos de dados obtidos mostram que a frequência média possui a maior sensibilidade aos efeitos da oxidação dos rolamentos quando comparada com a condição íntegra do sistema. Nesse caso, a presença das falhas

diminui o valor da frequência característica da corrente, sendo que o rolamento traseiro se destacou por apresentar a maior intensidade, uma vez que o mapeamento dos defeitos se encontra mais distante dos valores de referência, principalmente quando comparado com os agrupamentos que pertencem ao rolamento dianteiro.

Figura 48 – Agrupamento de dados: técnica cromática; oxidação dos rolamentos dianteiro e traseiro




Fonte: autoria própria

A análise realizada na Figura 48 também mostra que, quando ambos os rolamentos do motor são submetidos à oxidação, os agrupamentos localizam-se entre as condições nas quais somente um dos rolamentos apresentam defeitos. Além disso, os mapas dos conjugados a vazio, 90 e 100 % indicam que a presença das falhas no elemento traseiro tem caráter dominante devido à proximidade dos agrupamentos obtidos. Nesse caso, pode-se concluir que a excentricidade provocada pelos danos foi mais significativa no rolamento traseiro que no dianteiro.

A largura de banda eficaz também sofre variações com a identificação da oxidação dos rolamentos. Como visualizado na Figura 48, o avanço da severidade das falhas devido ao rolamento traseiro provoca uma redução no valor da frequência de banda. Por outro lado, a energia dos coeficientes wavelets permite distinguir o torque do motor. Nesse caso, é possível observar que o padrão das falhas devido aos efeitos da oxidação é reproduzido para qualquer conjugado analisado, exceto para a máquina vazio que possui proximidade maior dos agrupamentos.

A qualidade dos mapeamentos obtidos para a oxidação dos rolamentos é mostrada na Figura 49 para cada carregamento do motor. Como observado, os conjugados com agrupamentos de maior proximidade tendem a produzir *silhouettes* de menor desempenho. O pior cenário registrado corresponde à máquina a vazio, que possui um índice igual a 0,92. Nesse caso, o resultado obtido verifica que a técnica proposta é eficaz na identificação das falhas de oxidação dos rolamentos. Além disso, o *silhouette* médio é 0,952 e o seu valor garante a individualidade dos agrupamentos obtidos para os danos envolvidos.

Figura 49 – Índice *silhouette*: oxidação dos rolamentos



Fonte: autoria própria

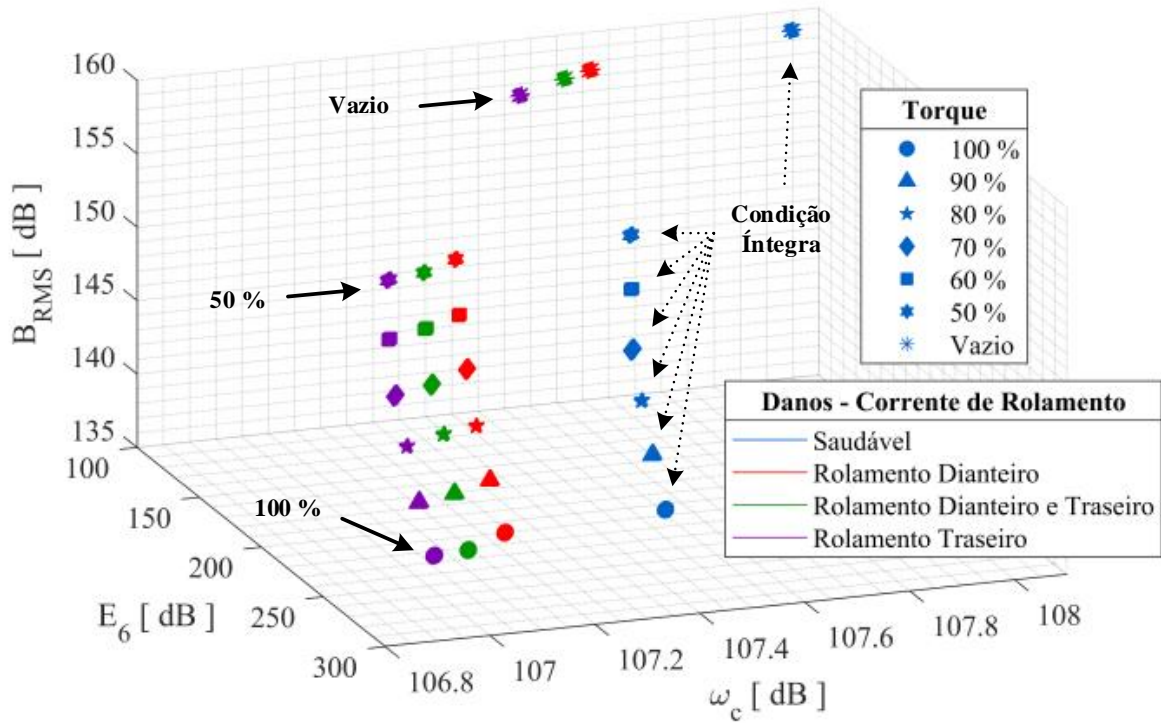
6.4. Identificação dos Danos por Correntes de Rolamento

Estendendo a aplicação da metodologia apresentada para os danos causados pelas correntes de rolamento, na Figura 50 é apresentado os experimentos nº. 20, 21, e 22 na Tabela 4, em que um dos rolamentos é mantido na condição íntegra enquanto o outro está sujeito às deteriorações devido à passagem da corrente elétrica, e em seguida, ambas as peças com as falhas implementadas.

Conforme observado na Figura 50, a abordagem proposta apresentou quatro mapas de cores distintos para cada carregamento do motor de indução. Os resultados obtidos são similares aos ensaios da oxidação. Nesse caso, os agrupamentos de dados mostram que a frequência média apresentou as maiores variações quando comparada com a largura de banda e a energia dos coeficientes de detalhe. A combinação dos três parâmetros confere um comportamento análogo das falhas os diferentes conjugados da máquina, enquanto que o desempenho dos agrupamentos


é mostrada na Figura 51 mediante o *índice silhouette*, calculado por carregamento do motor a partir dos mapas cromáticos de cada dano e da condição íntegra dos rolamentos.

Figura 50 – Agrupamento de dados: técnica cromática; danos por correntes de rolamento: elemento dianteiro e traseiro



Fonte: autoria própria

Figura 51 – *Índice silhouette*: correntes de rolamento



Fonte: autoria própria

A análise realizada na Figura 50 mostra que, quando ambos os rolamentos são submetidos aos danos da corrente, os agrupamentos localizam-se em uma região intermediária entre as condições nas quais somente um dos rolamentos contém a falha. Nesse caso, os mapas gerados concentram-se entre os efeitos individuais de cada rolamento, com exceção da máquina a vazio, no qual agrupamento observado se deslocou em direção a falha dianteira.

Conforme visualizado na Figura 50, a presença das falhas diminui a frequência característica da corrente. Os efeitos no rolamento traseiro foram mais significativos que o rolamento dianteiro do motor de indução, indicando que a excentricidade da falha se mostrou mais intensa no elemento posterior. Independente do ensaio realizado, a abordagem proposta diferenciou os efeitos das falhas. O *índice silhouette* calculado na Figura 51 contribui para o resultado obtido, uma vez a média obtida é igual a 0,997, comprovando que cada dano pertence ao seu respectivo grupo de dados.

6.5. Considerações sobre a Abordagem Proposta


A visão geral metodologia proposta para todos os danos implementados neste trabalho é apresentada na Figura 52. Para facilitar a visualização, somente o carregamento nominal é mostrado para experimentos nº. 01 ao 22 na Tabela 4: rolamentos na condição íntegra, desgastes abrasivos, oxidação e danos por correntes de rolamentos.

Conforme na Figura 52, os resultados mostrados resumem os comportamentos anteriormente discutidos. As falhas nos rolamentos têm um impacto significativo na frequência média do sistema, provocando um deslocamento dos agrupamentos de dados. Dependendo da intensidade e característica dos danos, a largura de banda eficaz também sofre variações. Além disso, a energia dos coeficientes de detalhe wavelets associa-se com a intensidade da corrente absorvida pelo motor em função do torque analisado. Desse modo, os padrões observados são reproduzidos para qualquer carregamento analisado.

Como a abordagem proposta mostrou-se sensível às alterações discretas da frequência média, largura de banda e níveis de energia para um mesmo conjugado, os resultados obtidos comprovam que a técnica do mapeamento cromático forma regiões que distinguem falhas distribuídas nos rolamentos quando comparadas com as condições originais ou íntegras.

O *índice silhouette* médio dos 22 agrupamentos na Figura 52 é igual a 0,98. Esse parâmetro de desempenho estatístico mostra as observações são independentes e que cada amostra do mapeamento cromático pertence ao seu respectivo grupo. Por conseguinte, os mapas de cada falha podem ser utilizados com segurança na classificação dos resultados por um sistema inteligente, como será apresentado.

Figura 52 – Agrupamento de dados: técnica cromática; falhas nos rolamentos dianteiro e traseiro



Rolamento Dianteiro x Rolamento Traseiro	
● Saudável x Saudável	● 60 min x 30 min
● 15 min x Saudável	● Saudável x 60 min
● 30 min x Saudável	● 15 min x 60 min
● 60 min x Saudável	● 30 min x 60 min
● Saudável x 15 min	● 60 min x 60 min
● 15 min x 15 min	● Saudável x Oxidação
● 30 min x 15 min	● Oxidação x Oxidação
● 60 min x 15 min	● Oxidação x Saudável
● Saudável x 30 min	● Saudável x Corrente
● 15 min x 30 min	● Current x Corrente
● 30 min x 30 min	● Corrente x Saudável

Fonte: autoria própria

6.6. Análise do Desempenho da Rede Neural Artificial

Mediante as combinações de treinamento apresentadas pela Tabela 6, a entrada da rede neural artificial foi alimentada pelos mapeamentos formados pela largura de banda eficaz, frequência média e energia dos coeficientes de detalhe wavelet (nível 6). A saída do sistema é dividida em três grupos: carregamento do motor, grupos de ensaios e experimentos realizados (Tabela 5). Para todas as classificações, foi definido que 70 % das amostras seriam o conjunto de treinamento, 15 % a validação e 15 % os testes.

A partir da matriz de confusão de cada topologia experimentada, a porcentagem total dos casos classificados de forma incorreta é apresentada na Tabela 7 para o conjunto das saídas da RNA, obtidas por meio do software MATLAB/Simulink®:

Tabela 7 – Erro percentual das topologias das RNA


Topologia	Erro Percentual (%)		
	Carregamento (Saída 01 a 07)	Grupo (Saídas 08 a 13)	Experimento (Saídas 14 a 17)
1	0,75	5,56	11,12
2	0,12	5,44	9,06
3	0,21	2,26	3,77
4	0,17	0,46	0,76
5	0,06	0,72	1,19
6	0,01	0,64	1,07
7	0,00	0,17	0,71
8	0,00	0,01	0,34
9	0,00	0,56	0,81

Fonte: autoria própria

A partir da análise dos erros de classificação, na Tabela 7 é observado que o conjugado do motor de indução pode ser identificado independentemente da topologia adotada, uma vez que o erro máximo visualizado foi de 0,75 %. Contudo, as saídas que envolvem as combinações dos experimentos e ensaios possuem taxas de acerto maiores conforme o número de neurônios da camada de entrada aumenta. Nessa situação, a Topologia 8 (35 neurônios) forneceu o melhor desempenho, uma vez que a incerteza da classificação das saídas 08 a 13 é de 0,01 %, enquanto que as saídas 14 a 17 é de 0,34 %. Nessa configuração, o erro no carregamento é nulo.

Considerando a Topologia 8, na Figura 53 é mostrado o parâmetro de performance da rede neural utilizada em função das épocas de treinamento. Nesse caso, nota-se que nas primeiras 1.000 épocas o algoritmo *crossentropy* estabiliza rapidamente semelhante a um decaimento exponencial, mostrando que não há necessidade de treinamentos mais longos na classificação dos danos dos rolamentos. Desse modo, o critério de parada inicialmente atribuído para 1.500 épocas é suficiente para treinar a RNA. Embora o algoritmo utilize uma função de convergência com o critério de parada (objetivo) padrão em 0,01, o parâmetro de performance obtido foi igual a 0,2 para a topologia escolhida. Como os erros calculados na Tabela 7 para a Topologia 08 são menores 0,5 %, o valor final da performance não interferiu no desempenho da RNA.


Figura 53 – Performance da RNA



Fonte: autoria própria

O histograma de erros da rede neural utilizada é mostrado na Figura 54. O comportamento observado é de que a distribuição dos erros ficou muito próxima ao erro nulo tanto para os dados de treinamento, quanto para os dados de validação e testes para as diferentes combinações dos danos nos rolamentos. Como os erros calculados são próximos de zero, o resultado realça que a taxa de acertos da RNA é extremamente alta. Além disso, a distribuição dos erros não se assemelha a uma distribuição gaussiana, sugerindo uma estrutura paramétrica.

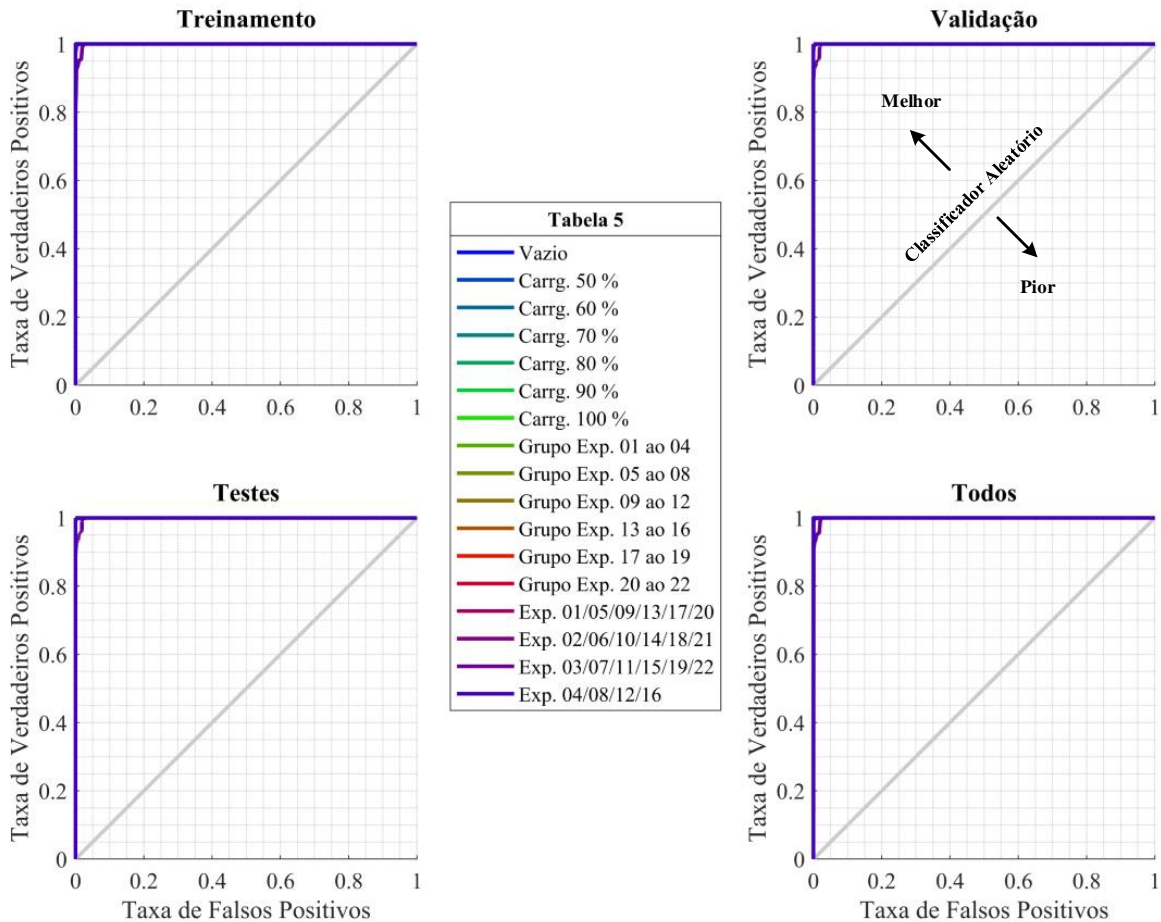
Figura 54 – Histograma de erros da RNA



Fonte: autoria própria

Para validar o desempenho da rede neural utilizada, a Característica de Operação do Receptor (ROC) ilustra o desempenho da rede neural quanto a classificação dos dados. O comportamento das saídas é apresentado na Figura 55:

Figura 55 – Curvas ROC da RNA



Fonte: autoria própria

As curvas ROC são analisadas a partir da linha de classificação aleatória. Nesse caso, os valores abaixo dessa região exprimem que a RNA não aprendeu a classificar os resultados a partir dos conjuntos de entrada e as probabilidades da saída são definidas de forma puramente arbitrária, isto é, aleatória, fornecendo o pior desempenho para o sistema. Em contrapartida, os gráficos que se localizam acima da linha de referência correspondem a previsões mais confiáveis, na qual o modelo comete menos falsos positivos e falsos negativos, isto é, erros de classificação. Nesse caso, conforme observado na Figura 55, as curvas ROC das saídas da rede neural da Topologia 08 possui uma classificação quase que perfeita, pois à medida que a taxa de verdadeiros positivos diminui, o modelo não comete um falso positivo, pois a taxa é igual a zero. Por outro lado, se a taxa de falsos positivos aumentar, a RNA obtida está sempre em 100 % dos verdadeiros positivos, indicando que não comete erros.

Como as curvas ROC na Figura 55 são similares, isto é, possuem a mesma probabilidade estimada. Dessa forma, o método da área sobre a curva (AUC) é aplicado como um complemento para exprimir a confiabilidade das previsões de cada saída. Os resultados calculados são mostrados na Tabela 8:

Tabela 8 – Área sobre a curva ROC

Saída da RNA	Tipo de Saída	AUC (%)
1	Vazio	100
2	Carrg. 50 %	100
3	Carrg. 60 %	100
4	Carrg. 70 %	100
5	Carrg. 80 %	100
6	Carrg. 90 %	100
7	Carrg. 100 %	100
8	Grupos Exp. 01 ao 04	99,99
9	Grupos Exp. 05 ao 08	99,99
10	Grupos Exp. 09 ao 12	99,99
11	Grupos Exp. 13 ao 16	99,99
12	Grupos Exp. 17 ao 19	99,97
13	Grupos Exp. 20 ao 21	99,99
14	Exp. 01/05/09/13/17/20	99,86
15	Exp. 02/06/10/14/18/21	99,72
16	Exp. 03/07/11/15/19/22	99,41
17	Exp. 04/08/12/16	99,99

Fonte: autoria própria

As áreas sob as curvas ROC na Tabela 8 mostram que as saídas de 1 a 7 da RNA, que se referem ao conjugado do motor, possuem previsões 100 % corretas. Por outro lado, a classificação das falhas nos rolamentos (saídas 8 a 17) apresentam um modelo com mais de 99,4 % de confiança de que a probabilidade do dano identificado pertence a condição localizada. Desse modo, a partir das curvas ROC e os valores da AUC, a rede neural artificial implementada neste trabalho classifica as falhas nos rolamentos a partir da abordagem proposta para os agrupamentos de dados baseados nos mapeamentos cromáticos.

6.7. Conclusão do Capítulo

O presente capítulo apresentou resultados experimentais referentes à metodologia proposta para esta tese, que engloba a identificação e a classificação das falhas nos rolamentos de motores de indução trifásicos. Por meio da assinatura da corrente do estator e das técnicas de processamento de sinais, os danos nos rolamentos foram detectados fazendo uso mapeamentos cromáticos tridimensionais. Os defeitos implementados consistiram nos desgastes abrasivos, na oxidação e nas deteriorações por correntes de rolamento, em que os comportamentos observados foram especificados por uma rede neural probabilística.

Para formação dos mapas de cores, foram utilizados três parâmetros: frequência média, largura de banda eficaz e energia dos coeficientes de detalhe wavelet. Os resultados observados mostraram que as falhas nos rolamentos provocam um deslocamento dos agrupamentos de dados formados por essas métricas em relação a condição íntegra. Nesse caso, as falhas emuladas movem os valores da frequência média e largura banda, enquanto que o carregamento do motor se relaciona com a energia wavelet da corrente, reproduzindo os padrões obtidos independentemente do torque solicitado no eixo.

Em uma análise geral, a abordagem proposta mostrou-se sensível às alterações discretas da frequência média, largura de banda e níveis de energia para um mesmo carregamento. O índice silhouette permitiu verificar que os resultados obtidos comprovam que a técnica do mapeamento cromático forma regiões que distinguem falhas distribuídas nos rolamentos em relação às condições saudáveis. A individualidade dos agrupamentos foi superior a 95 % e permitiu utilizar uma rede neural com treinamento bayesiano que apresentou um modelo de 99,4 % de confiança na probabilidade estimada dos danos.

Assim, os resultados apresentados nesta tese mostram-se eficientes na indentação dos danos em rolamentos, sendo capaz de diagnosticar falhas de diferentes origens e intensidades. Ainda, a metodologia proposta pode ser aplicada sob diversas condições de conjugado de carga, mas com limitado a tensões equilibradas e puramente senoidais. O próximo capítulo discute as conclusões deste trabalho e as perspectivas para trabalhos futuros.

CAPÍTULO 7

CONCLUSÃO

A detecção e a classificação das falhas nos rolamentos são de grande importância no diagnóstico do motor de indução trifásico em relação à segurança, a manutenção preditiva e a redução nos tempos de paradas não programadas. Tanto a ciência quanto a indústria têm buscado desenvolver sistemas capazes de fornecer diagnósticos confiáveis das condições dos rolamentos, a fim de reduzir os custos por meio de manutenções eficientes. Embora seja uma metodologia de monitoramento e identificação das falhas intensivamente estudada nas últimas décadas, poucos trabalhos têm utilizado a assinatura da corrente do estator na detecção dos danos distribuídos nos rolamentos.

Tomando como base essa problemática, esta tese apresenta uma nova abordagem e sua capacidade de identificar e separar os diferentes tipos de danos distribuídos presentes nos rolamentos das máquinas de indução a partir da corrente do estator. O método proposto aplica sensores de corrente de efeito Hall para monitorar a assinatura da corrente trifásica e, consequentemente, os danos nos rolamentos. Por meio de técnicas de processamento de sinais e mapeamentos cromáticos, a abordagem distingui as características das falhas por meio de agrupamentos de dados tridimensionais.

A partir dessa contextualização, os conceitos de frequência média, largura de banda eficaz e energia dos coeficientes wavelets foram utilizados para as formações dos mapas a partir dos sinais amostradas da corrente do estator. As falhas exploradas emularam deteriorações distribuídas nos rolamentos dianteiro e traseiro do motor de indução, simulando o uso excessivo dos ambientes industriais por meio dos desgastes abrasivos, assim como oxidação e danos gerados pelas correntes de rolamento. Diferentes valores de conjugado foram aplicados no motor para monitorar o comportamento das falhas.

Os resultados apresentados mostraram que as diferentes falhas aplicadas nos rolamentos da máquina produzem perturbações na envoltória senoidal da corrente do estator, no entanto nenhum comportamento ou padrão é registrado em relação à amplitude e deslocamento angular. Além disso, a análise pura da FFT dos sinais amostrados não revelou componentes de frequência para identificar a existência dos danos nos rolamentos, muito menos permitiu distinguir as condições das falhas aplicadas. Como os danos emulados são do tipo distribuídos, o torque do motor também não evidenciou a característica das falhas estudadas.

Nesse contexto, a abordagem proposta neste trabalho mostrou sensibilidade às alterações na frequência média, largura de banda eficaz e energia dos coeficientes wavelets para as

diferentes falhas implementadas. Os resultados obtidos constatam que a técnica do mapeamento cromático forma regiões que distinguem os danos distribuídos nos rolamentos quando comparadas com as condições íntegras. Também foi verificado que os comportamentos de cada mapa das falhas se reproduzem para os diferentes conjugados do motor. Essa condição implica que a metodologia proposta pode ser aplicada para monitorar a máquina trifásica independentemente do valor do torque solicitado no eixo.

Devido ao alto número de agrupamentos para um mesmo carregamento do motor e as variações discretas dos mapas entre as intensidades e os tipos de falhas, o *índice silhouette* foi utilizado para avaliar o desempenho do método proposto. Os valores obtidos variam entre 0,952 a 0,995 e estão próximos da unidade, sustentando uma validação estatística de que cada observação é independente e que as amostras dos agrupamentos pertencem ao respectivo grupo identificado. Esse resultado permitiu que os mapeamentos fossem aplicados no treinamento de uma rede neural artificial para classificar as falhas nos rolamentos. A partir da característica da operação do receptor e a área sobre as curvas ROC, a topologia implementada mostrou 99,4 % de confiabilidade na probabilidade da classificação dos danos.

O presente estudo se deu como uma contribuição aos sistemas baseados na identificação das falhas distribuídas nos rolamentos a partir da corrente do estator do motor de indução. A abordagem desenvolvida e apresentada nesse trabalho contribuí na expansão das técnicas das técnicas de monitoramento de máquinas elétricas em aplicações reais. Entretanto, no desenvolvimento da metodologia proposta, desbalanços e harmônicos na alimentação do motor não foram considerados. Sendo assim, para trabalhos futuros, esse tipo de investigação para as métricas utilizadas no mapeamento das falhas nesta tese se torna desejável. Nesse caso, a aplicação de senoides reais, isto é, a conexão direta com a rede sem o auxílio de uma fonte programável deve ser estudada, assim como a presença de tensões desequilibradas. Além disso, um acionamento por meio de inversores de frequência pode ser explorado para avaliar o comportamento da técnica proposta com a introdução de harmônicos na alimentação do motor de indução.

PUBLICAÇÕES

Trabalho Completo Publicado em Anais de Congresso

SOUZA, W. G.; CASTRO, B. A.; LUCAS, G. B.; ROCHA M. A.; ANDREOLI, A. L. Identificação de Falhas Em Rolamentos Aplicados Em Motores de Indução Por Meio de Sensores de Corrente. **14th IEEE/IAS International Conference on Industry Applications**, 2021.

Cooperação em Trabalho Completo Publicado em Anais de Congresso

COSTA, C. F.; ROCHA, M. A.; SOUZA, W. G.; JUSTINO, P. T.; ANDREOLI, A. L. Implementation of na Induction Motor Mathematical Model for Stator Winding Fault Analysis. **13th IEEE/IAS International Conference on Industry Applications**, Novembro, 2018.

OZAWA, F.; ROCHA, M. A.; LUCAS, G. B.; SOUZA, W. G.; ANDREOLI, A. L. Application of Torque Transducer and Rotary Encoder in a Hardware-in-the-Loop Wind Turbine Emulation. **Proceedings, MDPI AG**, v. 42, n. 1, p. 55, novembro, 2019. DOI: 10.3390/ecsa-6-06633.

ROCHA M. A.; LUCAS, G. B.; SOUZA, W. G.; CASTRO, B. A.; ANDREOLI, A. L. Detection and Phase Identification of Inter-Turn Short-Circuit Faults in Three-Phase Induction Motors Using MEMS Accelerometer and Hilbert Transform. **14th IEEE/IAS International Conference on Industry Applications**, 2021.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABOOD, S. I. **Digital Signal Processing: A Primer With MATLAB®**. 1^a ed. [s.l.]: CRC Press, Taylor & Francis Group, 2020. 338 p. ISBN: 978-0-367-44493-8.
- ABU-RUB, H.; MALINOWSKI, M.; AL-HADDAD, K. **Power electronics for renewable energy systems, transportation, and industrial applications**. 1^a ed. [s.l.]: John Wiley & Sons Ltd, 2014. 795 p. ISBN: 978-1-118-63403-5.
- ADDISON, P. S. **The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance**. 2^a ed. [s.l.]: CRC Press, Taylor & Francis Group, 2017. 446 p. ISBN: 978-1-4822-5132-6.
- ADOUNI, A.; J. MARQUES CARDOSO, A. **Thermal Analysis of Low-Power Three-Phase Induction Motors Operating under Voltage Unbalance and Inter-Turn Short Circuit Faults**. *Machines*, [s.l.], v. 9, n^o 1, p. 2, 2021. DOI: 10.3390/machines9010002.
- AI, X. **Angular Contact Bearings**. Em: WANG, Q. J.; CHUNG, Y.-W. (Orgs.). *Encyclopedia of Tribology*. Boston, MA: Springer US, 2013. p. 80–83. ISBN: 978-0-387-92897-5, DOI: 10.1007/978-0-387-92897-5_335.
- ALSHORMAN, O. et al. **A Review of Artificial Intelligence Methods for Condition Monitoring and Fault Diagnosis of Rolling Element Bearings for Induction Motor**. *Shock and Vibration*, [s.l.], v. 2020, p. e8843759, 2020. ISSN: 1070-9622, DOI: 10.1155/2020/8843759.
- ALVAREZ, M. A. Z. et al. **Demand Response Strategy Applied to Residential Electric Water Heaters Using Dynamic Programming and K-Means Clustering**. *IEEE Transactions on Sustainable Energy*, [s.l.], v. 11, n^o 1, p. 524–533, 2020. ISSN: 1949-3037, DOI: 10.1109/TSTE.2019.2897288.
- ALVAREZ-GONZALEZ, F.; GRIFFO, A.; WANG, B. **Permanent magnet synchronous machine stator windings fault detection by Hilbert–Huang transform**. *The Journal of Engineering*, [s.l.], v. 2019, n^o 17, p. 3505–3509, 2019. ISSN: 2051-3305, DOI: 10.1049/joe.2018.8173.
- AMBUR, R.; RINDERKNECHT, S. **Unbalance detection in rotor systems with active bearings using self-sensing piezoelectric actuators**. *Mechanical Systems and Signal Processing*, [s.l.], v. 102, p. 72–86, 2018. ISSN: 0888-3270, DOI: 10.1016/j.ymsp.2017.09.006.
- AMEID, T. et al. **Broken rotor bar fault diagnosis using fast Fourier transform applied to field-oriented control induction machine: simulation and experimental study**. *The International Journal of Advanced Manufacturing Technology*, [s.l.], v. 92, n^o 1, p. 917–928, 2017. ISSN: 1433-3015, DOI: 10.1007/s00170-017-0143-2.
- _____. **Discrete wavelet transform and energy eigen value for rotor bars fault detection in variable speed field-oriented control of induction motor drive**. *ISA Transactions*, [s.l.], v. 79, p. 217–231, 2018. ISSN: 0019-0578, DOI: 10.1016/j.isatra.2018.04.019.
- AMIRAT, Y. et al. **EEMD-based notch filter for induction machine bearing faults detection**. *Applied Acoustics*, [s.l.], v. 133, p. 202–209, 2018. ISSN: 0003-682X, DOI: 10.1016/j.apacoust.2017.12.030.

ANTONINO-DAVIU, J. A. et al. **A Critical Comparison Between DWT and Hilbert–Huang-Based Methods for the Diagnosis of Rotor Bar Failures in Induction Machines.** *IEEE Transactions on Industry Applications*, [s.l.], v. 45, n° 5, p. 1794–1803, 2009. ISSN: 1939-9367, DOI: 10.1109/TIA.2009.2027558.

ARDILA-REY, J. A. et al. **A Comparison of Inductive Sensors in the Characterization of Partial Discharges and Electrical Noise Using the Chromatic Technique.** *Sensors*, [s.l.], v. 18, n° 4, p. 1021, 2018. DOI: 10.3390/s18041021.

AZEEZ, A. A.; ALKHEDHER, M.; GADALA, M. S. **Thermal Imaging Fault Detection for Rolling Element Bearings.** [s.l.]: [s.n.], 2020. DOI: 10.1109/ASET48392.2020.9118361.

BAIMEL, D. et al. **Dynamic Modeling of Networks, Microgrids, and Renewable Sources in the dq0 Reference Frame: A Survey.** *IEEE Access*, [s.l.], v. 5, p. 21323–21335, 2017. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2017.2758523.

BATAL, K. E. et al. **Diagnostic of electromechanical system by fault-tolerant-control using piezoelectric sensors.** *European Physical Journal. Applied Physics*, [s.l.], v. 91, n° 3, p. 30101, 2020. ISSN: 1286-0050, DOI: 10.1051/epjap/2020200162.

BAZAN, G. H. et al. **Information Theoretical Measurements From Induction Motors Under Several Load and Voltage Conditions for Bearing Faults Classification.** *IEEE Transactions on Industrial Informatics*, [s.l.], v. 16, n° 6, p. 3640–3650, 2020. ISSN: 1941-0050, DOI: 10.1109/TII.2019.2939678.

BESSOUS, N. et al. **Diagnosis of bearing defects in induction motors using discrete wavelet transform.** *International Journal of System Assurance Engineering and Management*, [s.l.], v. 9, n° 2, p. 335–343, 2018. ISSN: 0976-4348, DOI: 10.1007/s13198-016-0459-6.

BLANCHARD, P.; HIGHAM, D. J.; HIGHAM, N. J. **Accurate Computation of the Log-Sum-Exp and Softmax Functions.** *arXiv:1909.03469 [cs, math]*, [s.l.], 2019.

BOASHASH, B. **Time-Frequency Signal Analysis and Processing.** 1^a ed. [s.l.]: Academic Press, 2016. 1020 p. ISBN: 978-0-12-398499-9.

BOGLIETTI, A. et al. **Winding Thermal Model for Short-Time Transient: Experimental Validation in Operative Conditions.** *IEEE Transactions on Industry Applications*, [s.l.], v. 54, n° 2, p. 1312–1319, 2018. ISSN: 1939-9367, DOI: 10.1109/TIA.2017.2777920.

BONYÁR, A. **Application of localization factor for the detection of tin oxidation with AFM.** [s.l.]: [s.n.], 2015. DOI: 10.1109/SITME.2015.7342289.

BOUDINAR, A. H. et al. **Induction Motor Bearing Fault Analysis Using a Root-MUSIC Method.** *IEEE Transactions on Industry Applications*, [s.l.], v. 52, n° 5, p. 3851–3860, 2016. ISSN: 1939-9367, DOI: 10.1109/TIA.2016.2581143.

BOYLESTAD, R. L.; NASHELKY, L. **Dispositivos Eletrônicos e Teoria dos Circuitos.** 11^a ed. [s.l.]: Pearson Universidades, 2013. 784 p. ISBN: 978-85-64574-21-2.

BRITO, J.; FILHO, P.; CHRISTOFORO, A. **Study of damages in bearings proceeding from tensions and currents parasites using the sensor Shaft Probe.** *Revista Vértices*, [s.l.], v. 13, n° 3, p. 143–155, 2011. DOI: 10.5935/1809-2667.20110030.

BUSSE, D. et al. **Bearing currents and their relationship to PWM drives.** *IEEE Transactions on Power Electronics*, [s.l.], v. 12, n° 2, p. 243–252, 1997. ISSN: 1941-0107, DOI: 10.1109/63.558735.

CAVALLINI, A.; FABIANI, D.; MONTANARI, G. C. **Power electronics and electrical insulation systems ρ Part 1: Phenomenology overview.** *IEEE Electrical Insulation Magazine*, [s.l.], v. 26, n° 3, p. 7–15, 2010. ISSN: 1558-4402, DOI: 10.1109/MEI.2010.5482783.

CHATTERJEE, A. K. S., Sukanta Das, Tarun Kumar. **Wavelet Transform Based Ball Bearing Fault Detection Scheme for Heavy Duty Mining Electrical Motors under Supply Frequency Regulation using MCSA.** *IJTech - International Journal of Technology*, [s.l.], v. 9, n° 1, p. 170–180, 2018. DOI: <https://doi.org/10.14716/ijtech.v9i1.1507>.

CHEN, X.; YANG, Y. **Analysis of the partial discharge of ultrasonic signals in large motor based on Hilbert-Huang transform.** *Applied Acoustics*, [s.l.], v. 131, p. 165–173, 2018. ISSN: 0003-682X, DOI: 10.1016/j.apacoust.2017.10.028.

CHEN, Z. et al. **Deep neural networks-based rolling bearing fault diagnosis.** *Microelectronics Reliability*, [s.l.], v. 75, p. 327–333, 2017. ISSN: 0026-2714, DOI: 10.1016/j.microrel.2017.03.006.

CHENG, L. et al. **The Optimal Wavelet Basis Function Selection in Feature Extraction of Motor Imagery Electroencephalogram Based on Wavelet Packet Transformation.** *IEEE Access*, [s.l.], v. 7, p. 174465–174481, 2019. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2019.2953972.

CHOUDHARY, A.; GOYAL, D.; LETHA, S. S. **Infrared Thermography-Based Fault Diagnosis of Induction Motor Bearings Using Machine Learning.** *IEEE Sensors Journal*, [s.l.], v. 21, n° 2, p. 1727–1734, 2021. ISSN: 1558-1748, DOI: 10.1109/JSEN.2020.3015868.

CHUI, C. K. **Wavelets: A Mathematical Tool for Signal Analysis.** [s.l.]: Society for Industrial and Applied Mathematics, 1997. 228 p. ISBN: 978-0-89871-384-8.

CROTTI, G. et al. **Frequency Response of MV Voltage Transformer Under Actual Waveforms.** *IEEE Transactions on Instrumentation and Measurement*, [s.l.], v. 66, n° 6, p. 1146–1154, 2017. ISSN: 1557-9662, DOI: 10.1109/TIM.2017.2652638.

CUNHA, R. G. C.; TEODORO DA SILVA, E.; MEDEIROS, C. M. de S. **Machine learning and multiresolution decomposition for embedded applications to detect short-circuit in induction motors.** *Computers in Industry*, [s.l.], v. 129, p. 103461, 2021. ISSN: 0166-3615, DOI: 10.1016/j.compind.2021.103461.

DALVAND, F. et al. **Current Noise Cancellation for Bearing Fault Diagnosis Using Time Shifting.** *IEEE Transactions on Industrial Electronics*, [s.l.], v. 64, n° 10, p. 8138–8147, 2017. ISSN: 1557-9948, DOI: 10.1109/TIE.2017.2694397.

_____. **Detection of Generalized-Roughness and Single-Point Bearing Faults Using Linear Prediction-Based Current Noise Cancellation.** *IEEE Transactions on Industrial Electronics*, [s.l.], v. 65, n° 12, p. 9728–9738, 2018. ISSN: 1557-9948, DOI: 10.1109/TIE.2018.2821645.

DEHINA, W.; BOUMEHRAZ, M.; KRATZ, F. **Diagnosis of Rotor and Stator Faults by Fast Fourier Transform and Discrete Wavelet in Induction Machine.** [s.l.]: [s.n.], 2018. DOI: 10.1109/CISTEM.2018.8613311.

DEMS, M.; KOMEZA, K. **Designing an Energy-Saving Induction Motor Operating in a Wide Frequency Range.** *IEEE Transactions on Industrial Electronics*, [s.l.], v. 69, n° 5, p. 4387–4397, 2022. ISSN: 1557-9948, DOI: 10.1109/TIE.2021.3082057.

DENG, W. et al. **A Novel Fault Diagnosis Method Based on Integrating Empirical Wavelet Transform and Fuzzy Entropy for Motor Bearing.** *IEEE Access*, [s.l.], v. 6, p. 35042–35056, 2018. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2018.2834540.

DINARDO, G.; FABBIANO, L.; VACCA, G. **A smart and intuitive machine condition monitoring in the Industry 4.0 scenario.** *Measurement*, [s.l.], v. 126, p. 1–12, 2018. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2018.05.041.

DING, C. et al. **Kernel ridge regression-based chirplet transform for non-stationary signal analysis and its application in machine fault detection under varying speed conditions.** *Measurement*, [s.l.], v. 192, p. 110871, 2022. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2022.110871.

DONOLO, P.; BOSSIO, G.; DE ANGELO, C. **Analysis of voltage unbalance effects on induction motors with open and closed slots.** *Energy Conversion and Management*, [s.l.], v. 52, n° 5, p. 2024–2030, 2011. ISSN: 0196-8904, DOI: 10.1016/j.enconman.2010.10.045.

DORRELL, D. G. **Magnetic Bearings and Bearingless Drives.** 1^a ed. [s.l.]: Newnes, 2005. 381 p. ISBN: 978-0-7506-5727-3.

DUQUE-PEREZ, O. et al. **Condition Monitoring of Bearing Faults Using the Stator Current and Shrinkage Methods.** *Energies*, [s.l.], v. 12, n° 17, p. 3392, 2019. ISSN: 1996-1073, DOI: 10.3390/en12173392.

ELBOUCHIKHI, E. et al. **An Efficient Hilbert–Huang Transform-Based Bearing Faults Detection in Induction Machines.** *IEEE Transactions on Energy Conversion*, [s.l.], v. 32, n° 2, p. 401–413, 2017. ISSN: 1558-0059, DOI: 10.1109/TEC.2017.2661541.

EWERT, P.; KOWALSKI, C. T.; ORLOWSKA-KOWALSKA, T. **Low-Cost Monitoring and Diagnosis System for Rolling Bearing Faults of the Induction Motor Based on Neural Network Approach.** *Electronics*, [s.l.], v. 9, n° 9, p. 1334, 2020. ISSN: 2079-9292, DOI: 10.3390/electronics9091334.

FAIZ, J.; GHORBANIAN, V.; JOKSIMOVIĆ, G. **Fault Diagnosis of Induction Motors.** 1^a ed. [s.l.]: The Institution of Engineering and Technology, 2017. 517 p. ISBN: 978-1-78561-329-6.

FENG, X. et al. **Prediction of Slope Stability using Naive Bayes Classifier.** *KSCE Journal of Civil Engineering*, [s.l.], v. 22, n° 3, p. 941–950, 2018. ISSN: 1976-3808, DOI: 10.1007/s12205-018-1337-3.

GANGSAR, P.; TIWARI, R. **Comparative investigation of vibration and current monitoring for prediction of mechanical and electrical faults in induction motor based on multiclass-support vector machine algorithms.** *Mechanical Systems and Signal Processing*, [s.l.], v. 94, p. 464–481, 2017. ISSN: 0888-3270, DOI: 10.1016/j.ymsp.2017.03.016.

GAYDECKI, P. **Foundations of Digital Signal Processing: Theory, algorithms and hardware design**. 1^a ed. [s.l.]: The Institution of Engineering and Technology - IET, 2004. 484 p. ISBN: 978-0-85296-431-6.

GLOWACZ, A. **Acoustic based fault diagnosis of three-phase induction motor**. *Applied Acoustics*, [s.l.], v. 137, p. 82–89, 2018. ISSN: 0003-682X, DOI: 10.1016/j.apacoust.2018.03.010.

_____. **Early fault diagnosis of bearing and stator faults of the single-phase induction motor using acoustic signals**. *Measurement*, [s.l.], v. 113, p. 1–9, 2018. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2017.08.036.

GNACIŃSKI, P. et al. **The effects of voltage subharmonics on cage induction machine**. *International Journal of Electrical Power & Energy Systems*, [s.l.], v. 111, p. 125–131, 2019. ISSN: 0142-0615, DOI: 10.1016/j.ijepes.2019.04.009.

GOHARI, M.; EYDI, A. M. **Modelling of shaft unbalance: Modelling a multi discs rotor using K-Nearest Neighbor and Decision Tree Algorithms**. *Measurement*, [s.l.], v. 151, p. 107253, 2020. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2019.107253.

GONG, T. et al. **Non-stationary feature extraction by the stochastic response of coupled oscillators and its application in bearing fault diagnosis under variable speed condition**. *Nonlinear Dynamics*, [s.l.], v. 108, n^o 4, p. 3839–3857, 2022. ISSN: 1573-269X, DOI: 10.1007/s11071-022-07373-y.

GONZALEZ-CORDOBA, J. L. et al. **Correlation Model Between Voltage Unbalance and Mechanical Overload Based on Thermal Effect at the Induction Motor Stator**. *IEEE Transactions on Energy Conversion*, [s.l.], v. 32, n^o 4, p. 1602–1610, 2017. ISSN: 1558-0059, DOI: 10.1109/TEC.2017.2706194.

GUEDES, J. J. **Identificação de falhas em motores de indução trifásicos utilizando algoritmos de otimização e sistemas inteligentes**. 144 p. - Universidade Tecnológica Federal do Paraná (UTFPR), 2019.

HAHS-VAUGHN, D. L.; LOMAX, R. G. **Statistical Concepts - A First Course**. 1^a ed. [s.l.]: Routledge; Taylor & Francis Group, 2020. 440 p. ISBN: 978-0-367-20396-2.

HANSFORD SENSORS. **HS-100S Accelerometer**. [s.l.], 2020.

HASAN, M. J.; ISLAM, M. M. M.; KIM, J.-M. **Acoustic spectral imaging and transfer learning for reliable bearing fault diagnosis under variable speed conditions**. *Measurement*, [s.l.], v. 138, p. 620–631, 2019. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2019.02.075.

HASSAN, O. E. et al. **Induction motor broken rotor bar fault detection techniques based on fault signature analysis – a review**. *IET Electric Power Applications*, [s.l.], v. 12, n^o 7, p. 895–907, 2018. ISSN: 1751-8679, DOI: <https://doi.org/10.1049/iet-epa.2018.0054>.

HAYKIN, S.; MOHER, M. **Introduction to Analog and Digital Communications**. 2^a ed. [s.l.]: John Wiley & Sons, Inc., 2007. 544 p. ISBN: 978-0-471-43222-7.

HAYKIN, S.; VEEN, B. V. **Sinais e Sistemas**. 1^a ed. [s.l.]: Bookman, 2001. 668 p. ISBN: 978-85-7307-741-4.

HONEYWELL. **Model 1602 - Low Capacity Torque Sensor**. [s.l.], 2014.

HOSEINZADEH, M. S.; KHADEM, S. E.; SADOOGHI, M. S. **Modifying the Hilbert-Huang transform using the nonlinear entropy-based features for early fault detection of ball bearings**. *Applied Acoustics*, [s.l.], v. 150, p. 313–324, 2019. ISSN: 0003-682X, DOI: 10.1016/j.apacoust.2019.02.011.

HUANG, N. E.; ATTOH-OKINE, N. O. **The Hilbert-Huang Transform in Engineering**. 1^a ed. [s.l.]: CRC Press, Taylor & Francis Group, LLC, 2005. 305 p. ISBN: 978-0-8493-3422-1.

HUANG, N. E.; SHEN, S. S. P. **Interdisciplinary Mathematical Sciences: Hilbert–Huang Transform and Its Applications**. 2^a ed. [s.l.]: World Scientific Publishing, 2014. v. 16, 386 p. ISBN: 978-981-4508-23-0.

HWANG, M.-H.; LEE, H.-S.; CHA, H.-R. **Analysis of Torque Ripple and Cogging Torque Reduction in Electric Vehicle Traction Platform Applying Rotor Notched Design**. *Energies*, [s.l.], v. 11, n^o 11, p. 3053, 2018. ISSN: 1996-1073, DOI: 10.3390/en11113053.

IBRAHIM, M. E.; ABD-ELHADY, A. M. **A Proposed Non-Invasive Rogowski Coil Design for Measuring 3-Phase Currents Through a 3-Core Cable**. *IEEE Sensors Journal*, [s.l.], v. 21, n^o 1, p. 593–599, 2021. ISSN: 1558-1748, DOI: 10.1109/JSEN.2020.3012839.

IDIL FIBRE OPTIQUES. **Fiber Bragg Gratings (FBG)**. [s.l.], 2021.

IEEE STD 519-2014. **IEEE Recommended Practice and Requirements for Harmonic Control in Electric Power Systems**. *IEEE Std 519-2014 (Revision of IEEE Std 519-1992)*, [s.l.], p. 1–29, 2014. DOI: 10.1109/IEEESTD.2014.6826459.

IMORU, O. et al. **Diagnosis of stator shorted-turn faults in induction machines using discrete wavelet transform**. *African Journal of Science, Technology, Innovation and Development*, [s.l.], v. 9, n^o 3, p. 349–355, 2017. ISSN: 2042-1338, DOI: 10.1080/20421338.2017.1327933.

IRFAN, M. **Modeling of Fault Frequencies for Distributed Damages in Bearing Raceways**. *Journal of Nondestructive Evaluation*, [s.l.], v. 38, n^o 4, p. 98, 2019. ISSN: 1573-4862, DOI: 10.1007/s10921-019-0635-0.

JADHAV, P. M. et al. **Distributed fault diagnosis of rotor-bearing system using dimensional analysis and experimental methods**. *Measurement*, [s.l.], v. 166, p. 108239, 2020. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2020.108239.

JATHURSAJAN, K.; WIJETHUNGE, A. **Diagnosing Localized and Distributed Bearing Faults by Bearing Noise Signal Using Machine Learning and Kurstogram**. *Advances in Technology*, [s.l.], p. 139–150, 2022. ISSN: 2773-7098, DOI: 10.31357/ait.v2i2.5475.

JOUANNE, A. VON; BANERJEE, B. **Assessment of voltage unbalance**. *IEEE Transactions on Power Delivery*, [s.l.], v. 16, n^o 4, p. 782–790, 2001. ISSN: 1937-4208, DOI: 10.1109/61.956770.

KAK, S. C. **The discrete Hilbert transform**. *Proceedings of the IEEE*, [s.l.], v. 58, n^o 4, p. 585–586, 1970. ISSN: 1558-2256, DOI: 10.1109/PROC.1970.7696.

KARIMI-GHARTEMA, M. **Synchronous Reference Frame PLL. Enhanced Phase-Locked Loop Structures for Power and Energy Applications.** [s.l.]: IEEE, 2014. p. 133–145. ISBN: 978-1-118-79516-3, DOI: 10.1002/9781118795187.ch6.

KARMAKAR, S. et al. **Induction Motor Fault Diagnosis: Approach through Current Signature Analysis.** 1^a ed. [s.l.]: Springer Science, Business Media Singapore, 2016. 161 p. ISBN: 978-981-10-0624-1.

KASIM, N. A.; MOHAMED, M. G.; NUAWI, M. Z. **Non-Stationary Vibratory Signatures Bearing Fault Detection Using Alternative Novel Kurtosis-based Statistical Analysis.** *Journal of Applied Science & Process Engineering*, [s.l.], v. 9, p. 1139–1148, 2022. ISSN: 2289-7771, DOI: 10.33736/jaspe.4594.2022.

KHOUALDIA, T.; LAKEHAL, A.; CHELLI, Z. **Practical Investigation on Bearing Fault Diagnosis Using Massive Vibration Data and Artificial Neural Network.** FARHAOUI, Y. (Org.). Em: *Big Data and Networks Technologies*. Cham: Springer International Publishing, 2020. ISBN: 978-3-030-23672-4, DOI: 10.1007/978-3-030-23672-4_9.

KIA, S. H.; HENAO, H.; CAPOLINO, Gé.-A. **Torsional Vibration Effects on Induction Machine Current and Torque Signatures in Gearbox-Based Electromechanical System.** *IEEE Transactions on Industrial Electronics*, [s.l.], v. 56, n^o 11, p. 4689–4699, 2009. ISSN: 1557-9948, DOI: 10.1109/TIE.2009.2026772.

KIM, K. **Conceptual Digital Signal Processing with MATLAB.** 1^a ed. [s.l.]: Springer Singapore, 2021. 667 p. ISBN: 978-981-15-2584-1.

KOMPELLA, K. C. D.; GOPALA RAO, M. V.; 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*, [s.l.], v. 9, n^o 4, p. 2427–2439, 2018. ISSN: 2090-4479, DOI: 10.1016/j.asej.2017.06.002.

KOURETAS, I.; PALIOURAS, V. **Hardware Implementation of a Softmax-Like Function for Deep Learning.** *Technologies*, [s.l.], v. 8, n^o 3, p. 46, 2020. DOI: 10.3390/technologies8030046.

KUDELINA, K. et al. **Induction Motor Bearing Currents - Causes and Damages.** Em: *2021 28th International Workshop on Electric Drives: Improving Reliability of Electric Drives (IWED)*. [s.l.]: [s.n.], 2021. DOI: 10.1109/IWED52055.2021.9376354.

KUMAR N., P.; VINOTHRAJ C.; ISHA T. B. **Effect of Wear and Tear Bearing Fault in Induction Motor Drives Using FEM.** Em: *2018 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*. [s.l.]: [s.n.], 2018. DOI: 10.1109/PEDES.2018.8707615.

KUMAR, P.; HATI, A. S. **Review on Machine Learning Algorithm Based Fault Detection in Induction Motors.** *Archives of Computational Methods in Engineering*, [s.l.], v. 28, n^o 3, p. 1929–1940, 2021. ISSN: 1886-1784, DOI: 10.1007/s11831-020-09446-w.

KUMAR, P. S. et al. **Stator End-Winding Thermal and Magnetic Sensor Arrays for Online Stator Inter-Turn Fault Detection.** *IEEE Sensors Journal*, [s.l.], v. 21, n^o 4, p. 5312–5321, 2021. ISSN: 1558-1748, DOI: 10.1109/JSEN.2020.3029041.

LAMIM FILHO, P. C. M.; PEDERIVA, R.; BRITO, J. N. **Detection of stator winding faults in induction machines using flux and vibration analysis.** *Mechanical Systems and Signal*

Processing, [s.l.], v. 42, n° 1, p. 377–387, 2014. ISSN: 0888-3270, DOI: 10.1016/j.ymsp.2013.08.033.

LATHI, B. P. **Sinais e Sistemas Lineares**. 2^a ed. [s.l.]: Bookman, 2006. 856 p. ISBN: 978-85-60031-13-9.

LEI, Y. et al. **Applications of machine learning to machine fault diagnosis: A review and roadmap**. *Mechanical Systems and Signal Processing*, [s.l.], v. 138, p. 106587, 2020. ISSN: 0888-3270, DOI: 10.1016/j.ymsp.2019.106587.

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*, [s.l.], v. 62, n° 3, p. 1855–1865, 2015. ISSN: 1557-9948, DOI: 10.1109/TIE.2014.2345330.

LEM. **Current Transducer HTA 100...1000-S**. [s.l.], 2017.

_____. **ART-B22-D125/SP25**. [s.l.], 2020.

LI, H. et al. **Extended Wide-Bandwidth Rogowski Current Sensor With PCB Coil and Electronic Characteristic Shaper**. *IEEE Transactions on Power Electronics*, [s.l.], v. 36, n° 1, p. 29–33, 2021. ISSN: 1941-0107, DOI: 10.1109/TPEL.2020.3001058.

LI, J. et al. **A Current Signal-Based Adaptive Semisupervised Framework for Bearing Faults Diagnosis in Drivetrains**. *IEEE Transactions on Instrumentation and Measurement*, [s.l.], v. 70, p. 1–12, 2021. ISSN: 1557-9662, DOI: 10.1109/TIM.2020.3046051.

LI, Z. et al. **An improved digital integral algorithm to enhance the measurement accuracy of Rogowski coil-based electronic transformers**. *International Journal of Electrical Power & Energy Systems*, [s.l.], v. 118, p. 105806, 2020. ISSN: 0142-0615, DOI: 10.1016/j.ijepes.2019.105806.

LIANG, H. et al. **Fault Detection of Stator Inter-Turn Short-Circuit in PMSM on Stator Current and Vibration Signal**. *Applied Sciences*, [s.l.], v. 8, n° 9, p. 1677, 2018. DOI: 10.3390/app8091677.

LIKAS, A.; VLASSIS, N.; J. VERBEEK, J. **The global k-means clustering algorithm**. *Pattern Recognition*, [s.l.], v. 36, n° 2, p. 451–461, 2003. ISSN: 0031-3203, DOI: 10.1016/S0031-3203(02)00060-2.

LIN, C.-L.; MEEHAN, P. A. **Morphological and elemental analysis of wear debris naturally formed in grease lubricated railway axle bearings**. *Wear*, [s.l.], v. 484–485, p. 203994, 2021. ISSN: 0043-1648, DOI: 10.1016/j.wear.2021.203994.

LIN, J.-L. et al. **Motor shaft misalignment detection using multiscale entropy with wavelet denoising**. *Expert Systems with Applications*, [s.l.], v. 37, n° 10, p. 7200–7204, 2010. ISSN: 0957-4174, DOI: 10.1016/j.eswa.2010.04.009.

LIU, Q.; WANG, Y.; XU, Y. **Synchrosqueezing extracting transform and its application in bearing fault diagnosis under non-stationary conditions**. *Measurement*, [s.l.], v. 173, p. 108569, 2021. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2020.108569.

LIU, R. et al. **Artificial intelligence for fault diagnosis of rotating machinery: A review.** *Mechanical Systems and Signal Processing*, [s.l.], v. 108, p. 33–47, 2018. ISSN: 0888-3270, DOI: 10.1016/j.ymsp.2018.02.016.

LIU, X. et al. **Inter-Turn Short-Circuit Fault Detection Approach for Permanent Magnet Synchronous Machines Through Stray Magnetic Field Sensing.** *IEEE Sensors Journal*, [s.l.], v. 19, n° 18, p. 7884–7895, 2019. ISSN: 1558-1748, DOI: 10.1109/JSEN.2019.2918018.

LIU, Y. et al. **Surface wear evolution of traction motor bearings in vibration environment of a locomotive during operation.** *Science China Technological Sciences*, [s.l.], 2022. ISSN: 1869-1900, DOI: 10.1007/s11431-021-1939-3.

LIU, Z.; ZHANG, L. **A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings.** *Measurement*, [s.l.], v. 149, p. 107002, 2020. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2019.107002.

LUCAS, G. B. et al. **A New Acoustic Emission-Based Approach for Supply Disturbances Evaluation in Three-Phase Induction Motors.** *IEEE Transactions on Instrumentation and Measurement*, [s.l.], v. 70, p. 1–10, 2021. ISSN: 1557-9662, DOI: 10.1109/TIM.2020.3047492.

LUCAS, Guilherme Beraldi et al. **Three-phase induction motor loading estimation based on Wavelet Transform and low-cost piezoelectric sensors.** *Measurement*, [s.l.], v. 164, p. 107956, 2020. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2020.107956.

_____. **Uma nova técnica para monitoramento e diagnóstico de desequilíbrios de tensão aplicada em motores de indução trifásicos empregando sensores de emissão acústica e Transformada Wavelet.** 130 p. - Universidade Estadual Paulista (UNESP), 2020.

LUO, G. et al. **Impulsive noise reduction for transient Earth voltage-based partial discharge using Wavelet-entropy.** *IET Science, Measurement & Technology*, [s.l.], v. 10, n° 1, p. 69–76, 2016. ISSN: 1751-8830, DOI: 10.1049/iet-smt.2014.0203.

MACHADO, F. C. et al. **Reduced Reference Frame Transform: Deconstructing Three-Phase Four-Wire Systems.** *IEEE Access*, [s.l.], v. 8, p. 143021–143032, 2020. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2020.3012510.

MACHADO, T. H.; ALVES, D. S.; CAVALCA, K. L. **Investigation about journal bearing wear effect on rotating system dynamic response in time domain.** *Tribology International*, [s.l.], v. 129, p. 124–136, 2019. ISSN: 0301-679X, DOI: 10.1016/j.triboint.2018.08.004.

MARIAPPAN, P. **Biostatistics: An Introduction.** 1^a ed. [s.l.]: Pearson Education, 2013. 464 p. ISBN: 978-93-325-1415-7.

MARTINEZ-HERRERA, A. L. et al. **Multiple Fault Detection in Induction Motors through Homogeneity and Kurtosis Computation.** *Energies*, [s.l.], v. 15, n° 4, p. 1541, 2022. ISSN: 1996-1073, DOI: 10.3390/en15041541.

MBO’O, C. P.; HAMEYER, K. **Fault Diagnosis of Bearing Damage by Means of the Linear Discriminant Analysis of Stator Current Features From the Frequency Selection.** *IEEE Transactions on Industry Applications*, [s.l.], v. 52, n° 5, p. 3861–3868, 2016. ISSN: 1939-9367, DOI: 10.1109/TIA.2016.2581139.

- MEJIA-BARRON, A. et al. **The application of EMD-based methods for diagnosis of winding faults in a transformer using transient and steady state currents.** *Measurement*, [s.l.], v. 117, p. 371–379, 2018. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2017.12.003.
- MITSUBISHI ELECTRIC. **Instrument Transformers.** [s.l.], 2018.
- MOHAMMED, A.; DJUROVIĆ, S. **Stator Winding Internal Thermal Monitoring and Analysis Using In Situ FBG Sensing Technology.** *IEEE Transactions on Energy Conversion*, [s.l.], v. 33, n° 3, p. 1508–1518, 2018. ISSN: 1558-0059, DOI: 10.1109/TEC.2018.2826229.
- MOHAMMED, A.; MELECIO, J. I.; DJUROVIĆ, S. **Stator Winding Fault Thermal Signature Monitoring and Analysis by In Situ FBG Sensors.** *IEEE Transactions on Industrial Electronics*, [s.l.], v. 66, n° 10, p. 8082–8092, 2019. ISSN: 1557-9948, DOI: 10.1109/TIE.2018.2883260.
- MONRO, D. M.; SHERLOCK, B. G. **Space-frequency balance in biorthogonal wavelets.** Em: *Proceedings of International Conference on Image Processing*. [s.l.]: [s.n.], 1997. DOI: 10.1109/ICIP.1997.647990.
- MOOSAVIAN, A. et al. **Support vector machine and K-nearest neighbour for unbalanced fault detection.** *Journal of Quality in Maintenance Engineering*, [s.l.], v. 20, n° 1, p. 65–75, 2014. ISSN: 1355-2511, DOI: 10.1108/JQME-04-2012-0016.
- MORETTIN, P. A.; BUSSAB, W. de O. **Estatística Básica.** 9ª ed. [s.l.]: Saraiva Uni, 2017. 568 p. ISBN: 978-85-472-2022-8.
- MUETZE, A.; BINDER, A. **Calculation of Circulating Bearing Currents in Machines of Inverter-Based Drive Systems.** *IEEE Transactions on Industrial Electronics*, [s.l.], v. 54, n° 2, p. 932–938, 2007. ISSN: 1557-9948, DOI: 10.1109/TIE.2007.892001.
- MULTICOMP PRO. **Piezo Element.** [s.l.], 2019.
- NAIDU, M. S.; KAMARAJU, V. **High-Voltage Engineering.** 5ª ed. [s.l.]: McGraw Hill Education, 2013. 498 p. ISBN: 978-1-259-06289-6.
- NAIR, R. P.; VISHWANATH, S. B. **Analysis of partial discharge sources in stator insulation system using variable excitation frequency.** *IET Science, Measurement & Technology*, [s.l.], v. 13, n° 6, p. 922–930, 2019. ISSN: 1751-8830, DOI: 10.1049/iet-smt.2018.5666.
- NANDI, S.; TOLIYAT, H. A. **Fault diagnosis of electrical machines-a review.** [s.l.]: [s.n.], 1999. DOI: 10.1109/IEMDC.1999.769076.
- NATH, S. et al. **Low Latency Bearing Fault Detection of Direct-Drive Wind Turbines Using Stator Current.** *IEEE Access*, [s.l.], v. 8, p. 44163–44174, 2020. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2020.2977632.
- NAYANA, B. R.; GEETHANJALI, P. **Analysis of Statistical Time-Domain Features Effectiveness in Identification of Bearing Faults From Vibration Signal.** *IEEE Sensors Journal*, [s.l.], v. 17, n° 17, p. 5618–5625, 2017. ISSN: 1558-1748, DOI: 10.1109/JSEN.2017.2727638.
- OJAGHI, M.; SABOURI, M.; FAIZ, J. **Analytic Model for Induction Motors Under Localized Bearing Faults.** *IEEE Transactions on Energy Conversion*, [s.l.], v. 33, n° 2, p. 617–626, 2018. ISSN: 1558-0059, DOI: 10.1109/TEC.2017.2758382.

OKWUOSA, C. N.; AKPUDO, U. E.; HUR, J.-W. **A Cost-Efficient MCSA-Based Fault Diagnostic Framework for SCIM at Low-Load Conditions.** *Algorithms*, [s.l.], v. 15, n° 6, p. 212, 2022. ISSN: 1999-4893, DOI: 10.3390/a15060212.

OMITAOMU, O. A. et al. **Online Support Vector Regression Approach for the Monitoring of Motor Shaft Misalignment and Feedwater Flow Rate.** *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, [s.l.], v. 37, n° 5, p. 962–970, 2007. ISSN: 1558-2442, DOI: 10.1109/TSMCC.2007.900648.

OPPENHEIM, A. V.; WILLSKY, Alan. S. **Sinais e Sistemas.** 2ª ed. [s.l.]: Pearson Prentice Hall, 2010. 592 p. ISBN: 978-85-7605-504-4.

OSGOOD, B. G. **Lectures on the Fourier Transform and Its Applications.** 1ª ed. 693: American Mathematical Society, 2019. ISBN: 978-1-4704-4191-3.

OUACHTOUK, I. et al. **Detection and classification of broken rotor bars faults in induction machine using K-means classifier.** [s.l.]: [s.n.], 2016. DOI: 10.1109/EITech.2016.7519586.

PANDARAKONE, S. E.; MIZUNO, Y.; NAKAMURA, H. **Distinct Fault Analysis of Induction Motor Bearing Using Frequency Spectrum Determination and Support Vector Machine.** *IEEE Transactions on Industry Applications*, [s.l.], v. 53, n° 3, p. 3049–3056, 2017. ISSN: 1939-9367, DOI: 10.1109/TIA.2016.2639453.

PAPATHANASOPOULOS, D. A. et al. **Vibration Monitoring for Position Sensor Fault Diagnosis in Brushless DC Motor Drives.** *Energies*, [s.l.], v. 14, n° 8, p. 2248, 2021. DOI: 10.3390/en14082248.

PARK, R. H. **Two-reaction theory of synchronous machines generalized method of analysis-part I.** *Transactions of the American Institute of Electrical Engineers*, [s.l.], v. 48, n° 3, p. 716–727, 1929. ISSN: 2330-9431, DOI: 10.1109/T-AIEE.1929.5055275.

PARK, S.-H. et al. **Suppression of Torque Ripple Caused by Misalignment of the Gearbox by Using Harmonic Current Injection Method.** *IEEE/ASME Transactions on Mechatronics*, [s.l.], v. 25, n° 4, p. 1990–1999, 2020. ISSN: 1941-014X, DOI: 10.1109/TMECH.2020.2999379.

PATHAK, R. S. **The Wavelt Transform.** 1ª ed. [s.l.]: Atlantis Press, 2009. v. 4, 178 p. ISBN: 978-90-78677-26-0.

PELEGRIN, J. et al. **Optical Fiber Sensor Encapsulated in Carbon Fiber Reinforced Polymer for Fault Detection in Rotating Electrical Machines.** *IEEE Sensors Journal*, [s.l.], v. 20, n° 19, p. 11364–11371, 2020. ISSN: 1558-1748, DOI: 10.1109/JSEN.2020.2997597.

PENG, Z. K.; TSE, P. W.; CHU, F. L. **An improved Hilbert–Huang transform and its application in vibration signal analysis.** *Journal of Sound and Vibration*, [s.l.], v. 286, n° 1, p. 187–205, 2005. ISSN: 0022-460X, DOI: 10.1016/j.jsv.2004.10.005.

PHELAN, C. E. et al. **Hilbert transform, spectral filters and option pricing.** *Annals of Operations Research*, [s.l.], v. 282, n° 1, p. 273–298, 2019. ISSN: 1572-9338, DOI: 10.1007/s10479-018-2881-4.

PIETROWSKI, W. **Detection of time-varying inter-turn short-circuit in a squirrel cage induction machine by means of generalized regression neural network.** *COMPEL - The*

international journal for computation and mathematics in electrical and electronic engineering, [s.l.], v. 36, n° 1, p. 289–297, 2017. ISSN: 0332-1649, DOI: 10.1108/COMPEL-03-2016-0121.

PLAZENET, T. et al. **A Comprehensive Study on Shaft Voltages and Bearing Currents in Rotating Machines**. *IEEE Transactions on Industry Applications*, [s.l.], v. 54, n° 4, p. 3749–3759, 2018. ISSN: 1939-9367, DOI: 10.1109/TIA.2018.2818663.

POPESCU, T. D.; AIORDACHIOAIE, D.; CULEA-FLORESCU, A. **Basic tools for vibration analysis with applications to predictive maintenance of rotating machines: an overview**. *The International Journal of Advanced Manufacturing Technology*, [s.l.], v. 118, n° 9, p. 2883–2899, 2022. ISSN: 1433-3015, DOI: 10.1007/s00170-021-07703-1.

POPOVIC, R. S. **Hall Effect Devices**. 2^a ed. [s.l.]: IOP Publishing, 2004. 420 p. ISBN: 978-0-7503-0855-7.

PROAKIS, J. G.; MANOLAKIS, D. K. **Digital Signal Processing**. 4^a ed. [s.l.]: Pearson Education Limited, 2014. 1014 p. ISBN: 978-1-292-02573-5.

RAHMAN, Md. M.; UDDIN, M. N. **Online unbalanced rotor fault detection of an IM drive based on both time and frequency domain analyses**. [s.l.]: [s.n.], 2015. DOI: 10.1109/IAS.2015.7356825.

RAMSDEN, E. **Hall-Effect Sensors: Theory and Applications**. 2^a ed. [s.l.]: Newnes & Elsevier, 2006. 272 p. ISBN: 978-0-7506-7934-3.

RANGANATHAN, S. et al. **Encyclopedia of Bioinformatics and Computational Biology**. 1^a ed. [s.l.]: Elsevier Inc., 2019. v. 1, 3284 p. ISBN: 978-0-12-811414-8.

RANJAN, R.; GHOSH, S. K.; KUMAR, M. **Fault diagnosis of journal bearing in a hydro-power plant using wear debris, vibration and temperature analysis: A case study**. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, [s.l.], v. 234, n° 3, p. 235–242, 2020. ISSN: 0954-4089, DOI: 10.1177/0954408920910290.

RASHID, M. H. **Power Electronics Handbook**. 4^a ed. [s.l.]: Butterworth-Heinemann, 2018. 1496 p. ISBN: 978-0-12-811407-0.

RIPKA, P.; ARAFAT, M. M. **Magnetic Sensors: Principles and Applications**. *Reference Module in Materials Science and Materials Engineering*. [s.l.]: Elsevier, 2019. ISBN: 978-0-12-803581-8, DOI: 10.1016/B978-0-12-803581-8.11680-7.

SAAD, N.; IRFAN, M.; IBRAHIM, R. **Condition monitoring and faults diagnosis of induction motors : electrical signature analysis**. 1^a ed. [s.l.]: CRC Press, Taylor & Francis Group, 2018. 150 p. ISBN: 978-0-8153-8995-8.

SABBAGHIAN-BIDGOLI, F.; POSHTAN, J. **Fault Detection of Broken Rotor Bar Using an Improved form of Hilbert–Huang Transform**. *Fluctuation and Noise Letters*, [s.l.], v. 17, n° 02, p. 1850012, 2018. ISSN: 0219-4775, DOI: 10.1142/S0219477518500128.

SADDAM, B. et al. **Detection of rotor faults based on Hilbert Transform and neural network for an induction machine**. [s.l.]: [s.n.], 2017. DOI: 10.1109/ICEE-B.2017.8192029.

- SADEGHI, R.; SAMET, H.; GHANBARI, T. **Detection of Stator Short-Circuit Faults in Induction Motors Using the Concept of Instantaneous Frequency.** *IEEE Transactions on Industrial Informatics*, [s.l.], v. 15, n^o 8, p. 4506–4515, 2019. ISSN: 1941-0050, DOI: 10.1109/TII.2018.2881921.
- SADOON, T. A.; ALI, M. H. **Deep learning model for glioma, meningioma and pituitary classification.** *International Journal of Advances in Applied Sciences*, [s.l.], v. 10, n^o 1, p. 88, 2021. ISSN: 2722-2594, 2252-8814, DOI: 10.11591/ijaas.v10.i1.pp88-98.
- SAIDI, L. et al. **Wind turbine high-speed shaft bearings health prognosis through a spectral Kurtosis-derived indices and SVR.** *Applied Acoustics*, [s.l.], v. 120, p. 1–8, 2017. ISSN: 0003-682X, DOI: 10.1016/j.apacoust.2017.01.005.
- SAINI, M. K.; AGGARWAL, A. **Detection and diagnosis of induction motor bearing faults using multiwavelet transform and naive Bayes classifier.** *International Transactions on Electrical Energy Systems*, [s.l.], v. 28, n^o 8, p. e2577, 2018. ISSN: 2050-7038, DOI: 10.1002/etep.2577.
- SALIH, S. M. **Fourier Transform – Signal Processing.** 1^a ed. [s.l.]: InTech, 2012. 354 p. ISBN: 978-953-51-0453-7.
- SAMANI, A. **An Introduction to Signal Processing for Non-Engineers.** 1^a ed. [s.l.]: CRC Press, Taylor & Francis Group, 2020. 99 p. ISBN: 978-0-367-20755-7.
- SANTHOSHI, M. S. et al. **An Investigation on Rolling Element Bearing Fault and Real-Time Spectrum Analysis by Using Short-Time Fourier Transform.** GUNJAN, V. K.; ZURADA, J. M. (Orgs.). Em: *Proceedings of International Conference on Recent Trends in Machine Learning, IoT, Smart Cities and Applications*. Singapore: Springer, 2021. ISBN: 9789811572340, DOI: 10.1007/978-981-15-7234-0_52.
- SANTOS, V. V. Dos et al. **An Application of Wavelet Analysis to Assess Partial Discharge Evolution by Acoustic Emission Sensor.** *Engineering Proceedings*, [s.l.], v. 2, n^o 1, p. 33, 2020. DOI: 10.3390/ecsa-7-08244.
- SAPENA-BANO, A. et al. **Induction machine model with space harmonics for fault diagnosis based on the convolution theorem.** *International Journal of Electrical Power & Energy Systems*, [s.l.], v. 100, p. 463–481, 2018. ISSN: 0142-0615, DOI: 10.1016/j.ijepes.2018.03.001.
- SCHUBERT, B.; PALO, M.; SCHLECHTER, T. **Review of UHF-Based Signal Processing Approaches for Partial Discharge Detection.** MORENO-DÍAZ, R.; PICHLER, F.; QUESADA-ARENCIBIA, A. (Orgs.). Cham: Springer International Publishing, 2018. ISBN: 978-3-319-74727-9, DOI: 10.1007/978-3-319-74727-9_26.
- SCHWENDEMANN, S.; AMJAD, Z.; SIKORA, A. **A survey of machine-learning techniques for condition monitoring and predictive maintenance of bearings in grinding machines.** *Computers in Industry*, [s.l.], v. 125, p. 103380, 2021. ISSN: 0166-3615, DOI: 10.1016/j.compind.2020.103380.
- SEROV, V. **Fourier Series, Fourier Transform and Their Applications to Mathematical Physics.** 1^a ed. [s.l.]: Springer, 2017. 534 p. ISBN: 978-3-319-65262-7.
- SHAO, Y.; KANG, R.; LIU, J. **Rolling Bearing Fault Diagnosis Based on the Coherent Demodulation Model.** *IEEE Access*, [s.l.], v. 8, p. 207659–207671, 2020. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2020.3038767.

- SHIFAT, T. A.; HUR, J.-W. **ANN Assisted Multi Sensor Information Fusion for BLDC Motor Fault Diagnosis**. *IEEE Access*, [s.l.], v. 9, p. 9429–9441, 2021. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2021.3050243.
- SHINKAWA. **Piezoelectric Acceleration / Velocity Transducers - CA/CV Series**. [s.l.], 2015.
- SIMEONE, O. **A Brief Introduction to Machine Learning for Engineers**. *Foundations and Trends® in Signal Processing*, [s.l.], v. 12, n° 3–4, p. 200–431, 2018. ISSN: 1932-8346, 1932-8354, DOI: 10.1561/2000000102.
- SINGH, S.; KUMAR, N. **Detection of Bearing Faults in Mechanical Systems Using Stator Current Monitoring**. *IEEE Transactions on Industrial Informatics*, [s.l.], v. 13, n° 3, p. 1341–1349, 2017. ISSN: 1941-0050, DOI: 10.1109/TII.2016.2641470.
- SINGH, Sukhjeet; KUMAR, A.; KUMAR, N. **Motor Current Signature Analysis for Bearing Fault Detection in Mechanical Systems**. *Procedia Materials Science*, [s.l.], v. 6, p. 171–177, 2014. ISSN: 2211-8128, DOI: 10.1016/j.mspro.2014.07.021.
- SINHA, A. K. et al. **ANN Based Fault Detection Scheme for Bearing Condition Monitoring in SRIMs using FFT, DWT and Band-pass Filters**. [s.l.]: [s.n.], 2020. DOI: 10.1109/PICC51425.2020.9362486.
- SOARES, L. R. **Projeto de Novos Sistemas-Wavelt com Aplicações na Análise de Sinais do Sistema Elétrico**. 223 p. - Universidade Federal de Pernambuco, 2006.
- SOUALHI, M. et al. **Health monitoring of bearing and gear faults by using a new health indicator extracted from current signals**. *Measurement*, [s.l.], v. 141, p. 37–51, 2019. ISSN: 0263-2241, DOI: 10.1016/j.measurement.2019.03.065.
- STAROSIELEC, S.; HÄGELE, D. **Discrete-time windows with minimal RMS bandwidth for given RMS temporal width**. *Signal Processing*, [s.l.], v. 102, p. 240–246, 2014. ISSN: 0165-1684, DOI: 10.1016/j.sigpro.2014.03.033.
- STONE, G. C.; SEDDING, H. G.; CHAN, C. **Experience With Online Partial-Discharge Measurement in High-Voltage Inverter-Fed Motors**. *IEEE Transactions on Industry Applications*, [s.l.], v. 54, n° 1, p. 866–872, 2018. ISSN: 1939-9367, DOI: 10.1109/TIA.2017.2740280.
- SUNDARARAJAN, D. **Discrete Wavelet Transform: A Signal Processing Approach**. 1^a ed. [s.l.]: Wiley & Sons, 2016. 344 p. ISBN: 978-1-119-04606-6.
- TAHIR, M.; TENBHOLEN, S.; MIYAZAKI, S. **Analysis of Statistical Methods for Assessment of Power Transformer Frequency Response Measurements**. *IEEE Transactions on Power Delivery*, [s.l.], v. 36, n° 2, p. 618–626, 2021. ISSN: 1937-4208, DOI: 10.1109/TPWRD.2020.2987205.
- TAHKOLA, M. et al. **A Novel Machine Learning-Based Approach for Induction Machine Fault Classifier Development—A Broken Rotor Bar Case Study**. *Energies*, [s.l.], v. 15, n° 9, p. 3317, 2022. ISSN: 1996-1073, DOI: 10.3390/en15093317.

TALHAOUI, H. et al. **Experimental diagnosis of broken rotor bars fault in induction machine based on Hilbert and discrete wavelet transforms.** *The International Journal of Advanced Manufacturing Technology*, [s.l.], v. 95, n° 1, p. 1399–1408, 2018. ISSN: 1433-3015, DOI: 10.1007/s00170-017-1309-7.

TAN, Q. et al. **Design of Open-Ended Structure Wideband PCB Rogowski Coil Based on New Winding Method.** *Electronics*, [s.l.], v. 11, n° 3, p. 381, 2022. ISSN: 2079-9292, DOI: 10.3390/electronics11030381.

TANG, H.; DAI, H.-L.; DU, Y. **Bearing Fault Detection for Doubly fed Induction Generator Based on Stator Current.** *IEEE Transactions on Industrial Electronics*, [s.l.], v. 69, n° 5, p. 5267–5276, 2022. ISSN: 1557-9948, DOI: 10.1109/TIE.2021.3080216.

TAO, S. et al. **Bearing fault diagnosis method based on stacked autoencoder and softmax regression.** [s.l.]: [s.n.], 2015. ISSN: 1934-1768, DOI: 10.1109/ChiCC.2015.7260634.

TEXAS INSTRUMENTS. **DRV5053 Analog-Bipolar Hall Effect Sensor.** [s.l.], 2015.

THOMSON, W. T.; CULBERT, I. **Current Signature Analysis for Condition Monitoring of Cage Induction Motors: Industrial Application and Case Histories.** 1^a ed. [s.l.]: Wiley - IEEE Press, 2017. 440 p. ISBN: 978-1-119-02959-5.

THYAGARAJAN, K. S. **Introduction to Digital Signal Processing Using MATLAB with Application to Digital Communications.** 1^a ed. [s.l.]: Springer International Publishing, 2019. 505 p. ISBN: 978-3-319-76028-5.

TINGARIKAR, G.; CHOUDHURY, A. **Vibration Analysis-Based Fault Diagnosis of a Dynamically Loaded Bearing with Distributed Defect.** *Arabian Journal for Science and Engineering*, [s.l.], 2021. ISSN: 2191-4281, DOI: 10.1007/s13369-021-05862-7.

TOLIYAT, H. A. et al. **Electric Machines: modeling, condition monitoring and fault diagnosis.** 1^a ed. [s.l.]: CRC Press, Taylor & Francis Group, LLC, 2013. 252 p. ISBN: 978-1-4200-0628-5.

TOMA, R. N.; PROSVIRIN, A. E.; KIM, J.-M. **Bearing Fault Diagnosis of Induction Motors Using a Genetic Algorithm and Machine Learning Classifiers.** *Sensors (Basel, Switzerland)*, [s.l.], v. 20, n° 7, p. 1884, 2020. ISSN: 1424-8220, DOI: 10.3390/s20071884.

TRACHI, Y. et al. **Induction Machines Fault Detection Based on Subspace Spectral Estimation.** *IEEE Transactions on Industrial Electronics*, [s.l.], v. 63, n° 9, p. 5641–5651, 2016. ISSN: 1557-9948, DOI: 10.1109/TIE.2016.2570741.

TRIGEASSOU, J.-C. **Electrical Machines Diagnosis.** 1^a ed. [s.l.]: John Wiley & Sons e ISTE, 2011. 334 p. ISBN: 978-1-84821-263-3.

TT ELECTRONICS. **SX-4428 - Compact Magnetorque Non-Contacting Steering Torque Sensor.** [s.l.], 2019.

UPADHYAY, R. K.; KUMARASWAMIDHAS, L. A. **Chapter 11 - Bearing failure issues and corrective measures through surface engineering.** Em: MAKHLOUF, A. S. H.; ALIOFKHAZRAEI, M. (Orgs.). *Handbook of Materials Failure Analysis.* [s.l.]: Butterworth-Heinemann, 2018. p. 209–233. ISBN: 978-0-08-101928-3, DOI: 10.1016/B978-0-08-101928-3.00011-2.

VAIMANN, T. et al. **Induction machine fault detection using smartphone recorded audible noise.** *IET Science, Measurement & Technology*, [s.l.], v. 12, n° 4, p. 554–560, 2018. ISSN: 1751-8830, DOI: 10.1049/iet-smt.2017.0104.

VASIĆ, M.; STOJANOVIĆ, B.; BLAGOJEVIĆ, M. **Failure analysis of idler roller bearings in belt conveyors.** *Engineering Failure Analysis*, [s.l.], v. 117, p. 104898, 2020. ISSN: 1350-6307, DOI: 10.1016/j.engfailanal.2020.104898.

VERMA, A. K. et al. **An efficient neural-network model for real-time fault detection in industrial machine.** *Neural Computing and Applications*, [s.l.], v. 33, n° 4, p. 1297–1310, 2021. ISSN: 0941-0643, 1433-3058, DOI: 10.1007/s00521-020-05033-z.

VERMA, A. K.; RADHIKA, S.; PADMANABHAN, S. V. **Wavelet Based Fault Detection and Diagnosis Using Online MCSA of Stator Winding Faults Due to Insulation Failure in Industrial Induction Machine.** [s.l.]: [s.n.], 2018. DOI: 10.1109/RAICS.2018.8635058.

VERUCCHI, C. J. et al. **Efficiency Assessment of Induction Motors Drives Operating Under Shaft Misalignment Conditions.** *Advances in Electrical and Electronic Engineering*, [s.l.], v. 18, n° 3, p. 142–152, 2020. ISSN: 1804-3119, DOI: 10.15598/aeec.v18i3.3596.

WANG, Y. et al. **Double Fed Induction Generator Shaft Misalignment Monitoring by FBG Frame Strain Sensing.** *IEEE Sensors Journal*, [s.l.], v. 20, n° 15, p. 8541–8551, 2020. ISSN: 1558-1748, DOI: 10.1109/JSEN.2020.2984309.

WANG, Z. et al. **Fault Diagnosis of a Rolling Bearing Using Wavelet Packet Denoising and Random Forests.** *IEEE Sensors Journal*, [s.l.], v. 17, n° 17, p. 5581–5588, 2017. ISSN: 1558-1748, DOI: 10.1109/JSEN.2017.2726011.

WEG. **W22 IR3 4 CV 4P L100L 3F 220/380/440 V 60 Hz.** WEG. 2020. Disponível em: <<https://www.weg.net/catalog/weg/BR/pt/Motores-El%C3%A9tricos/Trif%C3%A1sico---Baixa-Tens%C3%A3o/Usos-Gerais/W22/W22-/W22-IR3-Premium-4-cv-4P-L100L-3F-220-380-440-V-60-Hz-IC411---TFVE---B3D/p/11713210>>. Acesso em: 27/set./20.

WEI, Y. et al. **A Review of Early Fault Diagnosis Approaches and Their Applications in Rotating Machinery.** *Entropy*, [s.l.], v. 21, n° 4, p. 409, 2019. DOI: 10.3390/e21040409.

WIELGOS, S.; DOLEZALEK, E.; MIN, C.-H. **Garment Integrated Spinal Posture Detection Using Wearable Magnetic Sensors.** [s.l.]: [s.n.], 2020. ISSN: 2694-0604, DOI: 10.1109/EMBC44109.2020.9175725.

WU, S. et al. **Prediction Consistency Guided Convolutional Neural Networks for Cross-Domain Bearing Fault Diagnosis.** *IEEE Access*, [s.l.], v. 8, p. 120089–120103, 2020. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2020.3005422.

XIAO, C. et al. **An overview of integratable current sensor technologies.** [s.l.]: [s.n.], 2003. DOI: 10.1109/IAS.2003.1257710.

YAN, R.; GAO, R. X. **Hilbert–Huang Transform-Based Vibration Signal Analysis for Machine Health Monitoring.** *IEEE Transactions on Instrumentation and Measurement*, [s.l.], v. 55, n° 6, p. 2320–2329, 2006. ISSN: 1557-9662, DOI: 10.1109/TIM.2006.887042.

YANG, D.-M. **The Detection of Motor Bearing Fault with Maximal Overlap Discrete Wavelet Packet Transform and Teager Energy Adaptive Spectral Kurtosis.** *Sensors (Basel, Switzerland)*, [s.l.], v. 21, n° 20, p. 6895, 2021. ISSN: 1424-8220, DOI: 10.3390/s21206895.

YANG, M.; SINAGA, K. P. **A Feature-Reduction Multi-View k-Means Clustering Algorithm.** *IEEE Access*, [s.l.], v. 7, p. 114472–114486, 2019. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2019.2934179.

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*, [s.l.], v. 65, n° 3, p. 549–558, 2016. ISSN: 1557-9662, DOI: 10.1109/TIM.2015.2498978.

ZANDI, O.; POSHTAN, J. **Fault Diagnosis of Brushless DC Motors Using Built-In Hall Sensors.** *IEEE Sensors Journal*, [s.l.], v. 19, n° 18, p. 8183–8190, 2019. ISSN: 1558-1748, DOI: 10.1109/JSEN.2019.2917847.

ZHANG, S. et al. **Model-Based Analysis and Quantification of Bearing Faults in Induction Machines.** *IEEE Transactions on Industry Applications*, [s.l.], v. 56, n° 3, p. 2158–2170, 2020. ISSN: 1939-9367, DOI: 10.1109/TIA.2020.2979383.

ZHANG, Y.-C.; SAKHANENKO, L. **The naive Bayes classifier for functional data.** *Statistics & Probability Letters*, [s.l.], v. 152, p. 137–146, 2019. ISSN: 0167-7152, DOI: 10.1016/j.spl.2019.04.017.

ZHAO, S.; WANG, E. **Fault Diagnosis of Circuit Breaker Energy Storage Mechanism Based on Current-Vibration Entropy Weight Characteristic and Grey Wolf Optimization–Support Vector Machine.** *IEEE Access*, [s.l.], v. 7, p. 86798–86809, 2019. ISSN: 2169-3536, DOI: 10.1109/ACCESS.2019.2924056.