



UNIVERSIDADE ESTADUAL PAULISTA  
"JÚLIO DE MESQUITA FILHO"



**GUILHERME BERARDI LUCAS**

**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**

**BAURU**

**2020**

**GUILHERME BERARDI LUCAS**

**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**

Dissertação apresentada ao programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Bauru - UNESP, para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. André Luiz Andreoli

Coorientador: Prof. Dr. Bruno Albuquerque de Castro

**BAURU**

**2020**

Lucas, Guilherme Beraldi

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/ Guilherme Beraldi Lucas, 2020

130 f. : il.

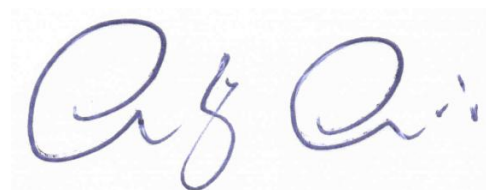
Orientador: Prof. Dr. André Luiz Andreoli

Dissertação (Mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Bauru, Bauru, 2020.

1. Tensão desequilibrada. 2. Transformada Wavelet. 3. Sensor Piezoelétrico. I. Universidade Estadual Paulista. Faculdade de Engenharia de Bauru. II. Título

**ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE GUILHERME BERARDI LUCAS, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.**

Aos 29 dias do mês de outubro do ano de 2020, às 14:00 horas, por meio de Videoconferência, realizou-se a defesa de DISSERTAÇÃO DE MESTRADO de GUILHERME BERARDI LUCAS, intitulada **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**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. ANDRÉ LUIZ ANDREOLI (Orientador - Participação Virtual) do Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. ALESSANDRO GOEDEL (Participação Virtual) do Departamento de Engenharia Elétrica / Universidade Tecnológica Federal do Paraná - UTFPR, Prof. Dr. PAULO JOSÉ AMARAL SERNI (Participação Virtual) do Departamento de Engenharia de Controle e Automação / Instituto de Ciência e Tecnologia - UNESP - Câmpus de Sorocaba. Após a exposição pelo mestrando e arguição pelos membros da Comissão Examinadora que participaram do ato de forma virtual, o discente recebeu o conceito final: APROVADO. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo Presidente da Comissão Examinadora.



Prof. Dr. ANDRÉ LUIZ ANDREOLI

# AGRADECIMENTOS

Agradeço, primeiramente, a minha família. Aos meus pais, Maria Aparecida e Evaldo, e minhas irmãs, Cássia e Marina, pelo suporte incondicional à minha formação pessoal e acadêmica e que sem a qual nada disso poderia ser realizado e nem faria sentido.

Ao Professor Dr. André Luiz Andreoli por me aconselhar e orientar em todas as etapas que me trouxeram até aqui. Seus conhecimentos técnicos e teóricos foram fundamentais para o desenvolvimento deste trabalho. Seu esforço constante para disponibilizar a melhor estrutura para seus orientandos inspirou e incentivou todas as atividades realizadas neste período. E, por fim, a amizade e os conselhos que levarei sempre comigo.

Ao meu Coorientador, Professor Dr. Bruno Albuquerque de Castro, pela amizade contínua e por todo tempo dedicado aos incontáveis conselhos e revisões, dentro e fora da academia. Pelo apoio e pelos ensinamentos durante os ensaios e produções científicas que engrandeceram, sem sombra de dúvida, todos os trabalhos realizados no período do mestrado.

À Marina, minha namorada, por me motivar e me tranquilizar sempre que foi preciso. Por me aconselhar e por acreditar em mim, sempre me dando forças para que eu seguisse em frente nos momentos mais decisivos da minha vida pessoal e profissional.

Aos meus colegas de laboratório, Marco Aurélio Rocha, Christielly Fernandes e Wallace Gabriel pelo companheirismo e pelas experiências que compartilhamos.

A todos os demais professores, técnicos e amigos que, de alguma maneira, contribuíram nessa jornada acadêmica e pessoal.

À CAPES pelo auxílio fornecido através da bolsa de estudos.

## RESUMO

A interrupção do funcionamento de um motor de indução trifásico (MIT) em uma linha de produção representa um alto custo operacional e financeiro. No entanto, estas máquinas estão frequentemente expostas a falhas mecânicas e elétricas que podem causar desde pequenos danos até a interrupção forçada de sua atividade. Esta conjuntura levou ao desenvolvimento de análises que utilizam diferentes sensores e técnicas de processamento de sinais com intuito de monitoramento dos MITs. Dentre elas, a análise de emissão acústica (EA) se destaca como uma ferramenta promissora e que se caracteriza por ser uma técnica não invasiva (TNI). Já o desequilíbrio de tensão (DT) é uma condição na alimentação elétrica da máquina e que, conhecidamente, é a origem de diversas falhas, entre elas o desgaste da isolação dos enrolamentos por efeito de sobreaquecimento, torque oscilatório e a diminuição da vida útil da máquina. Portanto, este trabalho propõe uma nova abordagem para o monitoramento dos DTs. Além de sua detecção e da identificação de qual fase foi afetada, foi também desenvolvido um sistema que possibilita a classificação de sua magnitude para MITs alimentados diretamente pela rede de baixa tensão. Para tanto, sensores piezoelétricos de baixo custo foram acoplados ao motor, tencionando a aquisição dos sinais de emissão acústica gerados como consequência dos DTs no equipamento. Para que fosse possível alcançar o diagnóstico proposto, foi desenvolvido um novo índice de análise dos sinais de EA baseado em técnicas avançadas de processamento de sinais como a Transformada Wavelet, energia do sinal de EA e a taxa de cruzamento por zero. Essas técnicas, além de possibilitarem o estudo de sinais transitórios e não-estocásticos, também permitiram uma análise no domínio tempo-frequência dos sinais. Por fim, os resultados demonstraram que este método é capaz de detectar, identificar e classificar os DTs corretamente, o que comprova a eficiência da abordagem e dos sensores utilizados.

**Palavras-chave:** Tensão desequilibrada; Transformada Wavelet; Sensor Piezoelétrico; Motor de Indução; Clusterização.

# ABSTRACT

The stoppage of a three-phase induction motor (TIM) on a production line represents a high operational and financial cost. However, these machines are often exposed to mechanical and electrical failures that can cause anything from minor damage to forced interruption of their activity. This situation has led to the development of analyses using different sensors and signal processing techniques for TIMs monitoring. Among them, acoustic emission analysis (AE) stands out as a promising tool that is characterized as a non-destructive technique (NDT). One of the most frequent anomalies, the voltage unbalance (VU) is a condition in the electrical supply that can cause winding insulation wearing due to overheating, torque oscillation, and the shortage of the machine working life. Therefore, this work proposes a new approach to detect the VUs events, identify which phase was affected by this unbalance, and classify the magnitude of the unbalanced voltage in TIMs directly powered by the low-voltage network. Thus, low-cost piezoelectric sensors were coupled to the motor, aiming to acquire the acoustic emission signals produced as a consequence of the VUs. In order to achieve the proposed diagnosis, a new AE signal analysis index was developed based on advanced signal processing techniques such as the Wavelet Transform, AE signal energy, and the zero-crossing rate. These techniques, besides enabling the study of transient and non-static signals, also allow a time-frequency domain analysis of the AE signals. Finally, the results stated that this method is capable of detecting, identifying, and classifying VUs correctly, which proves the efficiency of the approach.

**Keywords:** Unbalanced voltages, Wavelet Transform, Piezoelectric sensor, Induction motor, Clustering

## LISTA DE FIGURAS

Figura 1 – Exemplo de dano no enrolamento de um MIT causado por desequilíbrio de tensão . . . . .	15
Figura 2 – Diagrama de origens das falhas em máquinas elétricas . . . . .	21
Figura 3 – Elementos de um rolamento . . . . .	22
Figura 4 – Tipos de desalinhamento em MITs . . . . .	23
Figura 5 – Rotor do tipo gaiola de esquilo . . . . .	25
Figura 6 – Visão lateral e traseira do sistema de ventilação de um MIT . . . . .	26
Figura 7 – Exemplo de eixo excêntrico em um MIT . . . . .	27
Figura 8 – Imagens de danos causados por curtos-circuitos em MITs. . . . .	30
Figura 9 – Exemplos de tensões trifásicas equilibradas e desequilibradas . . . . .	34
Figura 10 – Componentes simétricas . . . . .	35
Figura 11 – Circuito equivalente para sequências positiva e negativa . . . . .	35
Figura 12 – Fator de depreciação de Torque para MIT . . . . .	39
Figura 13 – Espectro de frequência do sinal $X_c(j\Omega)$ . . . . .	43
Figura 14 – Espectro de frequência do sinal $S(j\Omega)$ . . . . .	43
Figura 15 – Espectro de frequência do sinal $X_s(j\Omega)$ . . . . .	44
Figura 16 – Espectro de frequência do sinal $X_s(j\Omega)$ com $\Omega_s < 2\Omega_N$ . . . . .	44
Figura 17 – Multimetro para porta de painéis . . . . .	47
Figura 18 – Sensores de corrente. a) baseado em TC; b) baseado em Efeito Hall . . . . .	49
Figura 19 – Fluxômetro baseado no Efeito Hall . . . . .	50
Figura 20 – Sensores Térmicos. a) Termoresistor; b) Termopar; c) Câmera Térmica; d) Termômetro Laser . . . . .	51
Figura 21 – Sensores Térmicos. a) Sensor MEMS; b) Sensor Piezo-resistivo; c) Sensor Piezoelétrico . . . . .	52
Figura 22 – Cristal de quartzo sob ação de forças no eixo x. a) Cristal estático; b) Cristal comprimido; c) Cristal tracionado . . . . .	54
Figura 23 – Capacitor sob ação de força mecânica . . . . .	55
Figura 24 – Cristal piezoelétrico com eletrodos . . . . .	57
Figura 25 – Forças de tração e compressão no diafragma piezoelétrico . . . . .	57
Figura 26 – Estrutura de um sensor comercial de emissão acústica . . . . .	58

Figura 27 – Sensor comercial de emissão acústica . . . . .	59
Figura 28 – Representação das distribuições de acordo com o valor de Curtose	62
Figura 29 – Representação da simetria de acordo com o valor de Assimetria . .	63
Figura 30 – Representação do sinal no domínio do tempo e no domínio da frequência. a) Domínio do tempo; b) Domínio da frequência . . . . .	64
Figura 31 – Diferença entre os sinais usados para reconstrução . . . . .	69
Figura 32 – Versão multirresolução da Transformada Wavelet . . . . .	71
Figura 33 – Transformada Wavelet de um sinal e suas escalas . . . . .	72
Figura 34 – Processo de criação dos coeficientes de aproximação e detalhe de cada nível Wavelet . . . . .	73
Figura 35 – Metodologia utilizada no trabalho . . . . .	76
Figura 36 – MIT acoplado ao gerador CC . . . . .	77
Figura 37 – Esquema das ligações das máquinas elétricas durante os ensaios .	77
Figura 38 – Sensores fixados ao MIT . . . . .	79
Figura 39 – Posição dos sensores no MIT . . . . .	80
Figura 40 – Placa de condicionamento de sinais . . . . .	81
Figura 41 – Esquemático interno de amplificação do CI INA128p . . . . .	81
Figura 42 – Fotografias dos elementos utilizados nos ensaios e suas ligações .	83
Figura 43 – Diferenças nos sinais de acordo com a fase afetada . . . . .	85
Figura 44 – Diagrama de cálculo do novo índice para cada um dos experimentos	87
Figura 45 – Exemplo de clusterização dos valores de $EZ$ . . . . .	88
Figura 46 – Diagrama de cálculo de $\bar{EZ}$ para cada um dos experimentos . . . .	89
Figura 47 – PSD do PLB aplicado ao sensor piezoelétrico . . . . .	93
Figura 48 – Valores limiares de $EZ$ para detecção de DT . . . . .	94
Figura 49 – Agrupamento obtido durante os testes preliminares . . . . .	95
Figura 50 – Índice <i>Silhouette</i> médio para os sensores frontais . . . . .	96
Figura 51 – Índice <i>Silhouette</i> médio para os sensores traseiros . . . . .	97
Figura 52 – Desvio padrão médio para os sensores frontais . . . . .	97
Figura 53 – Desvio padrão médio para os sensores frontais . . . . .	98
Figura 54 – Agrupamento das fases afetadas utilizando o valor de $EZ_{d6}$ nos sen- sores frontais . . . . .	99
Figura 55 – Agrupamento das fases afetadas utilizando o valor de $EZ_{d6}$ nos sen- sores frontais . . . . .	100

Figura 56 – Agrupamento das fases afetadas utilizando o valor de $EZ_{d6}$ nos sensores traseiros . . . . .	101
Figura 57 – Agrupamento das fases afetadas utilizando o valor de $EZ_{d6}$ nos sensores traseiros . . . . .	102
Figura 58 – $R^2$ da curva Energia <i>vs</i> Porcentagem de DT para a Fase A utilizando os valores referentes aos sensores frontais . . . . .	104
Figura 59 – $R^2$ da curva Energia <i>vs</i> Porcentagem de DT para a Fase B utilizando os valores referentes aos sensores frontais . . . . .	104
Figura 60 – $R^2$ da curva Energia <i>vs</i> Porcentagem de DT para a Fase C utilizando os valores referentes aos sensores frontais . . . . .	105
Figura 61 – $R^2$ da curva Energia <i>vs</i> Porcentagem de DT para a Fase A utilizando os valores referentes aos sensores traseiros . . . . .	105
Figura 62 – $R^2$ da curva Energia <i>vs</i> Porcentagem de DT para a Fase B utilizando os valores referentes aos sensores traseiros . . . . .	106
Figura 63 – $R^2$ da curva Energia <i>vs</i> Porcentagem de DT para a Fase C utilizando os valores referentes aos sensores traseiros . . . . .	106
Figura 64 – Regressão linear para Fase A utilizando o sensor frontal 4 . . . . .	107
Figura 65 – Regressão linear para Fase B utilizando o sensor frontal 2 . . . . .	108
Figura 66 – Regressão linear para Fase C utilizando o sensor frontal 1 . . . . .	108
Figura 67 – Regressão linear para Fase A utilizando o sensor traseiro 6 . . . . .	109
Figura 68 – Regressão linear para Fase B utilizando o sensor traseiro 7 . . . . .	109
Figura 69 – Regressão linear para Fase C utilizando o sensor traseiro 8 . . . . .	110

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	Considerações iniciais	13
1.2	Objetivos e motivação	17
1.3	Relevância Científica	17
1.4	Estrutura da dissertação	18
<b>2</b>	<b>FALHAS EM MÁQUINAS ELÉTRICAS E SUAS CONSEQUÊNCIAS</b>	<b>20</b>
2.1	As origens das falhas em máquinas elétricas	20
2.2	Falhas de origem mecânica	21
2.2.1	Falhas nos rolamentos	21
2.2.2	Desalinhamento	23
2.2.3	Desbalanceamento	23
2.2.4	Sobrecarga de carregamento mecânico	24
2.2.5	Barras quebradas	24
2.2.6	Problemas de ventilação	25
2.2.7	Excentricidade	26
2.3	Falhas de origem elétrica	28
2.3.1	Harmônicas	28
2.3.2	Falhas de isolamento	28
2.3.3	Curtos-circuitos	29
2.3.4	Descargas parciais	30
2.4	Desequilíbrio de tensão	31
2.4.1	Origens	31
2.4.2	Análise elétrica	33
2.4.3	Consequências	38
2.4.4	Definição e normas	39
<b>3</b>	<b>SENSORES APLICADOS À DETECÇÃO DE FALHAS EM MÁQUINAS ELÉTRICAS</b>	<b>42</b>
3.1	Aquisição de sinais	42
3.1.1	Subamostragem	42

3.1.2	Ruídos no sistema de medida . . . . .	45
<b>3.2</b>	<b>Sistemas baseados em sensores de tensão . . . . .</b>	<b>46</b>
<b>3.3</b>	<b>Sistemas baseados em sensores de corrente . . . . .</b>	<b>47</b>
<b>3.4</b>	<b>Sistemas baseados em sensores de fluxo . . . . .</b>	<b>49</b>
<b>3.5</b>	<b>Sistemas baseados em sensores de temperatura . . . . .</b>	<b>50</b>
<b>3.6</b>	<b>Sistemas baseados em sensores de vibração . . . . .</b>	<b>51</b>
<b>3.7</b>	<b>Demais sensores . . . . .</b>	<b>53</b>
<b>3.8</b>	<b>Sensores Piezoelétricos . . . . .</b>	<b>53</b>
3.8.1	Piezoelasticidade . . . . .	53
3.8.2	Sensores piezoelétricos de baixo custo . . . . .	56
<b>4</b>	<b>TÉCNICAS DE PROCESSAMENTO DE SINAIS NO DIAGNÓSTICO DE FALHAS EM MÁQUINAS ELÉTRICAS . . . . .</b>	<b>60</b>
<b>4.1</b>	<b>Técnicas de análise no domínio do tempo . . . . .</b>	<b>60</b>
4.1.1	Valor máximo e RMS . . . . .	60
4.1.2	Energia . . . . .	61
4.1.3	Curtose e Assimetria . . . . .	62
<b>4.2</b>	<b>Técnicas de análise no domínio da frequência . . . . .</b>	<b>63</b>
4.2.1	Transformada de Fourier . . . . .	64
4.2.2	Filtros . . . . .	65
4.2.3	Taxa de cruzamento por zero . . . . .	66
<b>4.3</b>	<b>Transformada de Hilbert . . . . .</b>	<b>67</b>
<b>4.4</b>	<b>Técnicas de análise utilizando Inteligência Artificial . . . . .</b>	<b>68</b>
<b>4.5</b>	<b>Transformada Wavelet . . . . .</b>	<b>68</b>
4.5.1	Introdução . . . . .	69
4.5.2	Transformada Wavelet Discreta . . . . .	73
<b>5</b>	<b>METODOLOGIA PROPOSTA . . . . .</b>	<b>75</b>
<b>5.1</b>	<b>Montagem experimental . . . . .</b>	<b>75</b>
5.1.1	Montagem das máquinas elétricas . . . . .	76
5.1.2	Sistema de aquisição de dados . . . . .	79
<b>5.2</b>	<b>Nova abordagem para detecção de desequilíbrios de tensão . . . . .</b>	<b>84</b>

5.2.1	Um novo índice baseado na Energia Ponderada pela Passagem por Zero . . . . .	86
5.2.2	Clusterização de dados e índice Silhouette . . . . .	89
<b>6</b>	<b>ANÁLISE DOS RESULTADOS . . . . .</b>	<b>92</b>
<b>6.1</b>	<b>Resposta em frequência do sensor piezoelétrico de baixo custo</b>	<b>92</b>
<b>6.2</b>	<b>Deteção do desequilíbrio de tensão . . . . .</b>	<b>93</b>
<b>6.3</b>	<b>Identificação da fase desequilibrada . . . . .</b>	<b>94</b>
6.3.1	Classificação da porcentagem de DT . . . . .	103
<b>7</b>	<b>CONCLUSÃO . . . . .</b>	<b>111</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>113</b>
<b>APÊNDICE A</b>	<b>LISTA DE PUBLICAÇÕES REALIZADAS DURANTE O PERÍODO DE MESTRADO . . . . .</b>	<b>130</b>

## Capítulo 1

# Introdução

*Neste primeiro capítulo, será exposto um panorama geral sobre o trabalho realizado. Aqui estarão dispostas as discussões que explicitam o contexto no qual esta dissertação está contida. Além disso, será descrito o objetivo principal deste trabalho, bem como suas motivações. Por fim, será evidenciada a relevância científica presente no escopo da dissertação.*

### 1.1 Considerações iniciais

No atual cenário de automação industrial, se faz como necessidade pungente o alto grau de monitoramento e controle das etapas do processo produtivo. A busca pela máxima eficiência e produtividade já não foca seus esforços apenas em novas tecnologias para o desenvolvimento de equipamentos especializados na substituição do trabalho manual, mas também na geração de um número massivo de dados a respeito das condições de manutenção e operação dos elementos da linha de produção. Assim sendo, técnicas capazes de monitorar e produzir diagnósticos de equipamentos mecânicos e elétricos vêm ganhando destaque nas pesquisas científicas (HE *et al.*, 2020; HU *et al.*, 2018; HU *et al.*, 2020; CHENG *et al.*, 2020).

No rol de equipamentos utilizados ao longo da linha de produção, os motores de indução trifásicos (MITs) podem ser apontados como um componente crucial para a continuidade da cadeia produtiva. Essa afirmação é baseada no fato de que inúmeros maquinários como esteiras, elevadores, centrífugas, bombas, ventiladores e muitos outros utilizam como força motriz um MIT. Além disso, são conhecidos por apresentar características construtivas atrativas, como robustez, baixo custo e facilidade de manutenção. Outro dado pertinente indica que os motores de indução estão associados a 90 % dos sistemas com acionamento elétrico e consomem mais de dois terços da energia elétrica produzida globalmente (NIKPAYAM *et al.*, 2020; KAVANA;


NEETHI, 2018; CHAWLA; VINAYAK; JAGADANAND, 2018; OJAGHI; SABOURI; FAIZ, 2018).

Dada a importância operacional dos MITs, existe uma relação mutualística entre o bom funcionamento desses motores com a eficiência e a produtividade de uma planta industrial. No entanto, mesmo apresentando alta confiabilidade, os MITs estão regularmente sujeitos a falhas de natureza elétrica e mecânica que podem causar efeitos diversos a esses equipamentos, incluindo a parada total do motor. Neste último caso, as consequências logísticas, materiais e financeiras podem tomar proporções relevantes, dependendo da operação envolvida. Portanto, inúmeras pesquisas têm sido desenvolvidas com o propósito de analisar e detectar as possíveis falhas que acometem os MITs e, através de um diagnóstico precoce, evitar a interrupção total do funcionamento, que pode causar danos permanentes aos motores, danos aos equipamentos adjacentes e a perda de matéria-prima associada à operação (GANGSAR; TIWARI, 2019; GLOWACZ; GLOWACZ, 2016; ALI *et al.*, 2019).

Dentre as falhas em MITs mais conhecidas, os danos no enrolamento do estator aparecem como uma das avarias mais corriqueiras de acordo com pesquisas anteriormente realizadas (ZHANG *et al.*, 2011; KUMAR; SINGH; NAIKAN, 2018). Diversos podem ser os eventos que dão origem a esse tipo de falha. No entanto, os mais habituais podem ser divididos em dois grupos, os estresses térmicos e os estresses mecânicos. Os primeiros têm como origem as sobrecargas e o desequilíbrio de tensão (DT). Já os estresses mecânicos tem como origem os atritos com o rotor desbalanceado, vibração e contaminação por óleo. Essas anomalias geralmente fazem com que correntes desbalanceadas percorram as espiras das fases do motor, causando sobreaquecimento, degradação do esmalte isolante (Figura 1), perda de torque, curtos-circuitos nos enrolamentos (fase/fase ou fase/terra) e, por fim, a diminuição da vida útil do equipamento significativamente (CARVALHO *et al.*, 2019; CAMPBELL; ARCE, 2016; WU; JIANG; WANG, 2020; GANGSAR; TIWARI, 2020).

Os DTs se ressaltam em meio as anormalidades já descritas, pois são ocorrências frequentes no cotidiano industrial. Apesar de eventos comuns como partidas de grandes motores possam gerar desequilíbrios de tensão na rede elétrica, diversas disfunções como contatos elétricos irregulares ou danificados, baixa qualidade do fornecimento de energia, defeitos construtivos em transformadores, irregularidades em cabos alimentadores e falhas nos dispositivos de proteção/seccionamento são fatores

Figura 1 – Exemplo de dano no enrolamento de um MIT causado por desequilíbrio de tensão



Fonte: WEG (2019)

igualmente capazes de originar DTs. (DASH; SAHU; PANIGRAHI, 2018; FERREIRA; ALBERTO; ALMEIDA, 2020).

Diferentes abordagens já foram propostas com a pretensão de elaborar técnicas capazes de monitorar e diagnosticar as inúmeras condições às quais o MIT está sujeito, e o DT não é uma exceção. De maneira simplificada, essas abordagens são compostas por um sensor, que é o responsável por fornecer um sinal de entrada para o sistema, e por uma técnica de processamento, que é a ferramenta computacional que irá estudar os sinais para viabilizar a interpretação desejada (KAHINGALA *et al.*, 2019; LASHKARI; POSHTAN; AZGOMI, 2015; XIA; KANNA; MANDIC, 2018; LUCAS *et al.*, 2018).

Desde que os estudos nessa área se iniciaram, o leque de novos sensores e técnicas de processamento está em expansão. Deste modo, diferentes pesquisadores fizeram uso desses instrumentos acompanhando as inovações tecnológicas. Desde então, foram desenvolvidos sistemas baseados em sensores de naturezas diversas, ou seja, capazes de mensurar diferentes tipos de grandezas. Dentre os mais utilizados nas pesquisas recentes, pode-se destacar os sensores de corrente, os de vibração mecânica, os térmicos e os de emissão acústicos (EA). Além disso, o aumento do poder computacional dos processadores permitiu que ferramentas matemáticas complexas pudessem ser executadas com maior facilidade. Como consequência direta disso, as técnicas de processamento de sinais avançadas evoluíram e possibilitaram análises não só no domínio do tempo, como também no domínio da frequência e tempo-frequência,

além dos sistemas inteligentes.

Diante das várias alternativas de sensores disponíveis, vale a pena destacar os de natureza acústica. Além de apresentar bons resultados em pesquisas anteriores (CASTRO *et al.*, 2017; GLOWACZ, 2019; SANGEETHA; HEMAMALINI, 2019; AKCAY; GERMEN; TURKAY, 2018), esse tipo de sensor tem como vantagem ser uma opção de técnica não invasiva para diagnósticos (CASTRO *et al.*, 2019), *i.e.*, não é necessário desmontar, danificar e nem ao menos desativar o equipamento para que seja feita a análise. Esse método se baseia na aplicação de um transdutor de EA com a finalidade de converter os sinais acústicos gerados por uma máquina em sinais elétricos.

Considerando que cada falha tem sua assinatura acústica específica, esses sinais elétricos podem ser examinados em busca de características que se correlacionem com algum comportamento anômalo e, desta forma, realizar o diagnóstico. Por fim, os métodos acústicos apresentam qualidades notáveis como uso de equipamento simples e práticos, capacidade de realizar diagnósticos de maneira precoce, alta sensibilidade e aptidão para captar sinais de baixa potência (PAREY; SINGH, 2019; VINAYA *et al.*, 2019; MONDAL *et al.*, 2019; HASAN; ISLAM; KIM, 2019). No entanto, os sinais de EA não estão totalmente imunes aos ruídos inerentes aos ambientes aonde esses dispositivos costumam estar alocados. Conseqüentemente, técnicas de processamento de sinal precisam ser empregadas não só para detectar possíveis falhas, mas também para separar o conteúdo relevante dos ruídos inseridos no sinal adquirido (ZHANG *et al.*, 2020).

Dada a sua capacidade de investigar as mudanças no espectro de um sinal ao longo de um determinado período de tempo, as técnicas de tempo-frequência têm sido utilizadas nas mais diversas áreas do conhecimento para o processamento de sinais que apresentam comportamento não estacionários e transitórios (COHEN, 1995). Sendo assim, a complexidade observada no estudo de certos sinais, culminou na preeminência das técnicas de análise no domínio do tempo-frequência devido às suas já citadas características únicas. Como será demonstrado nos capítulos posteriores, a Transformada Wavelet é um artifício matemático que se destaca dentre as análises de tempo-frequência. Alguns de seus atributos fizeram com que essa ferramenta fosse largamente aplicada para detecção de falhas, inclusive utilizando sinais acústicos (GENG; WANG; ZHOU, 2019; ZHANG *et al.*, 2017; PAREY; SINGH, 2019; SACHAN; SHUKLA; SINGH, 2020).

## 1.2 Objetivos e motivação

Devido ao papel relevante dos motores de indução nas operações e processos industriais, qualquer tempo de parada não planejada pode representar perdas econômicas e produtivas significativas. Deste modo, é crucial o desenvolvimento de TNIs que permitam a detecção de condições anormais em MITs, dentre elas as tensões desequilibradas. O DT leva ao desgaste mecânico dos enrolamentos e resulta em perdas de torque no eixo da máquina, reiterando a relevância das propostas que abordam este tema.

Portanto, este trabalho propõe uma nova metodologia para detectar a ocorrência de DTs em MITs alimentados diretamente pela rede de baixa tensão, identificar qual fase foi afetada e classificar sua magnitude. A proposta da dissertação foi concretizada através do desenvolvimento de uma nova métrica de agrupamento de dados baseada na energia dos coeficientes Wavelet e na taxa de cruzamento por zero (TCZ), chamada de Energia Ponderada pela Passagem por Zero (EZ). Os sinais de EA foram adquiridos por transdutores piezoelétricos acoplados ao motor para que fosse possível a aplicação da nova técnica. As cápsulas piezoelétricas utilizadas nesta pesquisa são baseadas em Titanato Zirconato de Chumbo (PZT). Essas cápsulas foram configuradas como sensores com o objetivo de captar os padrões acústicos do DT. Inúmeros testes foram realizados com a aplicação de diferentes tensões desequilibradas e os resultados indicaram que a abordagem desenvolvida foi capaz de efetuar uma análise bem sucedida dos DTs impostos ao MIT. Dessa maneira, é possível diagnosticar os DTs e evitar seus efeitos colaterais já descritos anteriormente.

## 1.3 Relevância Científica

Embora a técnica de emissão acústica já tenha sido utilizada para o diagnóstico de diversas falhas, ela não foi previamente validada para detecção, identificação de fase e classificação da severidade dos DTs simultaneamente (SIRAKI; PILLAY, 2012; AL-BADRI; PILLAY; ANGERS, 2016; XIA; KANNA; MANDIC, 2018; SHEIKH *et al.*, 2017b; SHEIKH *et al.*, 2017a), tornando-se um fator primordial para o avanço das técnicas de diagnóstico já existentes. Adicionalmente, o método apresentado pode ser englobado por sistemas de análise de emissão acústica que já estão previamente instalados

em máquinas elétricas, adicionando uma importante funcionalidade a esses sistemas. Ainda, como muitos picos, quedas e flutuações de tensão acontecem de forma aleatória, se faz necessário o desenvolvimento de sistemas capazes de monitorar, diagnosticar e arquivar dados acerca dos DTs e não apenas proteger os motores durante a ocorrência desses eventos.

Diversos autores já propuseram o estudo do desequilíbrio de tensão utilizando diferentes sensores e técnicas de processamento (CAMPBELL; ARCE, 2016; SHEIKH *et al.*, 2017a; DASH; SAHU; PANIGRAHI, 2018; FERREIRA; ALBERTO; ALMEIDA, 2020). No entanto, nenhum desses trabalhos alcançou o diagnóstico simultâneo de detecção, identificação e classificação do DT. Outro ponto que levou à criação desta métrica é o fato de ser uma técnica analítica de grande relevância para monitoramento de MITs e que também não depende de aprendizado supervisionado, como nas redes neurais artificiais. Além disso, os sensores piezoelétricos são uma alternativa de baixo custo aos sensores comerciais atuais (CASTRO; BAPTISTA; CIAMPA, 2019), viabilizando financeiramente a aplicação da EA em diagnósticos de máquinas.

## 1.4 Estrutura da dissertação

O Capítulo 2 fará uma revisão acerca das falhas às quais os MITs estão expostos. Além de suas naturezas, serão discutidas também as consequências que podem se originar devido a ocorrência dessas falhas. Por fim, a dinâmica e as consequências do DT, que é o foco deste trabalho, serão apresentadas de maneira mais detalhada.

O Capítulo 3 abordará alguns dos sensores que são comumente utilizados nos trabalhos envolvendo análise de falhas em máquinas elétricas, além de abranger as melhores práticas para obtenção de dados de acordo com as teorias de aquisição de sinais presentes nas bibliografias. Além disso, será exposto o funcionamento do sensor piezoelétrico de baixo custo proposto neste trabalho.

O Capítulo 4 tratará das técnicas de processamento de sinais mais conhecidas a respeito do tema desta dissertação. Serão detalhadas as técnicas aplicadas no domínio do tempo, no domínio da frequência e, por fim, a Transformada Wavelet, que foi a ferramenta utilizada no desenvolvimento da métrica elaborada neste trabalho.

O Capítulo 5 descreverá com detalhes a metodologia e os conceitos utilizados especificamente neste trabalho. O desenvolvimento da nova métrica, a montagem

experimental das máquinas elétricas e do sistema de aquisição de dados também serão detalhados.

Os resultados obtidos através do método proposto e as conclusões finais do trabalho, serão apresentados, respectivamente, no Capítulo 6 e no Capítulo 7.

Finalmente, no Apêndice A, estará disposta uma lista com as publicações realizadas durante o período de Mestrado.

## Capítulo 2

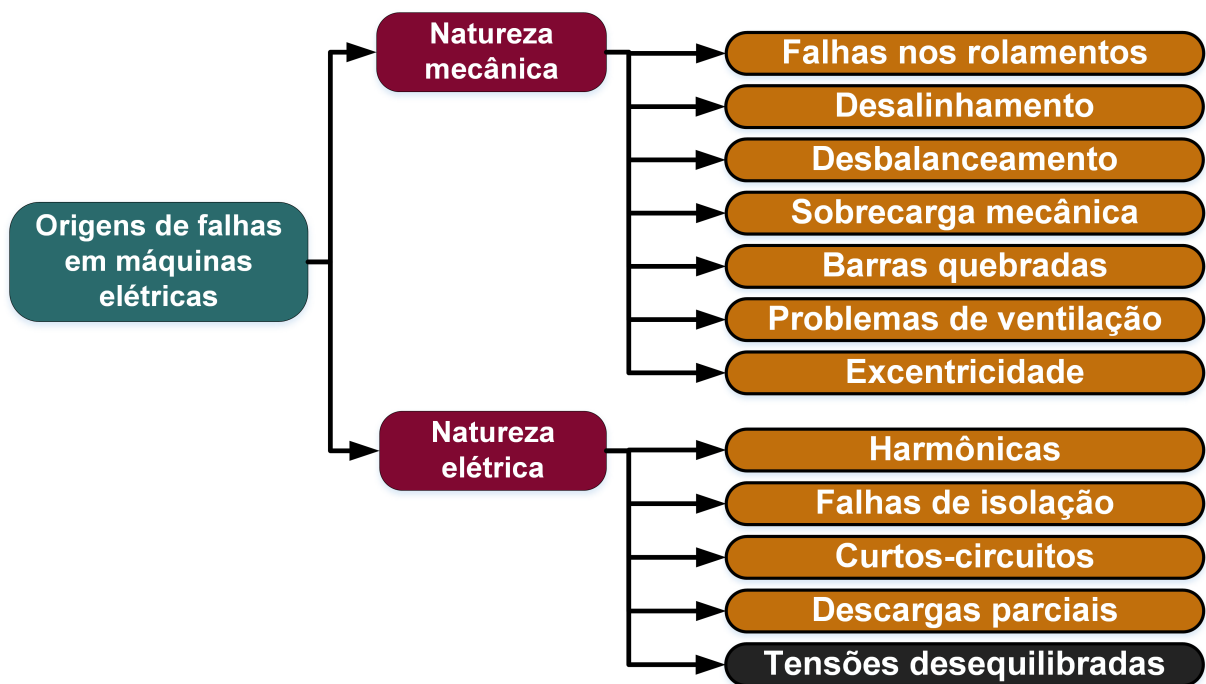
# Falhas em máquinas elétricas e suas consequências

*Como exposto anteriormente, os motores de indução são máquinas altamente confiáveis e sua aplicação na indústria revolucionou as linhas de produção. No entanto, os MITs não estão livres de uma ampla sorte de falhas elétricas e mecânicas que os acometem frequentemente. Baseados nesta constatação, os próximos subcapítulos descreverão, com maiores detalhes, as relações de causa e consequência inerentes a cada uma dessas falhas. Além dos motores de indução, também estarão citadas, de maneira mais sucinta, outras máquinas elétricas que estão sujeitas aos mesmos tipos de falhas aqui descritas.*

## 2.1 As origens das falhas em máquinas elétricas

Dado o numeroso conjunto de possíveis falhas, foram sintetizadas as de maior relevância na Figura 2, com destaque gráfico para o que será objeto do estudo. Essa listagem foi utilizada como base para a escolha dos próximos subcapítulos e representa as principais origens elétricas e mecânicas de falhas em MITs e outras máquinas elétricas.

Figura 2 – Diagrama de origens das falhas em máquinas elétricas



Fonte: Próprio autor

## 2.2 Falhas de origem mecânica

Neste subcapítulo serão apresentadas algumas das falhas de natureza mecânica que acometem as máquinas elétricas.

### 2.2.1 Falhas nos rolamentos


Os danos nos rolamentos de motores de indução aparecem em muitos levantamentos como a maior fonte de problemas que atingem estes equipamentos. Além disso, é sabido que dentre as possíveis causas de falhas nos rolamentos, as esferas são a sua fonte mais comum. A falta de lubrificação e a carga mecânica excessiva prejudicam esses componentes, levando ao excesso de atrito e danos físicos ao conjunto (TRIGEASSOU, 2011; OJAGHI; SABOURI; FAIZ, 2018).

Os rolamentos têm o papel de diminuir o atrito mecânico durante o movimento rotativo dos MITs. Portanto, a dissipação de energia resultante da fricção desse dispositivo se torna relevante nos parâmetros de eficiência do motor. Além disso, dependendo do nível de desgaste, essa falha pode gerar um movimento vibracional

de grande proporção, resultando em outros tipo de falha, ruídos sonoros e diminuição da vida útil do equipamento. Em casos extremos, esse fenômeno pode acarretar na parada total de um motor e em paradas não planejadas para manutenção forçada, gerando prejuízos financeiros (HASAN; ISLAM; KIM, 2019; SONG; WANG; HU, 2019; OJAGHI; SABOURI; FAIZ, 2018).

A importância dos rolamentos para os MITs se traduz nas diversas pesquisas já realizadas a respeito da detecção precoce de seus defeitos. Nesse contexto, os elementos dos rolamentos são costumeiramente divididos entre pista externa, pista interna, elemento rolante e gaiola (Figura 3). Esse tema já foi amplamente abordado e as frequências associadas às falhas de cada elemento dos rolamentos já são conhecidas (NIVSRANGSAN; JANTARAJIROJKUL, 2018; VIITALA; WIDMAIER; KUOSMANEN, 2018). Esse conhecimento prévio deu origem a diferentes equipamentos comerciais que são largamente aplicados nas rotinas de manutenção das indústrias. Dentre as causas associadas ao desgaste dos rolamentos, pode-se destacar a carga excessiva no eixo, lubrificação incorreta, tensões induzidas, vedação defeituosa e desalinhamento no eixo (TRIGEASSOU, 2011).

Figura 3 – Elementos de um rolamento




Fonte: Próprio autor

## 2.2.2 Desalinhamento

O desalinhamento é uma falha mecânica que tem como origem a instalação incorreta dos MITs. Se os equipamentos de ajuste não forem utilizados da maneira correta durante a instalação, pode haver um desalinhamento em relação ao eixo axial formado entre o motor e sua carga e que pode se apresentar de duas formas distintas: paralelo e angular, como demonstrado na Figura 4 . Comercialmente estão disponíveis ferramentas analógicas e digitais para realizar esse procedimento, como, por exemplo, relógios comparadores e níveis a laser. Os acoplamentos elásticos também são equipamentos projetados para diminuir os efeitos nocivos do desalinhamento em MITs (FAIZ, 2017).

Figura 4 – Tipos de desalinhamento em MITs



Fonte: Próprio autor

Os desalinhamentos geram aumento de temperatura, ruídos, vibrações e, conseqüentemente, perdas de potência. Adicionalmente, essa falha deteriora as partes móveis e fixas dos MITs, inclusive os rolamentos, diminuindo o tempo de vida útil da máquina. Por esses motivos, a detecção dessa condição também foi estudada por diversos autores (SAPUTRA *et al.*, 2019; CHAUDHURY; GUPTA, 2006; HUJARE; KARNIK, 2018).

## 2.2.3 Desbalanceamento

O desbalanceamento do eixo de um MIT apresenta conseqüências semelhantes às causadas pelo desalinhamento. No entanto, a origem dessa falha se deve a um deslocamento do centro de massa do rotor em relação ao eixo de rotação. Pode ser ocasionado por um defeito de fabricação, gerando assim, uma assimetria do rotor

e alterando seu centro de massa. Sua ocorrência gera movimentos vibratórios que podem ter consequências graves se não houver uma tratativa. Portanto, essa falha também é frequentemente tomada como objeto de estudo (TRIGEASSOU, 2011).

#### 2.2.4 Sobrecarga de carregamento mecânico

A sobrecarga mecânica ocorre quando a carga à qual o motor está acoplado demanda um torque superior ao seu valor nominal. Há também outros fatores que podem promover a obstrução do eixo, como rolamentos defeituosos, sujidades, falta de lubrificação e outros problemas mecânicos, inclusive na própria carga. Embora os MITs sejam projetados para suportar uma sobrecarga por um certo período de tempo, a persistência desta condição faz com que a corrente se eleve acima do valor nominal. O efeito adverso da elevação de corrente é o superaquecimento dos enrolamentos do motor, que leva à degradação do esmalte isolante que, por sua vez, pode acarretar em um curto-circuito entre as espiras, resultando em um efeito cascata totalmente destrutivo (KARMAKAR, 2016).

Apesar de ser extremamente prejudicial aos MITs, a sobrecarga pode ser mitigada com relativa facilidade por equipamentos como relês e dispositivos de proteção contra sobrecorrentes. No entanto, devido às margens de ajustes destes dispositivos, é de extrema importância que os motores de indução sejam bem dimensionados de acordo com as cargas que irá acionar (FERREIRA; LEPRETTRE; ALMEIDA, 2016).

#### 2.2.5 Barras quebradas

Os motores de indução do tipo gaiola de esquilo possuem em seu rotor uma estrutura com barras curto circuitadas entre si por meio de dois anéis em suas extremidades (Figura 5). Uma falha relativamente comum em MITs é a quebra de uma dessas barras, gerando efeitos indesejados para o bom funcionamento do motor. Dentre as causas do dano estão o efeito térmico causado por altas corrente fluindo pelo rotor, forças eletromagnéticas desequilibradas, problemas de manufatura, fadiga mecânica e forças centrífugas exacerbadas. Quando uma barra é danificada e impede a passagem de corrente, a resistência do rotor se altera, gerando flutuações de velocidade, correntes desbalanceadas, vibrações e fluxo desbalanceado. As barras danificadas não auxiliam na geração de torque, no entanto, o torque eletromagnético nominal do motor

ainda é exigido pela carga, fazendo com que as outras barras operem em sobrecorrente para compensar a barra quebrada. Esse comportamento pode gerar um efeito cascata, danificando as barras ainda saudáveis (FAIZ, 2017; XIE *et al.*, 2019).

Figura 5 – Rotor do tipo gaiola de esquilo



Fonte: adaptado de Umans (2014)

Uma só barra quebrada pode não causar uma parada total de um MIT num curto período de tempo, mas a médio e longo prazo essa falha pode se agravar, ocasionando avarias sérias ao motor. Por esse motivo, muitos autores se empenharam em desenvolver técnicas que possibilitem um diagnóstico precoce, evitando as consequências do funcionamento prolongado sob essa condição. Devido ao grande número de estudos, muito se sabe sobre os efeitos colaterais e sobre métodos eficazes de detectar essa anomalia, inclusive sobre as frequências de vibração associadas a cada número de barras danificadas (TRUJILLO-GUAJARDO *et al.*, 2018; DIAS; PEREIRA, 2018; RANGEL-MAGDALENO *et al.*, 2017; MALEK; ABDELSALAM; HASSAN, 2018; SINGH; NAIKAN, 2018).


## 2.2.6 Problemas de ventilação

Como já citado, o superaquecimento dos componentes internos de máquinas elétricas podem ocasionar danos irreversíveis. Mesmo em sua operação nominal, as máquinas elétricas produzem calor devido ao efeito Joule, atrito mecânico e correntes parasitas. Dependendo da dimensão e da operação da máquina, são necessários métodos de arrefecimento para o seu funcionamento. Inclusive, algumas máquinas

como motores de corrente contínua e grandes transformadores necessitam de sistemas de ventilação auxiliares para controlar a temperatura de seus componentes internos.

Em MITs, a temperatura é normalmente mantida dentro de valores aceitáveis por intermédio de uma ventoinha acoplada ao eixo, aproveitando o movimento rotacional executado pelo motor para promover a auto-ventilação. As ventoinhas forçam a passagem do ar em temperatura ambiente por meio das aletas de resfriamento do motor, como exemplificado na Figura 6 (UMANS, 2014). Devido a fadigas mecânicas ou defeitos de fabricação, as pás da ventoinha podem perder sua funcionalidade, acarretando na elevação da temperatura do motor, mesmo na ausência de outros tipos de falha. Por fim, se os orifícios por onde o ar ambiente é aspirado apresentarem algum tipo de obstrução ou a temperatura ambiente for muito alta, a ventilação também será afetada.

Figura 6 – Visão lateral e traseira do sistema de ventilação de um MIT




Fonte: Próprio autor

### 2.2.7 Excentricidade

Em condições normais, o eixo de rotação do rotor é perfeitamente alinhado ao centro geométrico do estator. Desta maneira, o comprimento do entreferro se mantém constante em todos os pontos durante o movimento de rotação. No entanto, em razão de má fabricação ou de algum efeito colateral resultante de outras falhas mecânicas como desalinhamento, desbalanceamento e falhas no rolamentos, o eixo de rotação pode se tornar excêntrico. Existem dois tipos de excentricidade: a dinâmica, aonde o eixo de rotação se desloca ao longo do tempo (Figura 7); e a estática: aonde o centro de rotação permanece fixo, porém ainda desalinhado em relação ao centro do estator.

Figura 7 – Exemplo de eixo excêntrico em um MIT



Fonte: Próprio autor

A falta de uniformidade do entreferro causa uma variação de indutância e altera a dinâmica do circuito magnético. O fluxo eletromagnético no entreferro se torna desbalanceado gerando, deste modo, forças desequilibradas. O lado do rotor que possui a menor distância de entreferro experimentará uma força de maior amplitude, enquanto o lado de maior distância estará sob o efeito de uma força de menor amplitude. Os sintomas mais comuns desta falha são ruídos, vibração, variação de torque e flutuação de velocidade. Em casos mais agravados, o rotor excêntrico pode ter contato mecânico com os enrolamentos do estator. O desgaste causado por esta condição eventualmente degrada o esmalte das espiras, podendo ocasionar curto-circuito ou até mesmo interrupção da passagem de corrente por rompimento (TOLIYAT, 2013; SAAD, 2018). Devido a alta frequência de ocorrência desse falhas e dos efeitos colaterais potencialmente prejudiciais, o diagnóstico da excentricidade em MITs já foi objeto de estudo de várias pesquisas científicas (WU; ZHU, 2019; SALAH; DORRELL; GUO, 2019; SAPENA-BANO *et al.*, 2020; OUMAAMAR *et al.*, 2017).

## 2.3 Falhas de origem elétrica

Neste subcapítulo serão apresentadas algumas das falhas de natureza elétrica que acometem as máquinas elétricas.

### 2.3.1 Harmônicas

As distorções harmônicas são deformações nas ondas perfeitamente senoidais devido a componentes de frequência indesejadas na rede elétrica. Ao percorrerem os enrolamentos, a energia dessas componentes geram perdas adicionais e podem aumentar a temperatura, reduzir o torque, produzir ruídos audíveis e diminuir a eficiência do motor. Essas frequências são geradas por cargas não lineares conectadas à rede e também pelas próprias falhas no MIT. De acordo com a norma IEEE : 519-2014 (2014) existem níveis aceitáveis para distorções harmônicas na alimentação de MITs e o funcionamento contínuo sob a influência de harmônicas pode levar ao enfraquecimento da capacidade isolante dos enrolamentos.

Os analisadores de qualidade de energia são equipamentos utilizados para investigar as componentes presentes na rede e permitem um diagnóstico dos níveis de cada uma delas. Adicionalmente, os efeitos e a mitigação de harmônicas são objetos frequentes de estudos na área de máquinas elétricas (PRAMANICK *et al.*, 2017; RAKESH; NARAYANAN, 2017; SIVAKUMAR; SELVAN, 2018; DONOLO *et al.*, 2016).

### 2.3.2 Falhas de isolação

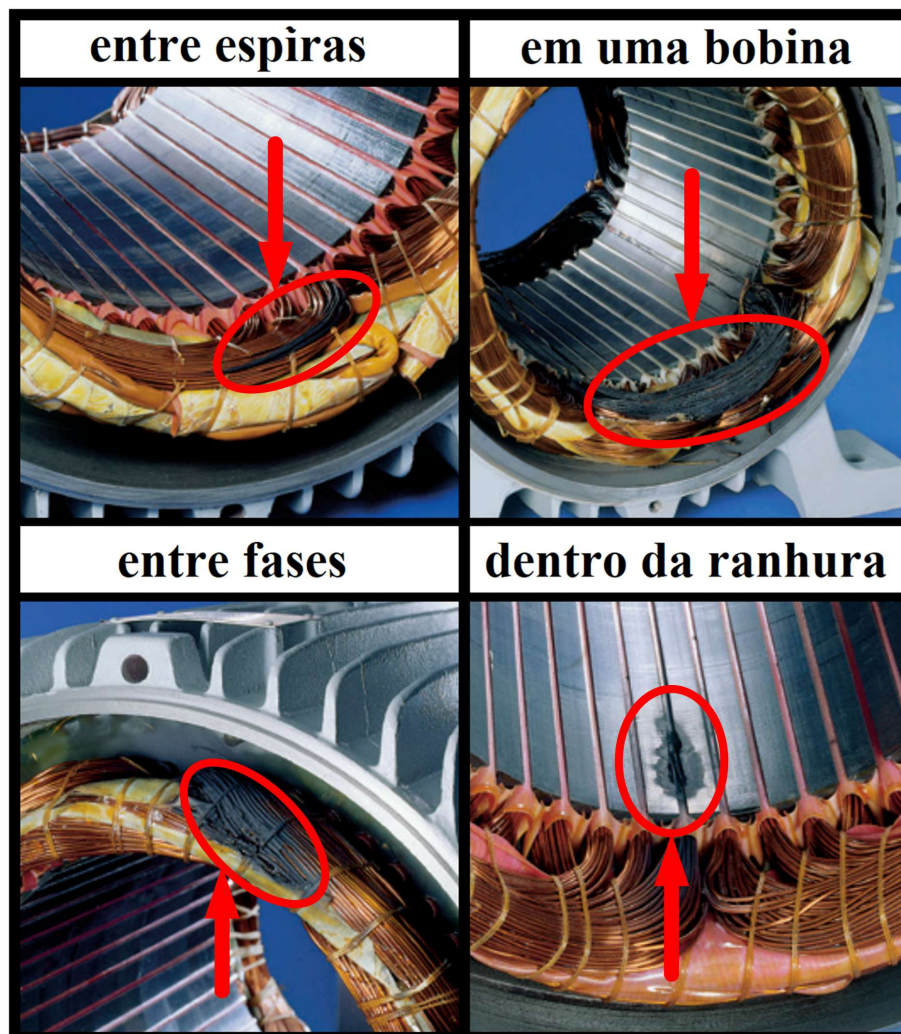
Os enrolamentos dos MITs são compostos por fios recobertos por um esmalte isolante. Essa isolação é primordial, se comprometida, pode vir a gerar curtos-circuitos, aquecimento, descargas parciais, fugas de corrente e outros problemas. Os enrolamentos estão sujeitos a elementos químicos abrasivos, altas temperaturas, atrito mecânico acidental com outros elementos do motor, envelhecimento, radiação, atrito devido a movimentos vibratórios e defeitos de fabricação. Todos esses itens são fatores que comprometem a qualidade e a vida útil dos enrolamentos e que também podem ser causados por outros tipos de falha (SAAD, 2018). Aparelhos como o megômetro foram desenvolvidos para avaliar a resistência dos MITs e diagnosticar possíveis defeitos.

### 2.3.3 Curtos-circuitos

Para os motores de indução, assim como para outras máquinas elétricas, os curtos-circuitos representam sérios riscos para o seu funcionamento. Além disso, os efeitos térmicos provocados por um curto circuito podem gerar danos irreversíveis aos equipamentos e, em alguns casos, iniciar focos de incêndio. Apesar da possibilidade de ocorrência transitória desse tipo de falha, a maioria dos curtos-circuitos evoluem de maneira gradativa nos enrolamentos, isto é, a isolação presente nos fios se degrada progressivamente por envelhecimento ou em razão de alguma outra falha. Ao longo do tempo, espiras vizinhas começam a apresentar contato elétrico, com isso, a resistência do enrolamento diminui, fazendo com que a corrente naquele ponto atinja um valor maior que o nominal. Deste modo, esse fenômeno dá origem a um efeito realimentado de desgaste da isolação elétrica nos condutores. Portanto, é possível que, no momento que os impactos mais evidentes forem percebidos, a isolação já esteja seriamente comprometida no interior da máquina. Conseqüentemente, muitos estudos buscam maneiras de detecção precoce da ocorrência de curtos-circuitos entre as espiras dos MITs (DHAMAL; BHATKAR, 2018; FIRETEANU *et al.*, 2018; SOLODKIY; DADENKOV; SALNIKOV, 2019; GONCALVES *et al.*, 2018).

Além do contato entre espiras da mesma fase, dependendo da dinâmica da falha, outros tipos de curto-circuito podem ocorrer: curto-circuito entre duas ou três fases; curto-circuito entre fase e terra; e curto-circuito entre fase e neutro (Figura 8). Por fim, os curtos-circuitos em máquinas elétricas são responsáveis por correntes desequilibradas entre os enrolamentos de cada fase. As forças desbalanceadas oriundas desse comportamento acarretam movimentos vibratórios excessivos que podem prejudicar outros componentes mecânicos do equipamento. Ademais, podem oferecer riscos à saúde, inclusive de choque elétrico, se os sistemas de proteção não forem adequadamente instalados.

Figura 8 – Imagens de danos causados por curtos-circuitos em MITs.



Fonte: adaptado de WEG (2019)

### 2.3.4 Descargas parciais

A descarga parcial (DP) é outra consequência da diminuição da rigidez dielétrica na isolação dos condutores de máquinas elétricas. Essas descargas se dão em forma de faíscas elétricas de curta duração que se originam quando o gradiente de tensão em pequenas partes danificadas do material supera a sua capacidade isolante, permitindo a passagem de corrente. Geralmente, está associada a equipamentos de maior nível de tensão e/ou acionados por inversores, devido aos abruptos pulsos de tensão utilizados no controle dos MITs. Na ocorrência de uma DP, apenas uma pequena alteração na corrente de alimentação pode ser notada, dificultando sua detecção (SAAD, 2018;

KARMAKAR, 2016).

Apesar de isoladamente não apresentar grandes ameaças às máquinas elétricas, esse fenômeno pode se repetir até ocasionar uma ruptura mais severa da isolação, que produz consequências já comentadas nos tópicos anteriores. Por esse motivo, diversos autores estudam a detecção das descargas parciais como ferramenta para mensurar a qualidade dos isolamentos em máquinas elétricas (LUSUARDI *et al.*, 2018; STONE; SEDDING; CHAN, 2018; YUAN *et al.*, 2019; CHEN; YANG, 2018).

## 2.4 Desequilíbrio de tensão

Os desequilíbrios de tensão (DT) são irregularidades na alimentação elétrica e que têm efeitos negativos para os motores de indução. Por serem o objeto de estudo deste trabalho, as próximas seções abordarão detalhadamente esses eventos.

### 2.4.1 Origens

As tensões nos terminais de um MIT devem ser idealmente idênticas em amplitude e defasadas de 120°. No entanto, inúmeras não idealidades nos componentes dos sistemas elétricos fazem com que essa regra nem sempre se cumpra. Apesar de várias normas e parâmetros serem estabelecidos para indicar os níveis toleráveis de distorções na qualidade de energia, alguns fatores estruturais ou circunstanciais podem levar esses níveis para patamares prejudiciais às cargas conectadas à rede (BAGGINI, 2008).

Os fatores estruturais são aqueles que apresentam uma influência de valor fixo ou com uma variação muito pequena. O desequilíbrio causado por esses fatores é previsível e pode ser monitorado de maneira mais simples. Contudo, são comuns e também podem causar danos sérios aos MITs. São exemplos desse tipo de fator os seguintes itens (JOUANNE; BANERJEE, 2001; DASH; SAHU; PANIGRAHI, 2018):

- a) **Transformadores com enrolamentos desbalanceados:** se os transformadores não forem cuidadosamente fabricados, as impedâncias de suas fases podem apresentar valores diferentes. Como resultado dessa diferença, o ajuste de tensão e as perdas nos enrolamentos serão diferentes e,

consequentemente, as tensões de saída do transformador também apresentarão valores distintos entre si, criando um desequilíbrio no sistema.

- b) **Linhas de transmissão desbalanceadas:** assim como os transformadores, as linhas de transmissão também precisam ter valores iguais de impedância. Muitas vezes, essas linhas podem apresentar comprimentos diferentes ou ter uma de suas linhas substituídas por materiais com propriedades de condução divergentes (em razão de economia de gastos, por exemplo). Esses fatores podem gerar diferenças significativas entre tensões de cada fase quando observadas em cada uma das extremidades da linha.
- c) **Bancos de capacitores desbalanceados:** os bancos de capacitores são equipamentos muito utilizados nas indústrias para compensação de fator de potência, principalmente em plantas que possuem muitos motores de indução. No entanto, se por algum motivo, esses capacitores não forem idênticos ou algum deles for danificado, as tensões de saída do banco podem ser desequilibradas.
- d) **Mau contato:** é muito comum, em grandes instalações industriais, devido à montagem incorreta ou desgaste natural com o tempo, que existam pontos de mau contato. Isso se dá em virtude do grande número de componentes que possuem conexões elétricas tanto móveis, quanto fixas. A alta impedância que se manifesta nesses pontos é responsável pelo aquecimento acima do normal e, em alguns casos, uma significativa queda de tensão. Sendo assim, num componente polifásico, essa queda pode gerar diferenças entre os valores de tensão de cada fase ou mesmo uma queda em todas as fases, dependendo de onde se manifestar o mau contato.

Os fatores circunstanciais são causados por eventos aleatórios ou de difícil previsibilidade. Esses fatores são dinâmicos, portanto, não há uma forma confiável de prever quando e com qual intensidade eles causarão DTs na rede. A melhor ferramenta contra esse tipo de ameaça é a manutenção preditiva, que pode ser balizada por

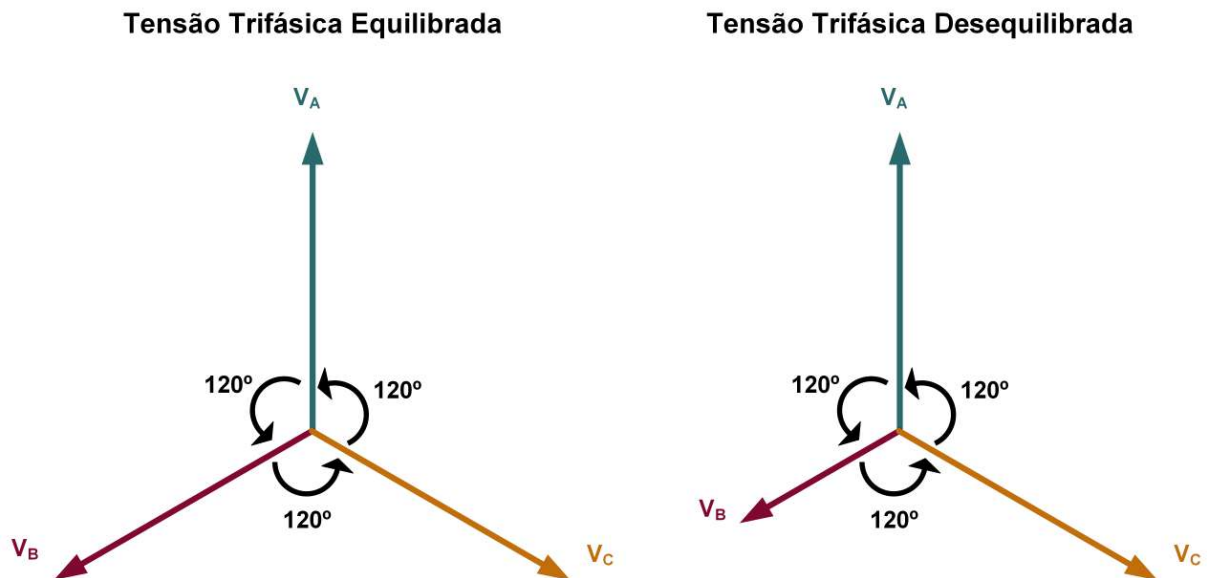
sistemas como o desenvolvido neste trabalho. Os principais exemplos desses fatores são (JOUANNE; BANERJEE, 2001; DASH; SAHU; PANIGRAHI, 2018):

- a) **Equipamento desbalanceado:** equipamentos trifásicos que possuem impedâncias de fase desbalanceadas também são capazes de gerar desequilíbrios na rede. Quando esses componentes são acionados, esses equipamentos representam cargas desiguais para cada uma das fases, gerando desequilíbrios.
- b) **Cargas monofásicas mal distribuídas:** quando grandes cargas monofásicas não são bem distribuídas entre as fases do sistema elétrico, o seu acionamento resultará em desequilíbrios na rede. Esse fenômeno é uma causa comum na criação de tensões significativamente diferentes na alimentação de outros equipamentos conectados ao sistema.
- c) **Falhas em dispositivos de proteção:** independente do tipo de partida, a alimentação de motores de indução sempre conta com ao menos um tipo de dispositivo de proteção (disjuntores, contatores, fusíveis, etc). O envelhecimento dos componentes internos, o desgaste pelo uso incorreto do dispositivo de proteção como dispositivo de operação, condições ambientais adversas e mau dimensionamento são fatores que diminuem a vida útil e podem acarretar em falhas que prejudiquem o fluxo de corrente em apenas uma das fases. Assim sendo, a alimentação do MIT estará desequilibrada.

#### 2.4.2 Análise elétrica

Um sistema trifásico equilibrado é composto por três tensões de mesma magnitude e defasadas exatamente em  $120^\circ$  entre si. Se qualquer alteração for feita nesse arranjo, pode-se dizer que o sistema estará desequilibrado, como ilustrado na Figura 9 (BAGGINI, 2008).

Figura 9 – Exemplos de tensões trifásicas equilibradas e desequilibradas



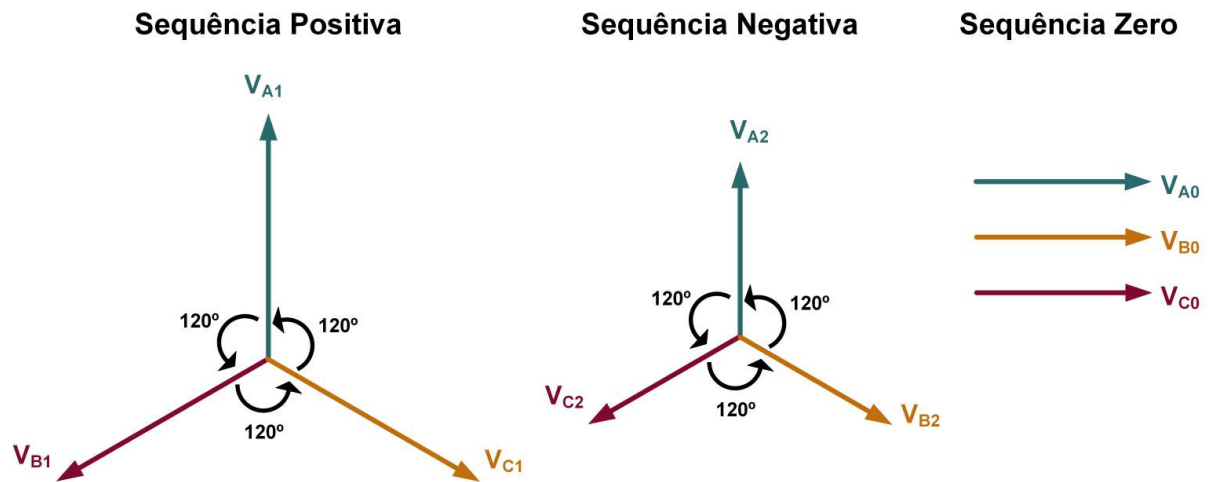
Fonte: Próprio autor

O estudo dos DTs é geralmente realizado usando uma abordagem matemática por meio da teoria das componentes simétricas (FORTESCUE, 1918; KINDERMANN, 1992). Com este método, as tensões desequilibradas são decompostas em três sistemas equilibrados, como mostrado na Figura 10. A sequência positiva e a negativa são compostas por três tensões defasadas em  $120^\circ$  entre si, já a sequência zero é composta de três tensões paralelas. Na representação por componentes simétricas, um sistema só é perfeitamente balanceado se as sequências negativa e zero forem nulas (JOUANNE; BANERJEE, 2001; GOSBELL; PERERA; SMITH, 2002).

Assim sendo, quando a alimentação de MIT apresenta um DT, uma componente de sequência negativa é adicionada na composição das tensões. Como os MITs, em sua maioria, possuem uma alimentação à três fios, não há caminho para as correntes de sequência zero fluírem, portanto, elas podem ser consideradas irrelevantes para esse estudo. Uma maneira de compreender a influência de uma componente negativa, é por meio dos circuitos equivalentes do motor para cada uma das sequências, ilustrados na Figura 11.

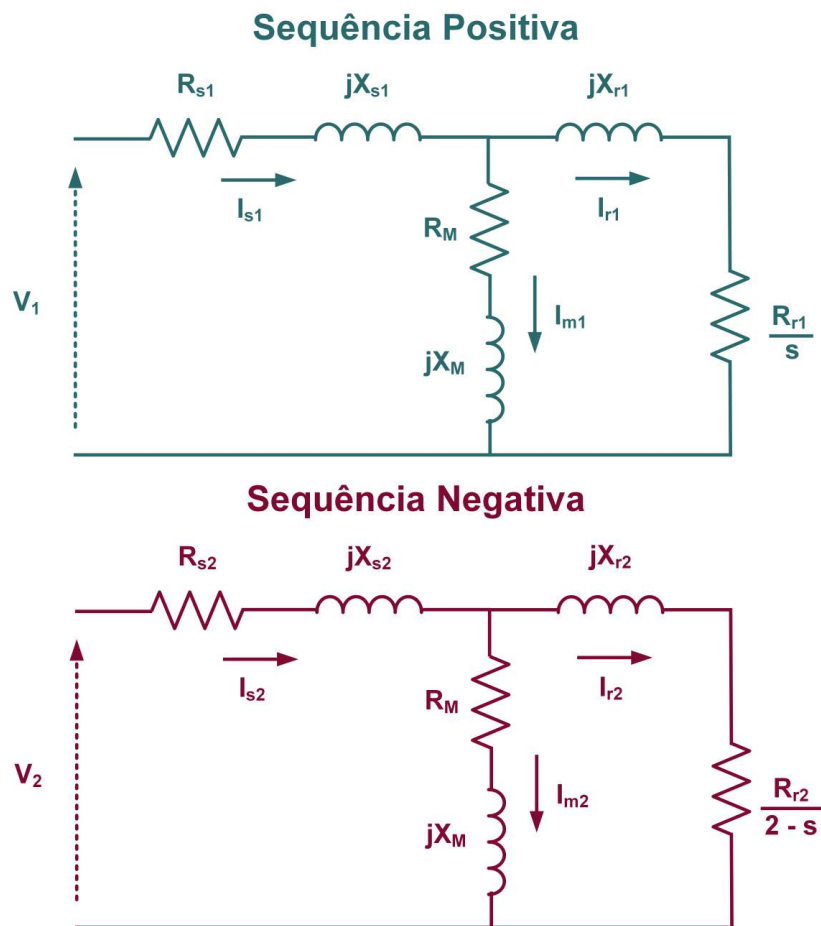
A tensão de sequência positiva  $V_1$ , a tensão de sequência negativa  $V_2$  e a tensão de sequência zero  $V_0$  podem ser calculadas como (AREE, 2016; CHAUHAN; SINGH,

Figura 10 – Componentes simétricas



Fonte: Próprio autor

Figura 11 – Circuito equivalente para sequências positiva e negativa



Fonte: Próprio autor

2019; QUISPE; LOPEZ, 2015; DONOLO; BOSSIO; ANGELO, 2011):

$$\begin{bmatrix} V_1 \\ V_2 \\ V_0 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & \alpha & \alpha^2 \\ 1 & \alpha^2 & \alpha \\ 1 & 1 & 1 \end{bmatrix} \cdot \begin{bmatrix} V_a \\ V_b \\ V_c \end{bmatrix} \quad (2.1)$$

onde  $\alpha$  é o operador  $1\angle 120^\circ$ ;  $R_s$ ,  $X_s$  são a resistência e a impedância do estator;  $R_M$ ,  $X_M$  são a resistência e a impedância de magnetização;  $R_r$ ,  $X_r$  são a resistência e a impedância do rotor;  $I_s$ ,  $I_r$  e  $I_M$  são as correntes de estator, de rotor e de magnetização. Os subscritos 1 e 2 são relativos, respectivamente, a sequência positiva e a sequência negativa.

Utilizando os circuitos equivalentes, nota-se que, assim como na sequência positiva, as tensões de sequência negativa também irão gerar seu próprio torque, suas perdas, sua potência de entrada e sua potência de saída. O torque de cada componente pode ser calculado da seguinte maneira (AREE, 2016; CHAUHAN; SINGH, 2019; QUISPE; LOPEZ, 2015; DONOLO; BOSSIO; ANGELO, 2011):

$$\tau_1 = 3 \left( \frac{I_{r1}^2 R_{r1}}{s\omega_s} \right) \quad (2.2)$$

$$\tau_2 = 3 \left( \frac{I_{r2}^2 R_{r2}}{(2-s)\omega_s} \right) \quad (2.3)$$

onde  $s$  é o escorregamento do MIT e  $\omega_s$  é a sua velocidade síncrona. As perdas ôhmicas no estator e no rotor podem ser calculadas como:

$$P_{ohm,s} = 3.I_{s1}^2.R_{s1} + 3.I_{s2}^2.R_{s2} \quad (2.4)$$

$$P_{ohm,r} = 3.I_{r1}^2.R_{r1} + 3.I_{r2}^2.R_{r2} \quad (2.5)$$

já se considerando as perdas das duas sequências. As potências de entrada são calculadas por:

$$P_1 = V_1.I_{s1}.\cos\varphi_1 \quad (2.6)$$

$$P_2 = V_2 \cdot I_{s2} \cdot \cos\varphi_2 \quad (2.7)$$

onde  $\varphi$  é o fator de potência. Já as potências de saída podem ser obtidas por:

$$P_{m1} = 3 \cdot I_{r1}^2 \cdot \left( \frac{1-s}{s} \right) \cdot R_{r1} \quad (2.8)$$

$$P_{m2} = 3 \cdot I_{r2}^2 \cdot \left( \frac{1-s}{2-s} \right) \cdot R_{r2} \quad (2.9)$$

Portanto, as perdas totais podem ser expressas pela soma das perdas no estator e no rotor expressas nas Equações 2.4 e 2.5:

$$P_{ohm,total} = P_{ohm,s} + P_{ohm,r} \quad (2.10)$$

Da mesma forma, a potência de entrada total é igual a soma das potências de entrada de cada sequência:

$$P_{total} = P_1 + P_2 \quad (2.11)$$

No entanto, como o fluxo gerado pela sequência negativa no entreferro tem sentido contrário ao fluxo de sequência positiva, o torque desenvolvido e a potência de saída total são resultado da subtração entre os valores de cada sequência (DONOLO; BOSSIO; ANGELO, 2011; GOSBELL; PERERA; SMITH, 2002):

$$\tau_{total} = \tau_1 - \tau_2 \quad (2.12)$$

$$P_{m,total} = P_1 - P_2 \quad (2.13)$$

Por fim, analisando as equações expostas nessa seção, conclui-se que o surgimento das sequências negativas tem efeitos não desejados nos MITs. Os danos que são resultado dessas características serão apresentados com maiores detalhes na seção a seguir.

### 2.4.3 Consequências

Nos motores de indução, os impactos causados pelos DTs podem ser irreversíveis. As correntes nos enrolamentos dos MITs chegam a ser de 6 a 10 vezes maiores em relação à proporção do desequilíbrio de tensão. Ou seja, um DT de 5 %, pode gerar um aumento de 30 a 50 % na corrente (JOUANNE; BANERJEE, 2001). Esse fenômeno pode representar significativas repercussões no funcionamento do MIT, pois, como visto na Equação 2.5, as componentes de sequência negativa representam perdas extras para os MITs e que são proporcionais ao quadrado da corrente. Por fim, o aumento das perdas provocam, inevitavelmente, a diminuição da eficiência da máquina.


Dentre os parâmetros analisados em qualidade de energia, o DT é o que mais afeta o aquecimento dos enrolamentos. As correntes desbalanceadas resultantes do desequilíbrio produzem altas temperaturas nas fases dos motores. Essa condição, mesmo que temporária, afeta o isolamento dos condutores e faz com que o processo de envelhecimento da isolação da máquina se acelere. Portanto, sistemas capazes de detectar a ocorrência ocasional são importantes para estender a vida útil da máquina (RAJ; AGARWAL; SRIVASTAVA, 2006; GNACIŃSKI *et al.*, 2019; CAMPBELL; ARCE, 2018).

Como visto na Equação 2.12, as componentes de sequência negativa produzem torques resistentes ao sentido de giro original do motor. Conseqüentemente, o torque total produzido pela máquina diminui. Em razão disto, algumas normas disponibilizam gráficos para superdimensionamento dos motores mais expostos a DTs, já prevendo o efeito de diminuição do torque (Figura 12). De acordo com o nível de tensão esperado (eixo x), a potência nominal do motor escolhido deve ser multiplicada pelos fatores encontrados no gráfico (eixo y).

O torque desenvolvido pela sequência negativa também produz outro efeito adverso: o aumento dos movimentos vibratórios. Ao perturbar a rotação normal do motor, o DT provoca vibrações em frequências diferentes das comumente encontradas nos MITs (duas vezes a frequência de alimentação da máquina) e que podem atingir níveis significantes (CAMPBELL; ARCE, 2016; DONOLO *et al.*, 2016; OLIVEIRA, 2011). Como já comentado, as vibrações mecânicas podem levar à outras falhas ou intensificar falhas que já estavam presentes no motor (CAMPBELL; ARCE, 2018).

Outro ponto negativo da DT é a diminuição da potência de saída, visto na

Figura 12 – Fator de depreciação de Torque para MIT



Fonte: adaptado de NEMA : MG 1-2016 (2016)

Equação 2.13. Este é outro fator que faz com que a eficiência do MIT diminua ainda mais quando submetido à tensões desequilibradas (FAIZ; EBRAHIMPOUR, 2007; ADEKITAN; SAMUEL; AMUTA, 2019).

#### 2.4.4 Definição e normas

De acordo com a Agência Nacional de Energia Elétrica (ANEEL) por meio do documento regulatório: Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) - Módulo 8 - Qualidade da Energia Elétrica, a definição de DT dá-se como:

O desequilíbrio de tensão é o fenômeno caracterizado por qualquer diferença verificada nas amplitudes entre as três tensões de fase de um determinado sistema trifásico, e/ou na defasagem elétrica de 120° entre as tensões de fase do mesmo sistema (ANEEL, 2018, p. 16).

Sendo assim, a mesma norma ainda determina o método necessário para o cálculo da porcentagem de desequilíbrio de tensão:

$$FD\% = \frac{V_-}{V_+} \cdot 100 \quad (2.14)$$

onde  $FD$  é o fator de DT,  $V_-$  é a magnitude da tensão eficaz de sequência negativa e  $V_+$  é a magnitude da tensão eficaz de sequência positiva. Assim como, alternativamente,  $FD$  pode ser calculado como:

$$FD\% = 100 \cdot \sqrt{\frac{1 - \sqrt{3 - 6\beta}}{1 + \sqrt{3 - 6\beta}}} \quad (2.15)$$

onde

$$\beta = \frac{V_{ab}^4 + V_{bc}^4 + V_{ca}^4}{(V_{ab}^2 + V_{bc}^2 + V_{ca}^2)^2} \quad (2.16)$$

sendo que  $V_{ab}, V_{bc}, V_{ca}$  são as tensões eficazes de linha. Por fim, o  $FD\%$  máximo estabelecido durante o funcionamento normal de sistemas até 1 kV é de 3,0%.

Além dos parâmetros nacionais, o cálculo da porcentagem de desequilíbrio de tensão possui algumas variações na literatura internacional. Dependendo das normas utilizadas, o resultado pode apresentar variações. Os três formatos mais conhecidos são: a taxa de desequilíbrio de tensão de linha, do inglês *line voltage unbalance rate* (LVUR); a taxa de desequilíbrio de tensão de fase, do inglês *phase voltage unbalance rate* (PVUR); e o fator de desequilíbrio de tensão, do inglês *voltage unbalance factor* (VUF) (LEE, 1999; QUISPE *et al.*, 2011; JOUANNE; BANERJEE, 2001).

A LVUR (%) é definida em NEMA : MG 1-2016 (2016) e leva em consideração o máximo desvio de tensão de linha em relação a tensão média de linha, deste modo:

$$LVUR = \frac{\text{Max}[|V_{ab} - V_{med}| |V_{bc} - V_{med}| |V_{ca} - V_{med}|]}{V_{med}} \times 100\% \quad (2.17)$$

onde

$$V_{med} = \frac{V_{ab} + V_{bc} + V_{ca}}{3} \quad (2.18)$$

A taxa PVUR (%) também é definida em NEMA : MG 1-2016 (2016) e utiliza o máximo desvio de tensão de fase em relação a tensão média de fase. Pode-se calculá-la da seguinte maneira:

$$PVUR = \frac{\text{Max}[|V_a - V_{med}| |V_b - V_{med}| |V_c - V_{med}|]}{V_{med}} \times 100\% \quad (2.19)$$

onde

$$V_{med} = \frac{V_a + V_b + V_c}{3} \quad (2.20)$$

Já o VUF (%) é um método estabelecido por IEC : 60034-26 (2006) que leva em conta as tensões das componentes simétricas de sequência positiva e negativa obtidas pela Equação 2.1. O cálculo do VUF é dado por:

$$VUF = \frac{V_2}{V_1} \times 100\% \quad (2.21)$$

## Capítulo 3

# Sensores aplicados à detecção de falhas em máquinas elétricas

*Devido à sua relevância, diversas variáveis físicas inerentes aos MITs já foram estudadas com o intuito de realizar diagnósticos de falhas nesses equipamentos. Neste Capítulo, serão abordados sistemas de diagnóstico baseados em sensores capazes de monitorar diferentes tipos de variáveis físicas. Além disso, também será apresentada uma breve introdução sobre alguns pontos chave na área de aquisição de sinais. Por fim, os sensores piezoelétricos, que foram utilizados durante os experimentos realizados na confecção deste estudo, terão sua estrutura e seus princípios de funcionamento detalhados.*

## 3.1 Aquisição de sinais

Antes de se iniciar qualquer tipo de medição utilizando sensores, é importante certificar-se de que o sistema de aquisição de dados esteja adequado para a situação. Isto mitiga os possíveis erros de medição impostos por práticas não adequadas, evitando resultados que podem estar mascarados por interferências externas. Portanto, na realização deste trabalho, foi imprescindível atentar-se aos conceitos descritos a seguir.


### 3.1.1 Subamostragem

Também conhecido como efeito de *aliasing*, a subamostragem é uma preocupação básica no projeto de um sistema de aquisição de sinais. Essa distorção ocorre nos sinais amostrados quando o valor da frequência de amostragem não é suficientemente alto. Quando ocorre, o *aliasing* corrompe a reconstrução do sinal original, gerando um sinal reconstruído que possui uma composição de frequências alterada. Daí vem o

nome *aliasing*, que significa disfarce, ou seja, o sinal reconstruído é uma modificação do sinal original (OPPENHEIM, 1997).

Para demonstrar esse efeito graficamente, pode-se considerar um sinal  $X_c(j\Omega)$  que tem uma banda limitada  $X_c(j\Omega) = 0$  para  $|\Omega| \geq \Omega_N$  e que é representado na frequência como mostrado na Figura 13.

Figura 13 – Espectro de frequência do sinal  $X_c(j\Omega)$




Fonte: adaptado de Oppenheim (2010)

considerando, também, um trem de impulsos periódico  $S(j\Omega)$  definido por:

$$S(j\Omega) = \frac{2\pi}{T} \sum_{k=-\infty}^{\infty} \delta(\Omega - k\Omega_s) \quad (3.1)$$

onde  $\delta$  é a função impulso unitário e  $\Omega_s$  é a frequência de amostragem. Esse sinal tem a representação na frequência como mostrado na Figura 14.


Figura 14 – Espectro de frequência do sinal  $S(j\Omega)$



Fonte: adaptado de Oppenheim (2010)

Agora, amostrando o sinal  $X_c(j\Omega)$  pelo trem de impulsos  $S(j\Omega)$ , tem-se a representação do sinal amostrado  $X_s(j\Omega)$  como na Figura 15.


Figura 15 – Espectro de frequência do sinal  $X_s(j\Omega)$



Fonte: adaptado de Oppenheim (2010)

Nota-se que a amostragem gerou múltiplas cópias do espectro do sinal  $X_c(j\Omega)$  original, no entanto, ainda é possível recuperá-lo utilizando um filtro passa baixas com frequência de corte  $\Omega_N$ . Porém, é importante notar que a distância entre cada cópia do sinal amostrado é igual a  $\Omega_s$ . Portanto, se  $\Omega_s < 2\Omega_N$ , haverá uma distorção irreversível do espectro do sinal amostrado  $X_s(j\Omega)$ , como demonstrado na Figura 16 (OPPENHEIM, 2010).

Figura 16 – Espectro de frequência do sinal  $X_s(j\Omega)$  com  $\Omega_s < 2\Omega_N$



Fonte: adaptado de Oppenheim (2010)

Este parâmetro é conhecido como Teorema da amostragem de Nyquist-Shannon que constata que a frequência de amostragem do sistema de aquisição de dados precisa, obrigatoriamente, ser duas vezes maior do a maior frequência que compõe o sinal original. Resumindo, o sinal  $x_c(t)$  só será fielmente representado por  $x[n] = x(nT)$ ,  $n = 0, \pm 1, \pm 2, \dots$ , se:

$$\Omega_s = \frac{2\pi}{T} \geq 2\Omega_N \quad (3.2)$$

Em consequência do *aliasing*, muitas vezes é necessário o uso de filtros *anti-aliasing*, que têm o objetivo de extinguir frequências do sinal de entrada que estão acima da capacidade da frequência de amostragem do sistema de aquisição de dados. Por fim, a metodologia utilizada neste trabalho foi concebida de maneira que as distorções causadas pelo *aliasing* não se manifestassem, assim como descrito no Capítulo 5.

### 3.1.2 Ruídos no sistema de medida

Ruídos podem ser definidos como qualquer distúrbio não desejado em um sinal. O parâmetro mais utilizado para medir a influência de um ruído no sinal original é a relação sinal/ruído ou, do inglês, *signal to noise ratio* (SNR). A SNR pode ser calculada em *dB* como a razão da variância (potência) do sinal ( $\sigma_S^2$ ) pela variância do ruído ( $\sigma_R^2$ ) (LATHI, 1998):

$$SNR = 10 \log_{10} \left( \frac{\sigma_S^2}{\sigma_R^2} \right) \quad (3.3)$$

Alguns das principais fontes de ruídos são (LATHI, 2003; OTT, 1976):

- a) **Ruído térmico:** devido a geração de cargas elétricas nos condutores em razão do movimento aleatório dos elétrons pelo efeito térmico. Esse ruído é categorizado como ruído branco, ou seja, tem uma densidade espectral constante para todas as frequências.
- b) **Ruído de quantização:** geralmente, nas aquisições de sinais, utiliza-se um conversor analógico/digital. Esses conversores tem como uma de suas características o número de bits utilizados para converter o sinal analógico para um valor digital. Esse número não é infinito, portanto, existe uma precisão máxima de tensão no momento da conversão. Essa precisão pode ser calculada pela divisão do valor máximo de entrada do conversor dividida pelo numero de bits do conversor ( $V_{max}/N_{bit}$ ).
- c) **Ruído de contato:** provocado pela transição entre dois tipos de materiais condutores diferentes. Esse ruído é conhecido por ter uma densidade

espectral de potência inversamente proporcional à frequência do sinal original ( $1/f$ ), esse tipo de ruído é chamado de ruído rosa.

- d) **Ruído *burst***: é um ruído comum em circuitos com circuitos integrados. É causado por impurezas presentes nas junções dos materiais semicondutores e pode ser atenuada por meio de um processo de fabricação melhorado. Está relacionado diretamente com o valor da corrente e sua amplitude é muitas vezes maior do que a dos ruídos causados pelo efeito térmico, embora sua frequência seja de valor baixo.

Adicionalmente, é importante notar que, além dos ruídos, os sinais também estão expostos as interferências externas como campos eletromagnéticos e eletrostáticos. Por esse motivo, os cabos que transmitem os sinais precisam ter a blindagem e o aterramento necessários. Por fim, todas as precauções tomadas para evitar os ruídos e interferências descritos foram listados no Capítulo 5.1.2.

## 3.2 Sistemas baseados em sensores de tensão

Apesar de ser uma das principais variáveis das máquinas elétricas por fornecer o torque necessário para a rotação, os sensores de tensão não são os mais aplicados nos sistemas que realizam diagnósticos de falhas em máquinas elétrica. Contudo, encontram-se estudos que utilizam a tensão induzida em bobinas que são colocadas próximas ao motor ou junto aos seus enrolamentos como sinal de entrada para um sistema que detecta falhas nessas máquinas (MENZHI; SAAD, 2009; FIRETEANU; TARAS, 2012).

No entanto, em dispositivos de proteção como relés o sinal de tensão é muito utilizado. Além disso, o uso de medidores de tensão elétrica é amplamente aplicado nos ambientes industriais utilizando-se mostradores alocados em centros de comando de motores (CCMs) e nos sistemas supervisórios. Neste caso, é utilizado por técnicos como um parâmetro para uma análise rápida da normalidade na alimentação elétrica das máquinas (Figura 17). Um sensor de tensão pode ser elaborado de maneira simples, por intermédio de um transformador de isolamento e um amplificador operacional (FAIZ; EBRAHIMPOUR, 2007).

Figura 17 – Multimetro para porta de painéis



Fonte: Siemens (2020)

### 3.3 Sistemas baseados em sensores de corrente

A análise das correntes do estator do MIT é uma ferramenta muito comum para diagnósticos de falha. O termo análise de assinatura da corrente da máquina, do inglês, *machine current signature analysis* (MCSA), indica o estudo das correntes de alimentação do MIT como meio para gerar diagnósticos de falhas elétricas e mecânicas. Estes estudos se baseiam no fato que as anomalias presentes nos motores modificam, de alguma forma, o comportamento das correntes nos MITs, permitindo sua identificação. As correntes, na maioria das instalações, podem ser facilmente medidas nos painéis de alimentação, sendo assim, são muito aplicadas em sistemas que utilizam TNIs (FAIZ; EBRAHIMPOUR, 2007).

Os sensores de corrente podem ser divididos em diferentes tipos. O método mais simples é mediante o uso de um resistor *shunt*. Onde um resistor de valor ôhmico reduzido é percorrido pela corrente a qual pretende-se medir. Conhecendo seu valor de resistência, pode-se medir a queda de tensão nesse componente e, indiretamente, obter o valor da corrente. Esse método, apesar de ainda ser muito utilizado em equipamentos mais simples, é o que consome mais energia e gera aquecimento, principalmente para correntes maiores. Desta forma, seu uso pode ser impraticável em muitos casos, conseqüentemente, não é muito comum nas aplicações envolvendo diagnósticos de máquinas (RIPKA, 2010).

Outro tipo de sensores de corrente são os transformadores de corrente (TC), que


utilizam o mesmo princípio de indução de outros tipos de transformadores. Conhecendo-se a relação de transformação do TC, assim como no resistor shunt, possibilita a medição da corrente de forma indireta pela medição de tensão nos seus terminais. Possuem vantagens como a simplicidade de funcionamento, isolamento galvânico e ausência de fontes externas. Por outro lado, os TCs não são sensíveis as correntes contínuas e, dependendo do nível de corrente, podem ter se tornar estruturas mais complexas e com custo e tamanho elevados (RIPKA, 2010; VOLOKHIN; DIAHOVCHENKO, 2017). Contudo, são muito utilizados na forma de garras de corrente (Figura 18a), inclusive no estudo de falhas em MITs (ALI *et al.*, 2019).

Os sensores de corrente de Efeito Hall, têm o funcionamento baseado na tensão Hall, fenômeno descoberto por Hall (1879). De maneira simplificada, o Efeito Hall é definido pela manifestação de uma diferença de potencial (ddp) em um material condutor percorrido por uma corrente e exposto a um campo magnético, essa ddp será proporcional ao campo magnético que atravessa o material. A simplicidade, a capacidade de medir correntes contínuas/alternadas e a possibilidade de encapsulamento desses dispositivos, forneceu aos sensores de corrente de Efeito Hall alta aplicabilidade. Esses dispositivos também possuem alta precisão e sua resposta em frequência pode chegar até 100 kHz. Por esses motivos, muitos estudos que se utilizam da MCSA fazem uso de garras de corrente (Figura 18b) baseadas nesses sensores (CHEN; FENG, 2019; MARTIN-DIAZ *et al.*, 2018; CHEN; FENG, 2020). No entanto, é importante notar que o sensor de Efeito Hall é um sensor ativo, ou seja, precisa de alimentação externa.

Ainda, a bobina de Rogowski é um sensor de corrente projetado para detectar altas frequências em sinais de duração muito curta. Esse sensor não é tão comum no diagnóstico de máquinas elétricas, no entanto, alguns estudos já foram publicados utilizando-o (PONCELAS *et al.*, 2009; GHANBARI; FARJAH, 2014).

Por fim, no estudo dos DTs, os sensores piezoelétricos representam uma solução de volume e custo inferiores aos sensores comerciais de corrente, ainda mantendo a característica de técnica não invasiva para diagnóstico da falha.

Figura 18 – Sensores de corrente. a) baseado em TC; b) baseado em Efeito Hall



Fonte: Fluke (2020c) e Fluke (2020b)

### 3.4 Sistemas baseados em sensores de fluxo

O fluxo magnético é o responsável por transferir a potência do estator para o rotor. Portanto, qualquer falha que ocorrer nesses componentes será refletido de um para outro pelo fluxo (FAIZ; EBRAHIMPOUR, 2007). Isto faz com que o fluxo magnético seja uma grandeza relevante no estudo das falhas em MITs.

O princípio básico para se obter um sensor de fluxo é a construção de uma bobina. No entanto, como o entreferro é uma área de difícil acesso, nem sempre é possível medir com precisão essa grandeza. A partir dessa problemática, autores e empresas desenvolveram diferentes soluções. Alguns autores resolveram este empecilho posicionando as bobinas em partes externas ao motor, outros desenvolveram bobinas extremamente finas para serem alocadas no estreito espaço do entreferro e, por fim, alguns infiltraram, junto aos enrolamentos do estator, bobinas especiais para medir o fluxo.

É importante notar que as soluções que envolvem sensores internos, são práticas invasivas. Além das bobinas, os sensores baseados no Efeito Hall também são utilizados para medir o fluxo magnético (Figura 19), no entanto, encontram as mesmas dificuldades estruturais (HAN *et al.*, 2008; CHERNYAVSKA; VITEK, 2017; FULNECCK; MISAK, 2018).

Ao contrário do que ocorre nos sensores piezoelétricos, as dificuldades encontradas no posicionamento dos sensores de fluxo magnético inviabilizam muitas

Figura 19 – Fluxômetro baseado no Efeito Hall



Fonte: Magnets (2020)

vezes a sua aplicação como TNI, o que pode representar a inviabilização para muitas aplicações.

### 3.5 Sistemas baseados em sensores de temperatura

Como comentado anteriormente, muitas das falhas que acometem as máquinas elétricas geram aquecimentos excessivos. Deste modo, é natural que os sensores de temperatura sejam usados nas detecções de falhas em MITs. Todavia, poucos trabalhos utilizam esses sensores como ferramenta para diagnóstico online em motores. Pois, mesmo indicando uma provável falha, os sensores de temperatura ou são invasivos ou não conseguem distinguir com precisão qual falha está presente no MIT. Este fato não suprime o amplo uso desses equipamentos em atividades de manutenção preventiva e preditiva de máquinas e instalações elétricas, que buscam indícios precoces da existência de falhas (SAAD, 2018).

Em geral, existem quatro tipos de sensores de temperatura utilizados para manutenção de motores e instalações elétricas: os sensores baseados na variação da

resistência de um condutor quando submetido a diferentes temperaturas (Figura 20a); os termopares, que se baseiam na diferença de potencial produzida pelo aquecimento da junção de dois metais diferentes (Figura 20b); as câmeras termográficas que captam a emissão infravermelha emitida por corpos proporcionalmente a sua temperatura (Figura 20c); e os sensores de temperatura a laser (Figura 20d).

Figura 20 – Sensores Térmicos. a) Termoresistor; b) Termopar; c) Câmera Térmica; d) Termômetro Laser



Fonte: Fluke (2020f), Fluke (2020d), Fluke (2020a), Fluke (2020e)

Por fim, uma vez que os sensores térmicos não tem a precisão necessária para distinguir com precisão magnitudes e origens de falhas como o DT, esses dispositivos não são adequados para a análise desenvolvida neste trabalho.

### 3.6 Sistemas baseados em sensores de vibração


Os movimentos vibratórios dos motores de indução podem ter várias fontes, dentre elas, as falhas que afetam os MITs. As vibrações podem ocorrer por causa de imperfeições mecânicas ou em consequência de forças magnéticas desbalanceadas geradas por algum desequilíbrio nas correntes do motor. São exemplos comuns: falhas nos rolamentos, desalinhamento/desbalanceamento, desequilíbrio de tensão, barras quebradas e harmônicas (FAIZ, 2017). Esse comportamento faz com que a análise de vibração seja uma das técnicas mais empregadas nos diagnósticos de motores. É importante lembrar que, mesmo em funcionamento normal, os MITs possuem certos

níveis de vibração. No entanto, existem níveis toleráveis pré-estabelecidos nas normas, por exemplo, em IEC : 60034-14 (2011).

Os sensores mais utilizados para análise da vibração são os acelerômetros. Esses dispositivos possuem a vantagem de não serem sensores invasivos, porém, os acelerômetros comerciais são equipamentos de custo elevado (SAAD, 2018). Apesar de seu alto custo, esses sensores são amplamente aplicados nos estudos acerca de inúmeros tipos de falhas mecânicas e elétricas (ALI *et al.*, 2019; LU *et al.*, 2018; CRISTALLI; PAONE; RODRÍGUEZ, 2006; SON *et al.*, 2016).

Os acelerômetros podem ser fixados permanentemente nos MITs ou serem utilizados como dispositivos móveis, permitindo a análise de várias máquinas com apenas um sensor. Ainda, podem ter naturezas distintas como os acelerômetros do tipo *Micro-Electro-Mechanical Systems* (MEMS) (Figura 21a) (SCHIEWALDT *et al.*, 2019), os acelerômetros piezo-resistivos (Figura 21b) (HAN *et al.*, 2018) e os acelerômetros piezoelétricos (Figura 21c) (DROZG *et al.*, 2018).

Figura 21 – Sensores Térmicos. a) Sensor MEMS; b) Sensor Piezo-resistivo; c) Sensor Piezoelétrico



Fonte: Analog Devices (2010), Meggitt Sensing (2020), Schenck (2020)

Apesar de serem sensores capazes de realizar diagnósticos de forma não destrutiva, o uso de sistemas que utilizam acelerômetros nem sempre são viáveis devido ao seu custo, o que justifica a aplicação dos sensores piezoelétricos para o estudo dos DTs.

## 3.7 Demais sensores

Alguns outros sensores de grandezas físicas relacionadas aos motores podem ser citados:

- a) **Sensores de velocidade:** são encontrados no formato de *encoders* ou ta-cógrafos. Podem ser elementos acoplados permanentemente ou portáteis e sua função é mensurar a velocidade angular dos MITs.
- b) **Sensores de torque:** assim como os sensores de velocidade, é possível encontrar torquímetros que trabalham de maneira invasiva e não invasiva. Geralmente, esses dispositivos são acoplados ao eixo do motor com o objetivo de medir o torque exercido pela máquina.
- c) **Análise química:** essa análise não representa um sensor específico, porém, a análise química de óleos, lubrificantes, gases e esmaltes presentes nas máquinas elétricas também é utilizada com certa frequência (principalmente em transformadores) com o intuito de investigar as suas falhas.

## 3.8 Sensores Piezoelétricos

Esta seção contém o embasamento teórico que elucida e justifica a aplicação dos sensores piezoelétricos de baixo custo nos experimentos realizados para esta dissertação.


### 3.8.1 Piezoeletricidade

A piezoeletricidade é uma interação eletromecânica observada em certos cristais dielétricos. Esse fenômeno linear acontece de forma reversível, ou seja, uma tensão mecânica em uma cápsula dielétrica faz com que apareçam cargas elétricas em suas extremidades, contudo, se aplicada uma diferença de potencial aos seus terminais, o resultado será uma deformação mecânica na cápsula. Os exemplos de dielétricos utilizados na produção de sensores são: cristal de quartzo, o fosfato de gálio e a turmalina (GAUTSCHI, 2002).

O efeito piezoelétrico, descoberto por Curie & Curie (1880), elucida a capacidade dessas cápsulas de atuarem como transdutoras das emissões acústicas produzidas

por um motor em movimento. Este efeito pode ser observado, por exemplo, em um cristal de quartzo. Na Figura 22, nota-se que um átomo de silício ( $S_i$ ) e dois átomos de oxigênio ( $O_2$ ) se alternam na composição da estrutura do cristal. Portanto, uma célula de cristal de quartzo possui três átomos de silício e seis átomos de oxigênio (FRADEN, 2016).

Figura 22 – Cristal de quartzo sob ação de forças no eixo x. a) Cristal estático; b) Cristal comprimido; c) Cristal tracionado




Fonte: adaptado de Fraden (2016)

Em termos de balanço de cargas, cada átomo de silício possui quatro cargas positivas e cada átomo de oxigênio possui duas cargas negativas. Logo, em condições normais, a célula de cristal de silício é eletricamente neutra (Figura 22a). No entanto, se força  $F_x$  é aplicada no sentido de compressão da estrutura, os átomos se rearranjam. Sendo assim, as cargas positivas se movimentam para a parte superior da célula e cargas negativas para a parte inferior (Figura 22b). Por fim, se outra força  $F_x$  for aplicada, desta vez, impondo uma força de tração no cristal, um novo arranjo de cargas será observado. Sendo que a maioria das cargas negativas se deslocarão para a parte superior da célula e cargas positivas para parte inferior (Figura 22c) (FRADEN, 2016).

Para a compreensão do modelo de comportamento dos materiais piezoelétricos, é possível utilizar um capacitor de placas paralelas, como o da Figura 23.

O dielétrico entre as placas paralelas do capacitor, inicialmente, não é um material piezoelétrico. A Lei de Hooke mostra que, ao se exercer uma força  $F$ , serão produzidas uma deformação  $S$  e uma tensão mecânica  $T$  no material. E a relação

Figura 23 – Capacitor sob ação de força mecânica



Fonte: adaptado de Fraden (2016)

entre elas dá-se do seguinte modo (ARNAU, 2008):

$$S = sT \quad (3.4)$$

onde  $s$  representa o tensor de elasticidade do material.

Quando aplicada uma diferença de potencial nos terminais do capacitor, um campo elétrico  $E$  surgirá e, conseqüentemente, um fluxo  $D$  poderá ser observado, assim como descrito abaixo (ARNAU, 2008):

$$D = \varepsilon_0 E + P \quad (3.5)$$

onde  $D$  é a densidade de fluxo elétrico,  $\varepsilon_0$  a permissividade no vácuo, cujo valor é  $8,85 \text{ pF/m}$ , e  $P$  o vetor polarização.

Agora, se o dielétrico em questão for considerado um material dielétrico, é possível fazer uma relação entre suas variáveis de natureza elétrica e mecânica. De acordo com o critério da energia livre Gibbs, se forem desconsiderados efeitos térmicos

e magnéticos, o modelo de comportamento desse material pode ser retratado como (ARNAU, 2008):

$$S = s^E T + dE \quad (3.6)$$

$$D = dT + \varepsilon^T E \quad (3.7)$$

considerando  $s^E$  como constante de conformidade elástica em um campo eléctrico constante,  $d$  como a constante dieléctrica e  $\varepsilon^T$  como a constante de permissividade dieléctrica (ARNAU, 2008). Por fim, admitindo os subscritos  $i, j, k$  e  $l$  para representar o sistema natural de coordenadas dos materiais piezoelétricos tem-se (CASTRO *et al.*, 2017):

$$S_{ij} = s_{ijkl}^E T_{kl} + d_{kij} E_k \quad (3.8)$$


$$D_i = d_{ikl} T_{kl} + \varepsilon_{ik}^T E_k \quad (3.9)$$

Finalmente, a tensão eléctrica produzida nos cristais pode ser obtida por eletrodos dispostos em suas extremidades, tornando-se assim possível o seu uso como transdutor.

### 3.8.2 Sensores piezoelétricos de baixo custo

Os sensores piezoelétricos utilizados neste trabalho possuem o formato de um diafragma compostos por um núcleo de cerâmica piezoelétrica e dois eletrodos em suas extremidades, para possibilitar a medição de tensão. Como visto na Figura 24, o sensor é constituído de um disco fino de cerâmica, alocado sobre um eletrodo circular de latão e coberto por um fino eletrodo de prata. Também são chamados de diafragmas PZT (titanato zirconato de chumbo), devido a composição química da cerâmica piezoelétrica, que, de acordo com Fraden (2016), é um dos materiais mais populares para produção desses transdutores, representado pela fórmula química:  $Pb(Zr, Ti)O_3$ .

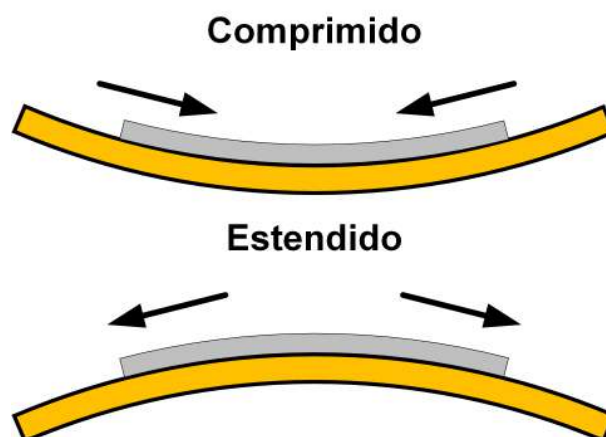
Figura 24 – Cristal piezoelétrico com eletrodos



Fonte: adaptado de Murata (2020)

Ao serem expostos a ondas mecânicas, como as acústicas, esses diafragmas experimentam forças de tração e compressão (Figura 25), originando tensões elétricas como demonstrado na Figura 22. Isto permite que estes dispositivos sejam usados como sensores de EA, com capacidade de traduzir em sinais elétricos as emissões características de cada anormalidade à qual o MIT está sujeito.

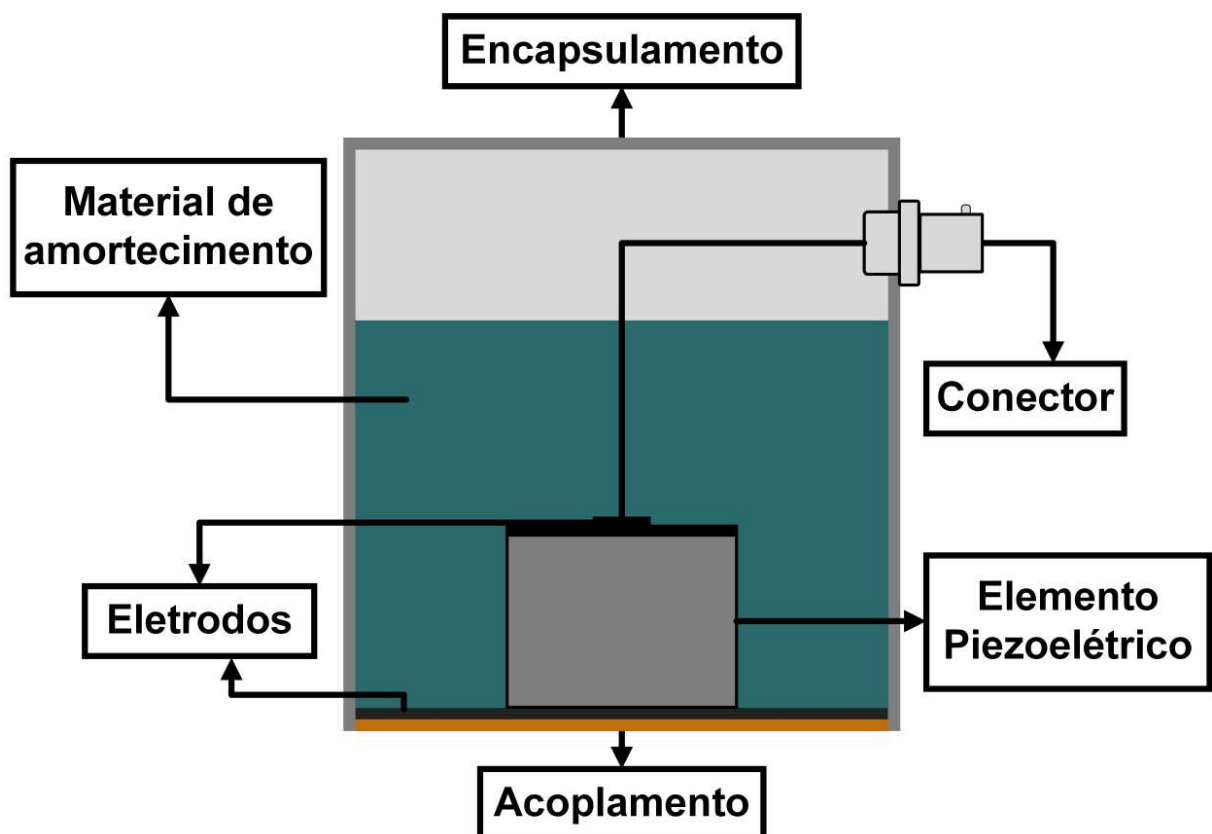
Figura 25 – Forças de tração e compressão no diafragma piezoelétrico



Fonte: Próprio autor

Os sensores já disponíveis comercialmente são baseados, em sua maioria, em materiais piezoelétricos. No entanto, ao contrário do diafragma de baixo custo, no sensor comercial, esse material piezoelétrico está encapsulado em um envoltório especial, o qual é acoplado à superfície do equipamento a ser monitorado. O aspecto construtivo básico de um sensor de emissão acústica pode ser visto na Figura 26 e um exemplo de sensor comercial real na Figura 27. O encapsulamento metálico evita interferências externas e o material de amortecimento influencia na resposta em frequência desejada para o sensor (INSPECT, 2016). Apesar de apresentarem bons resultados comprovados pela bibliografia, estes sensores se mostram dispendiosos (na ordem de milhares de reais) e podem se tornar um empecilho na aplicação da emissão acústica como TNI no monitoramento de máquinas elétricas (MARUTHI; HEGDE, 2016; VAIMANN *et al.*, 2018; CASTRO *et al.*, 2017).

Figura 26 – Estrutura de um sensor comercial de emissão acústica



Fonte: Próprio autor

Figura 27 – Sensor comercial de emissão acústica



Fonte: Physical Acoustics (2020)

Contudo, além da sensibilidade aos sinais acústicos, os diafragmas piezoelétricos são conhecidos por serem alternativas de baixo custo (na ordem de centavos de real) para implementações de sistemas de monitoramento dos sinais de EA (CASTRO; BAPTISTA; CIAMPA, 2019; LUCAS *et al.*, 2020), características que motivaram sua aplicação neste trabalho. Os detalhes de como esses sensores foram posicionados e de como os seus sinais foram adquiridos estão dispostos no Capítulo 5.1.2.

## Capítulo 4

# Técnicas de processamento de sinais no diagnóstico de falhas em máquinas elétricas

*Uma vez apresentadas as falhas que acometem as máquinas elétricas e os sensores capazes de mensurar as suas grandezas físicas, este Capítulo irá discorrer sobre as técnicas de processamento utilizadas na análise dos sinais adquiridos pelos sensores e, conseqüentemente, no diagnóstico das falhas. As técnicas de processamento são abordagens matemáticas aplicadas aos sinais com o intuito de extrair informações úteis utilizando índices, filtros e parâmetros. Sendo assim, as técnicas utilizadas neste trabalho: energia, taxa de cruzamento por zero e Transformada Wavelet, foram ferramentas fundamentais para que se alcançasse o escopo proposto. Por fim, como a grande maioria dos trabalhos de diagnóstico é baseada nos sinais digitais amostrados por sistemas de aquisição de dados, as técnicas serão abordadas a partir das teorias de processamento digital de sinais.*

### 4.1 Técnicas de análise no domínio do tempo

Nesta seção, serão expostas algumas métricas utilizadas para o monitoramento de máquinas elétricas e que são baseadas na representação dos sinais no domínio do tempo. Apesar de bastante utilizadas, essas técnicas possuem uma capacidade limitada para as análises mais complexas no diagnóstico de máquinas.

#### 4.1.1 Valor máximo e RMS

O valor máximo (VM) e o valor eficaz, do inglês, *root mean square* (RMS), são medidas estatísticas polivalentes e que são utilizadas em diversas áreas da engenharia elétrica.

O valor máximo de um sinal digital é uma métrica simples de ser obtida, porém, pode ser utilizada como um valor limiar no monitoramento de máquinas, como definido nas normas: IEC : 60034-26 (2006), IEC : 60034-14 (2011), NEMA : MG 1-2016 (2016). Isto porque, uma vez que um valor de uma grandeza como corrente, tensão, vibração ultrapasse o valor considerado saudável, pode indicar a presença de uma falha no equipamento.

Na Engenharia Elétrica, os valores RMS de tensão e corrente são largamente utilizados em cálculos, projetos, dimensionamentos e na indicação de valores nominais de equipamentos. No entanto, em termos gerais, o valor RMS é uma métrica estatística que representa a amplitude média do módulo dos valores de um sinal qualquer, ou seja, sua magnitude (FREEDMAN, 1998; DAINTITH, 2009). O valor RMS pode ser obtido por:

$$V_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x[i]^2} \quad (4.1)$$

que descreve a equação para amostras discretas, onde  $N$  é o número de amostras e  $x[n]$  é o valor da  $n$ -ésima amostra do sinal (DAINTITH, 2009).

Devido a sua capacidade de estudar as magnitudes dos sinais, o valor RMS já foi utilizado para monitorar parâmetros operacionais e diagnosticar falhas em MITs (RIBEIRO *et al.*, 2019; LUCAS *et al.*, 2018; LUCAS *et al.*, 2019).

#### 4.1.2 Energia

A energia de um sinal é uma métrica muito utilizada no processamento de sinais, principalmente para os não estacionários. Seu valor pode ser obtido por (BOASHASH, 2016):

$$E = \sum_{n=1}^N |x[n]|^2 \quad (4.2)$$

onde  $N$  é o número de amostras e  $x[n]$  é o valor da  $n$ -ésima amostra do sinal.

Quando uma falha ocorre em máquinas elétricas, a energia dos sinais acústicos, de corrente, de vibração e outras grandezas sofrem variação, isso faz com que o estudo

desses sinais possa resultar no diagnóstico de falhas em MITs. Sendo assim, inúmeros estudos utilizaram os valores de energia dos sinais de diferentes grandezas com este intuito (ZHAO; XU, 2018; LUO *et al.*, 2016; SINGH; PAREY, 2017).

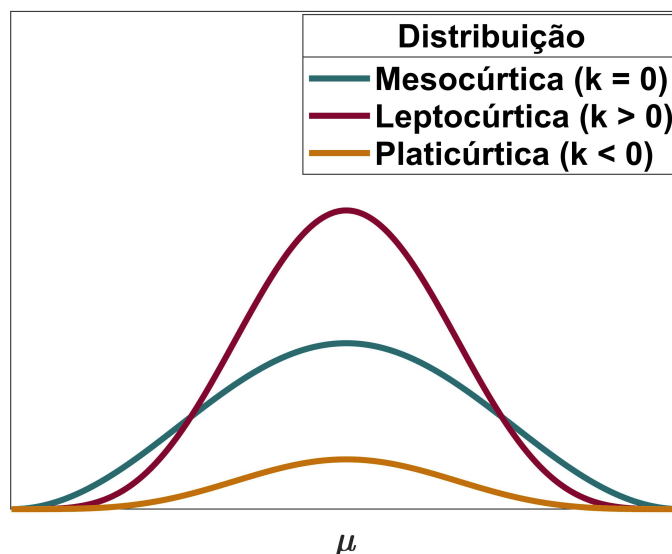
#### 4.1.3 Curtose e Assimetria

A Curtose é uma medida estatística adimensional que retrata o desvio de um sinal em comparação a função distribuição de probabilidade. Ou seja, estima quão achatado ou comprimido o sinal está em relação a distribuição normal (Figura 28). Trabalhos anteriores provaram que a Curtose pode ser uma ferramenta eficiente em diagnóstico de falhas em motores de indução (ZHAO; WANG, 2019; WANG *et al.*, 2019a). Seu valor pode ser obtido pela Equação (KARMAKAR, 2016):

$$K = \frac{\sum_1^N (x[n] - \bar{x})^4}{(N - 1)\sigma^4} - 3 \quad (4.3)$$

onde  $N$  é o número de amostras,  $x[n]$  é o valor da  $n$ -ésima amostra do sinal,  $\bar{x}$  é o valor médio de  $x$  e  $\sigma$  é o desvio padrão do sinal. Sendo que, se o valor de  $K$  for igual a zero, sua distribuição é mesocúrtica, se for menor que zero é definida como platicúrtica e se for maior que zero leptocúrtica.

Figura 28 – Representação das distribuições de acordo com o valor de Curtose



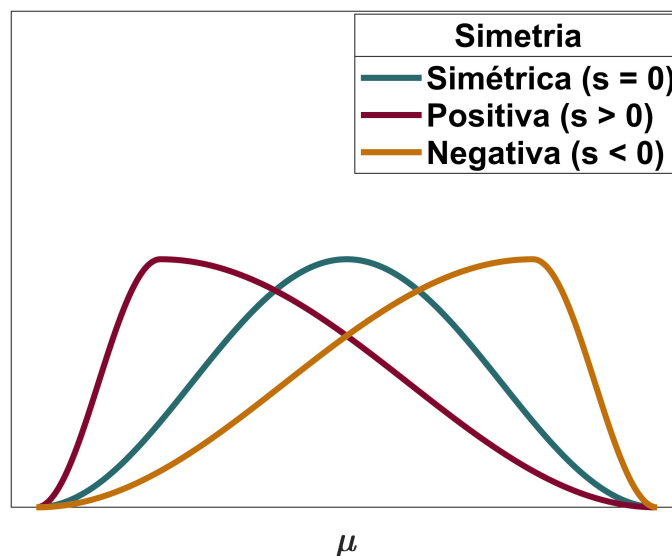
Fonte: adaptado de Freedman (1998)

A Assimetria é a medida que aponta para o deslocamento para esquerda ou para direita do pico da distribuição normal (Figura 29). Essa métrica também já foi utilizada com sucesso em outros trabalhos que buscavam monitor falhas em máquinas elétricas (STEPANIC; LATINOVIC; DJUROVIC, 2009). O seu valor é calculado por

$$S = \frac{\sum_1^N (x[n] - \bar{x})^3}{(N - 1)\sigma^3} \quad (4.4)$$

onde  $N$  é o número de amostras,  $x[n]$  é o valor da  $n$ -ésima amostra do sinal,  $\bar{x}$  é o valor médio de  $x$  e  $\sigma$  é o desvio padrão do sinal. Sendo que, se o valor de  $K$  for igual a zero, sua distribuição é simétrica, se for menor que zero é definida como negativa e se for maior que zero positiva.

Figura 29 – Representação da simetria de acordo com o valor de Assimetria



Fonte: adaptado de Freedman (1998)

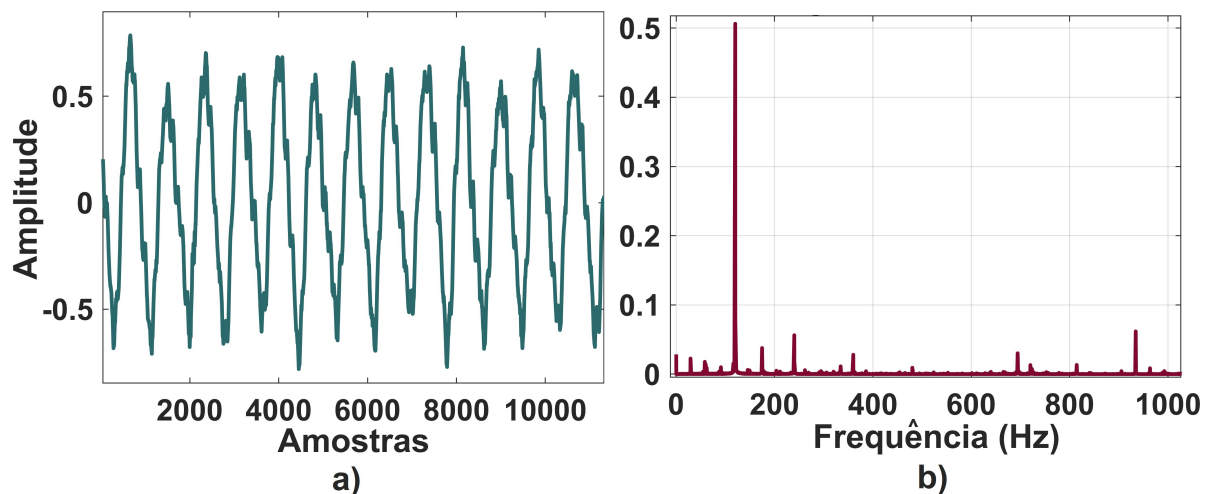
## 4.2 Técnicas de análise no domínio da frequência

A análise dos sinais no domínio da frequência é a abordagem mais comum nos trabalhos que envolvem diagnósticos em máquinas elétricas. Por meio do espectro do sinal, identificam-se as falhas específicas cujas as frequências já são conhecidas pela literatura deste tema. Deste modo, esta seção vai apresentar as técnicas de processamento comumente aplicadas para análise no domínio da frequência.

### 4.2.1 Transformada de Fourier

O trabalho apresentado por Fourier (1807), demonstrou que qualquer sinal pode ser decomposto por uma série de sinais senoidais. Mais tarde, esse trabalho resultou no desenvolvimento da Transformada de Fourier (TF). Essa ferramenta matemática é considerada uma das mais relevantes no campo de processamento de sinais, pois, é capaz de transformar uma função do domínio do tempo, para o domínio da frequência. Com isso, é obtêm-se os chamados espectros dos sinais, que indicam as frequências que os compõem (Figura 30).

Figura 30 – Representação do sinal no domínio do tempo e no domínio da frequência. a) Domínio do tempo; b) Domínio da frequência



Fonte: Próprio autor

Como já visto antes, cada falha possui sua assinatura específica e, muitas vezes, essa assinatura só pode ser enxergada no domínio da frequência. Para calcular a função  $X(f)$  no domínio da frequência a partir do sinal  $x(t)$  no domínio do tempo, pode-se utilizar a forma da TF (FAIZ; EBRAHIMPOUR, 2007; ARATO, 2004):

$$X(j\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (4.5)$$

onde  $\omega$  é a frequência angular igual a  $2\pi f$

Contudo, como já mencionado, ao se trabalhar com sinais discretos, é necessário a versão da TF para sistemas discretos: a Transformada de Fourier de tempo discreto. Que é definida por (OPPENHEIM, 1997):

$$X(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x[n]e^{-j\omega n} \quad (4.6)$$

Já nos softwares para processamento de sinais, para maximizar a eficiência computacional, é utilizado o algoritmo desenvolvido por Brigham & Morrow (1967), denominado Transformada Rápida de Fourier (TRF).

Nos MITs, diversas falhas já foram associadas a certos valores de frequência. São exemplos as barras quebradas, as falhas nos enrolamentos, as falhas em rolagens e excentricidade no entreferro (GANGSAR; TIWARI, 2020). Além disso, são encontrados estudos com sinais provenientes de diferentes tipos de sensores onde se aplica a TF (YANG *et al.*, 2016; ROMERO-TRONCOSO, 2017; RIVERA-GUILLEN *et al.*, 2018; GANDHI; TURK; DAHIYA, 2020). Por outro lado, devido às senóides utilizadas na aplicação da TF, essa ferramenta não apresenta bons resultados na análise de sinais não-estacionários e transitórios, ou seja, sinais que possuem diferentes frequências ao longo do tempo ou que se manifestam em curtos períodos de tempo, como na ocorrência de DTs de caráter transitório. Neste caso, as técnicas no domínio tempo-frequência são as mais indicadas.

#### 4.2.2 Filtros

Os filtros são instrumentos muito utilizados no processamento de sinais no domínio da frequência. Eles são utilizados para remover dos sinais certas frequências específicas. A performance dos filtros é descrita em sua resposta em frequência, isto é, um gráfico que demonstra quais e em qual intensidade cada frequência do sinal original será afetada pelo filtro. Este método é muito útil pois, conhecendo a banda de frequência do sinal original, com o uso dos filtros é possível remover todos os tipos de interferências que possuam componentes de frequência não contidas nessa banda. Os filtros permitem isolar frequências de interesse de um sinal para extração de informações relevantes, como, por exemplo, a equalização de um sistema de áudio. Além disso, os filtros também são utilizados em recuperação de sinais que foram

modulados por outras frequências, como na transmissão de TV e rádio (OPPENHEIM, 2010; OPPENHEIM, 1997; LATHI, 2003).

Em razão de seus potenciais, os filtros são ferramentas básicas aplicadas em praticamente todos os trabalhos envolvendo processamento de sinais. Portanto, é encontram-se inúmeros trabalhos que investigam falhas em máquinas elétricas e que utilizam diferentes tipos de filtros para alcançar seus objetivos (ZHOU; LIU; YANG, 2018; LU *et al.*, 2017; AMEID *et al.*, 2017).

### 4.2.3 Taxa de cruzamento por zero

A taxa de cruzamento por zero mensura o número de vezes que um sinal muda seu valor de negativo para positivo e vice-versa. Essa técnica é muito utilizada em processamento de sinais e seu valor possui uma relação direta com a composição de frequência do sinal, isto é, é baseada nos elementos do espectro do sinal. Outra característica dessa métrica é a sensibilidade a transitórios, sendo que seu valor se altera fortemente quando sinais de frequências maiores que a fundamental do sinal são detectados. Portanto, a TCZ é uma análise multi-frequência que pode ser aplicada para extrair características dos sinais estudados (QUATIERI, 2001).

As equações que são utilizadas para se obter o valor da TCZ são (TOLEDO-PEREZ; RODRIGUEZ-RESENDIZ; GOMEZ-LOENZO, 2020; RABINER; SCHAFER, 1978):

$$Z_{x[n]} = \sum_{m=-\infty}^{+\infty} |sgn[x(m)] - sgn[x(m-1)]| w(n-m) \quad (4.7)$$

onde,  $Z_{x[n]}$  é a taxa de cruzamento por zero do sinal  $x[n]$  e

$$\begin{aligned} sgn[x(n)] &= 1 & x(n) &\geq 0 \\ sgn[x(n)] &= -1 & x(n) &< 0 \end{aligned} \quad (4.8)$$

e

$$\begin{aligned} w(n) &= \frac{1}{2N} & 0 \leq n \leq N-1 \\ w(n) &= 0 & 0 > n > N-1 \end{aligned} \quad (4.9)$$

onde  $N$  é o número de amostras do sinal.

### 4.3 Transformada de Hilbert

A Transformada de Hilbert (TH), descrita por HARDY (1932), é uma abordagem matemática que se mostra eficiente no estudo de sinais não estacionários. Apesar de, em um primeiro momento, a TH não modificar o domínio da função à qual ela é aplicada, a partir da função analítica, permite-se elaborar um espectro altamente preciso do sinal original. Esta função consiste em uma parte real, expressa pelo próprio sinal e uma parte imaginária, expressa pela TH do sinal. Matematicamente, a transformada e a função analítica podem ser obtidos por (OPPENHEIM, 1997; RANGEL-MAGDALENO *et al.*, 2017):

$$\hat{y}(t) = \mathcal{H}\{x(t)\} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (4.10)$$

ainda, é importante notar que o lado direito da equação é a convolução do sinal com a fração  $(\pi t)^{-1}$ . Sendo assim, o sinal analítico pode ser desenvolvido como:

$$Z(t) = x(t) + i\hat{y}(t) = a(t)e^{i\theta(t)} \quad (4.11)$$

sendo que a amplitude desse sinal é o envelope do sinal original. A amplitude e a fase instantâneas do sinal analítico são dados, respectivamente, por:

$$a(t) = \sqrt{x^2(t) + \hat{y}^2(t)} \quad (4.12)$$

$$\theta(t) = \arctg\left(\frac{\hat{y}(t)}{x(t)}\right) \quad (4.13)$$

Finalmente, pode-se obter a frequência instantâneo do sinal por:

$$\omega = \frac{d\theta(t)}{dt} \quad (4.14)$$

Pelas suas vantagens no estudo de sinais não estacionários, a TH é uma técnica que é frequentemente empregada em diagnósticos de falhas em MITs que buscam

por frequências específicas no espectro dos sinais de corrente e vibração do motor (RANGEL-MAGDALENO *et al.*, 2017; MALEK; ABDELSALAM; HASSAN, 2018; MALEK; ABDELSALAM; HASSAN, 2017; KHELFI *et al.*, 2018).

#### 4.4 Técnicas de análise utilizando Inteligência Artificial

Como visto em Gangsar & Tiwari (2020), vários sistemas de Inteligência Artificial já foram implementados na classificação e diagnóstico de MITs. São alguns exemplos: Redes Neurais, Lógica *Fuzzy*, Algoritmos Genéticos, modelos de Markov, classificadores Baysianos, Máquina de vetores de suporte e *Deep Learning*. A vantagem dessas técnicas é: a ampla gama de falhas que podem ser abordadas, a dispensabilidade da criação de índices estatísticos específicos e a versatilidade de aplicação.

Os sistemas de IA funcionam a partir de uma variável escolhida como valor entrada, que é utilizada pela rede para calcular o diagnóstico final. Essa variável pode ser, inclusive, o resultado da aplicação de alguma técnica já descrita nas seções anteriores sobre um sinal, tanto no domínio do tempo, quanto no domínio da frequência. Esse sinal também pode ser de natureza qualquer, como corrente, tensão, EA, vibração, temperatura, etc. Uma vez escolhido qual métrica será escolhida como entrada do sistema, a IA irá determinar, por meio de seu método de aprendizado específico, sob qual situação o motor seu encontra. Por fim, a eficiência e a precisão desses sistemas são condicionados pelas boas escolhas para variáveis de entrada (LIU *et al.*, 2018).

Há estudos que utilizam diversas combinações de tipos de IA e variáveis de entrada, com resultados finais também diversos (LIU *et al.*, 2018; CHEN; CHAO; TSENG, 2019; FU *et al.*, 2020; AZAMFAR *et al.*, 2020). No entanto, nota-se desvantagens ocasionalmente inerentes às IAs como: requisição de grande esforço computacional, necessidade de *datasets* volumosos, tempo para treinamento excessivamente prolongado e necessidade de muitas variáveis de entrada são algumas delas (LIU *et al.*, 2018).

#### 4.5 Transformada Wavelet

Nesta seção serão apresentadas as principais vantagens e particularidades que levaram à escolha da Transformada Wavelet como a técnica de processamento de

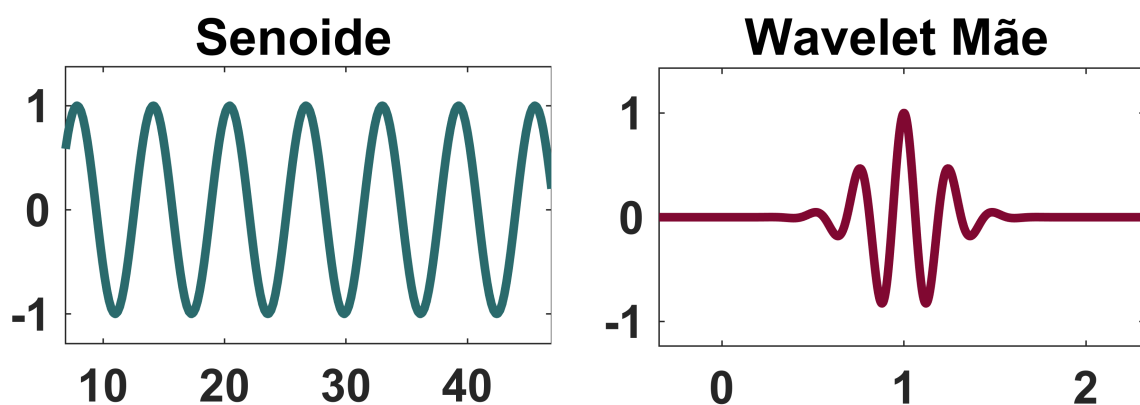
sinais na realização deste trabalho.

#### 4.5.1 Introdução

Como anteriormente descrito, a Transformada de Fourier é uma técnica notável de processamento de sinais. No entanto, devido ao fato da TF utilizar a soma de senoides periódicas, faz com que essa técnica não apresente boa performance na análise de sinais que possuam variações abruptas e repentinas. No entanto, os sinais resultantes dos fenômenos físicos do mundo real frequentemente apresentam esse tipo de imperfeição. Portanto, ao invés das senoides, a Transformada Wavelet recorre a sinais menores e de duração finita. Essas ondas são deslocadas no tempo e modificadas em escala para reconstituir uma versão multirresolução do sinal original. Dessa maneira, a TW se dá como uma ferramenta poderosa no estudo de sinais não periódicos, não estacionários ou de transientes (BURRUS, 1998).

A onda de curta duração utilizada pela TW é chamada de Wavelet mãe (WM) e esta é a onda que será manipulada para reconstruir o sinal original. Duas características precisam ser observadas para uma onda ser empregada como Wavelet mãe: duração finita no tempo e valor médio igual a zero. Deste modo, múltiplos tipos de Wavelets mãe diferentes já foram propostos, um exemplo de WM está representado na Figura 31. Esta variedade que se apresenta como um ponto positivo para a TW, uma vez que é possível encontrar uma Wavelet mãe com o melhor desempenho para cada tipo de reconstrução (WALNUT, 2002).

Figura 31 – Diferença entre os sinais usados para reconstrução



Fonte: Próprio autor

Matematicamente, a TW pode ser comparada com a TF (Equação 4.5) na medida em que as duas transformadas apresentam o sinal original multiplicado por um sinal de análise. No entanto, enquanto a TF apresenta como resultado uma função que tem apenas uma variável, a TW apresenta como resultado uma função com duas variáveis: escala e deslocamento. Desta forma, a TW permite uma análise no domínio do tempo-frequência do sinal original. A equação que dá origem à TW do sinal  $x(t)$  pode ser descrita como (BURRUS, 1998):

$$W_{(a,b)} = \int_{-\infty}^{\infty} x(t) \psi_{a,b}(t) dt \quad (4.15)$$

onde  $a$  e  $b$  são, respectivamente, os coeficientes de escala e de deslocamento e  $\psi_{a,b}$  é a função Wavelet, que é obtida da seguinte maneira:

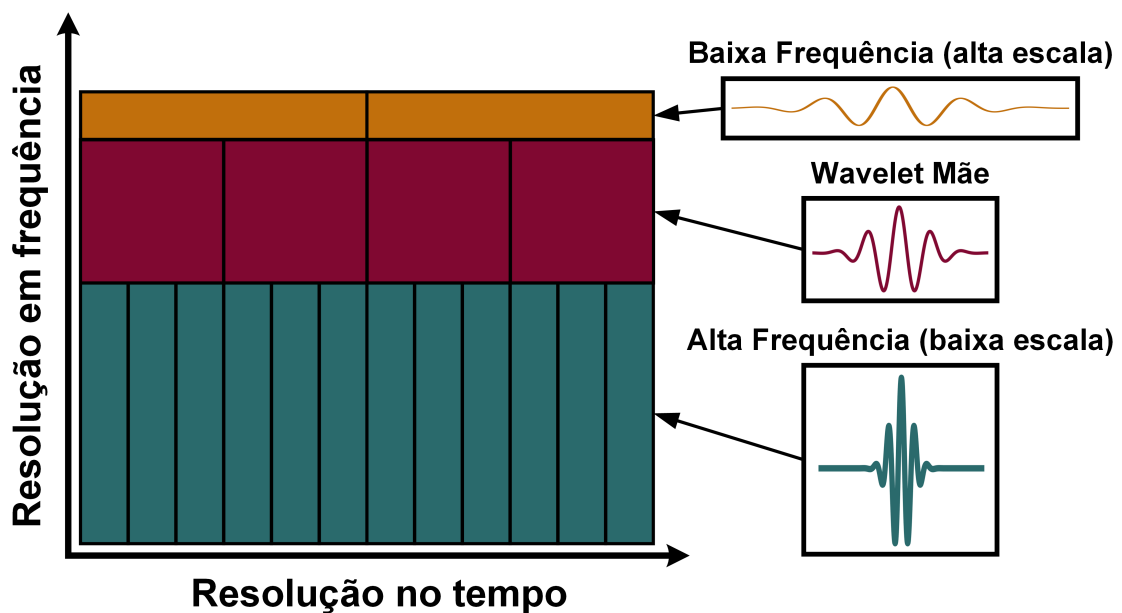
$$\psi_{a,b} = \frac{1}{\sqrt{|a|}} \psi \left( \frac{t-b}{a} \right) \quad (4.16)$$

sendo que a Wavelet mãe é representada pelo resultado de  $\psi_{1,0}$ .

Portanto, a base da aplicação da TW são as operações de escalonamento e deslocamento da WM. O deslocamento é uma operação de simples compreensão, que se limita a deslocar a WM no eixo do tempo. Já o escalonamento consiste em comprimir ou esticar a WM resultando em diferentes características de análise para cada valor do coeficiente  $a$  escolhido. Como visto na Equação 4.16, quanto menor o valor de  $a$ , maior a frequência da WM e, quanto maior o valor de  $a$ , menor a frequência da WM. Em razão dos diferentes valores de escala que podem ser adotados, cria-se uma versão multirresolução do sinal original, ou seja, a resolução em tempo e em frequência variam de acordo com os coeficientes aplicados, como explicado na Figura 32 (BURRUS, 1998).

Ainda na Figura 32 nota-se que, quando utilizado uma alta escala, ganha-se em precisão de frequência, mas perde-se em resolução no tempo. Já nas baixas escalas, ganha-se em resolução no tempo, mas perde-se em resolução na frequência. Sendo assim, a TW permite a criação de uma representação em três dimensões para representar o sinal original, utilizando todas as suas escalas.

Figura 32 – Versão multirresolução da Transformada Wavelet



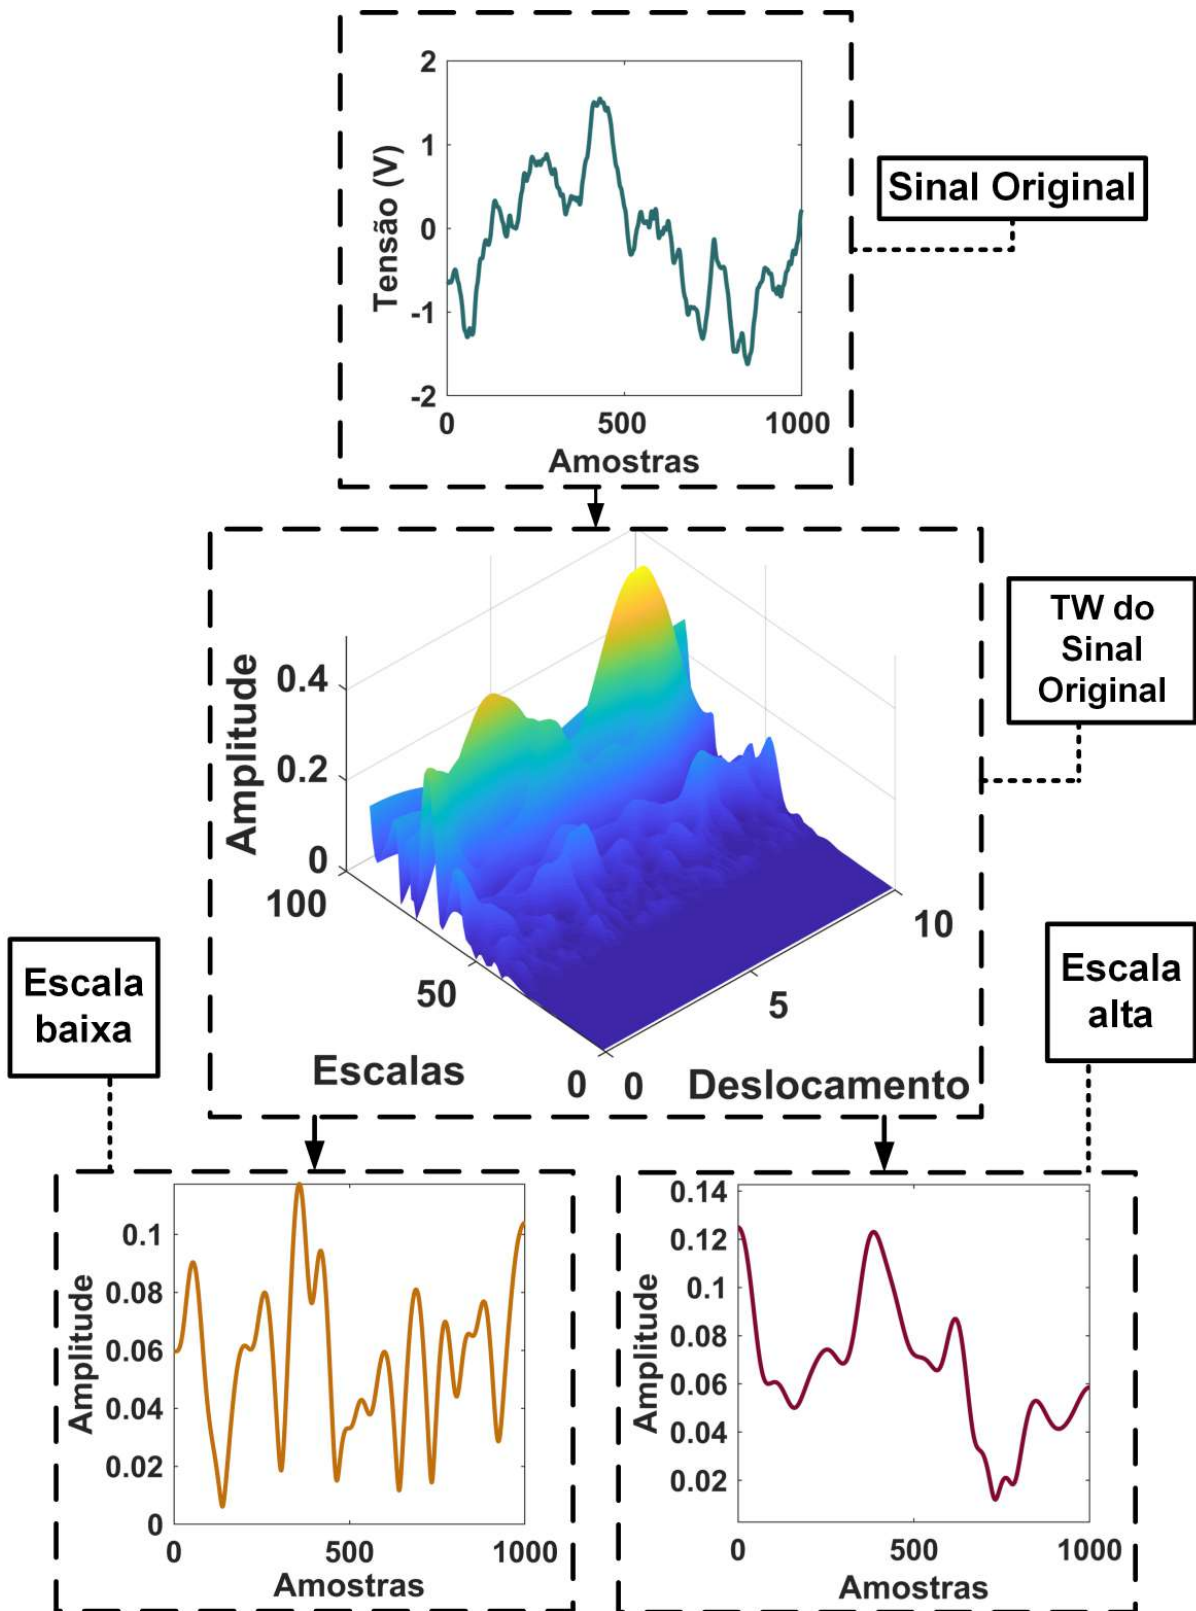
Fonte: Próprio autor

Uma análise muito comum é a escolha de qual escala será usada para reproduzir o sinal original, de acordo com o escopo do estudo. Para elucidar essas possibilidades foi elaborada a Figura 33. Um sinal qualquer, tido como sinal original, pode ser visto no topo da Figura. Ao ser aplicada a TW neste sinal (Equação 4.15), obtém-se o gráfico em três dimensões: escala, deslocamento e amplitude, também visualizado ao centro da mesma Figura. Neste gráfico 3D, observa-se as diversas reconstruções do sinal com o uso de diferentes valores de escala.

Ainda na Figura 33, foram destacadas as reconstruções utilizando duas escalas diferentes, uma baixa e uma alta. Fica nítido que, em escalas altas, o sinal é reconstruído pelas suas frequências de valores mais baixos, algo similar a um filtro passa-baixas. Já em escalas baixas, o sinal reconstruído possui frequências de valor mais elevado, revelando, geralmente, detalhes como ruídos e interferências do sinal original, semelhante a um filtro passa-altas.

Outro aspecto relevante pode ser notado observando-se os maiores valores de amplitude (valores em amarelo). O valor do eixo de escala associado a esses valores tem uma relação direta com a frequência fundamental do sinal original pois, ao ser comprimida ou esticada por essa escala, a WM apresentou alta correspondência com o sinal original.

Figura 33 – Transformada Wavelet de um sinal e suas escalas



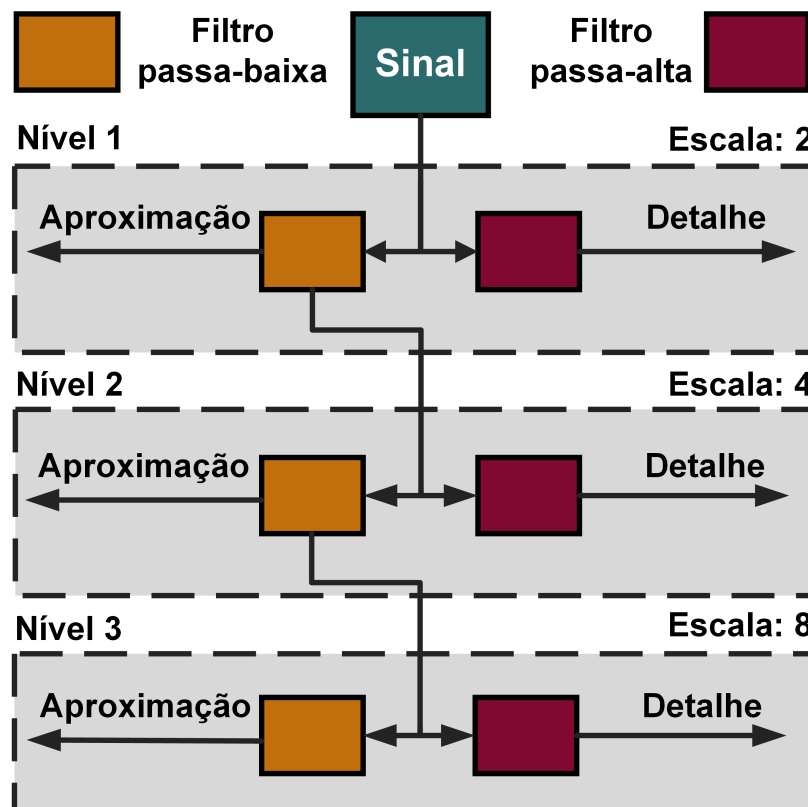
Fonte: Próprio autor

## 4.5.2 Transformada Wavelet Discreta

Conceber os coeficientes para todas as escalas possíveis seria custoso computacionalmente e dispendioso para a memória dos dispositivos, já que originaria uma imensa quantidade de dados. Uma versão mais prática e mais tangível é a transformada Wavelet discreta (TWD). As escalas e deslocamentos, na TWD, são tomados apenas em potências de dois, ou seja,  $a = 2^j$ , sendo que ( $j = 1, 2, 3, 4, \dots$ ) e  $b = 2^j m$ , sendo que ( $m = 1, 2, 3, 4, \dots$ ), tornando o processo menos laborioso (SUNDARARAJAN, 2015).

Esse procedimento faz com que a TWD se torne uma espécie de filtro duplo aplicada ao sinal, um filtro passa-baixa e um filtro passa-alta. A cada nova escala tomada, ou nível, esse filtro duplo se repete, gerando um processo iterativo. Os valores de reconstrução resultantes da aplicação de cada filtro são chamados de coeficientes. Os coeficientes de aproximação e detalhe que representam, respectivamente, o conteúdo de baixa e alta frequência. Esse processo é melhor explicado pela Figura 34.

Figura 34 – Processo de criação dos coeficientes de aproximação e detalhe de cada nível Wavelet



Fonte: Próprio autor

O algoritmo elaborado por Mallat (1989), permite a criação da transformada rápida de Wavelet (TRW), que é amplamente utilizada na implementação da TWD em softwares, reduzindo o esforço computacional e diminuindo o tamanho dos vetores de saída resultantes. Os coeficientes de detalhe e aproximação são calculados na TRW por (HAFIZ *et al.*, 2019):

$$a_{j+1}[p] = \sum_{n=-\infty}^{+\infty} h[n - 2p]a_j[n] \quad (4.17)$$

e

$$d_{j+1}[p] = \sum_{n=-\infty}^{+\infty} g[n - 2p]a_j[n] \quad (4.18)$$

onde  $a$  e  $d$  são, respectivamente, os coeficientes de aproximação e detalhe,  $h$  é o filtro passa-baixa,  $g$  é o filtro passa-alta e  $j$  é o nível Wavelet.

Muitas vezes, principalmente nos estágios incipientes, as falhas costumam produzir sinais transientes, não periódicos e não-estacionários. No entanto, a capacidade da TW de estudar estes tipos de fenômenos no domínio tempo-frequência e as vantagens computacionais da TDW fazem com que essa técnica seja largamente utilizada na detecção de falhas em máquinas elétricas (HUSSEIN; EL-HAG; SHABAN, 2016; WANG *et al.*, 2019b; XU *et al.*, 2019; SU; LI; ZHANG, 2019; CHEN *et al.*, 2019; SONG *et al.*, 2018; CASTRO; BAPTISTA; CIAMPA, 2019). Por fim, essas características também motivaram a utilização da TWD nesta dissertação.

## Capítulo 5

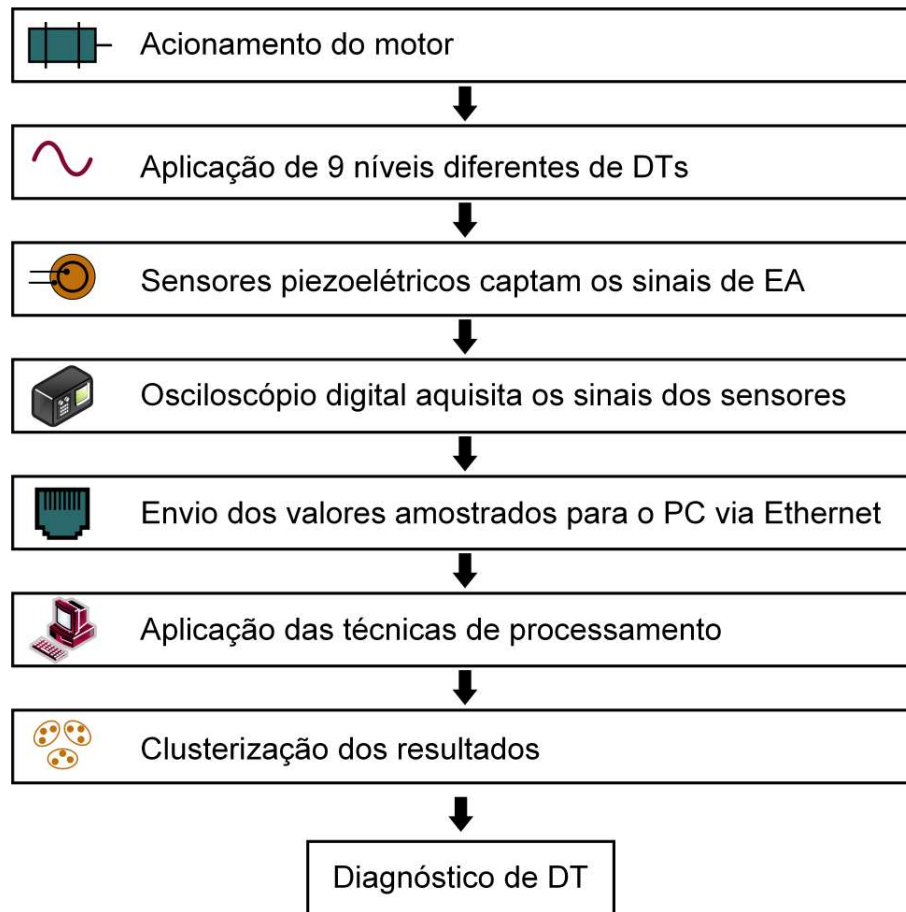
# Metodologia proposta

*Neste Capítulo, serão apresentados os métodos relacionados tanto aos ensaios experimentais, quanto às técnicas de processamento de sinais utilizadas. A priori, será descrita a montagem experimental utilizada nos ensaios, detalhando suas particularidades. Em seguida, será apresentado como foi elaborado o novo índice especialmente desenvolvido para análise de desequilíbrio de tensão, além de outros métodos estatísticos utilizados no processamento de sinais.*

### 5.1 Montagem experimental

Neste trabalho, todos os experimentos e aquisições de dados foram realizados com foco na confiabilidade e no controle do ambiente, com o objetivo de padronizar os resultados experimentais. Portanto, todas as aquisições de sinais foram realizadas diversas vezes, garantindo a repetibilidade das medições. Além disso, todos os ensaios foram realizados no Laboratório de Pesquisa em Qualidade da Energia Elétrica (LAQEE). As subseções a seguir descrevem os principais componentes e procedimentos adotados para a bancada de testes e o sistema de aquisição de dados. A Figura 35 descreve as etapas realizadas no desenvolvimento deste trabalho.

Figura 35 – Metodologia utilizada no trabalho




Fonte: Próprio autor

### 5.1.1 Montagem das máquinas elétricas

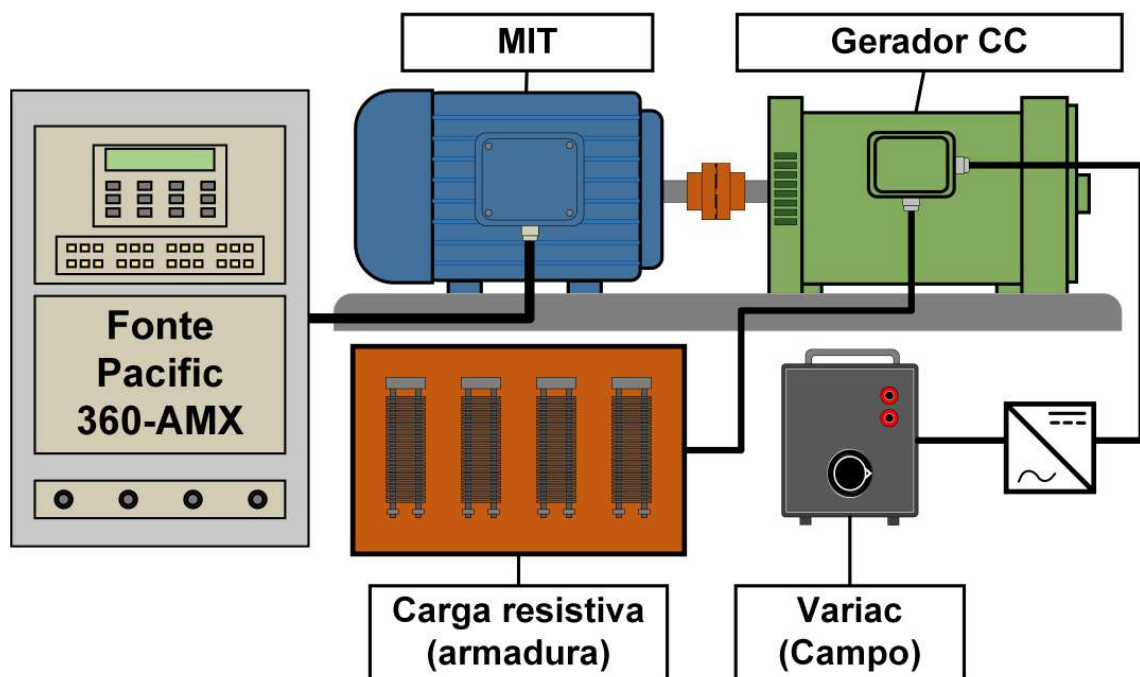
Antes da aplicação dos DTs, o motor de indução foi acoplado a uma máquina DC usando um acoplamento industrial (Figura 36), a fim de simular uma carga real. O MIT foi alimentado por uma fonte trifásica controlada por software, o que permite a medição e controle dos níveis de corrente e tensão fornecidos. O circuito de campo da máquina CC foi conectado a uma ponte retificadora, alimentada por um Variac, e o circuito de armadura foi conectado a uma carga resistiva (Figura 37). Com o aumento da tensão de campo do gerador CC, a corrente do circuito de armadura também se amplia, gerando o aumento do carregamento no eixo do motor até que se atinja sua corrente nominal. Este procedimento é essencial para emular uma condição mais corriqueira na indústria, já que motores elétricos costumam ser dimensionados para trabalharem próximos ao seu carregamento nominal.

Figura 36 – MIT acoplado ao gerador CC



Fonte: Próprio autor

Figura 37 – Esquema das ligações das máquinas elétricas durante os ensaios



Fonte: Próprio autor

Depois disso, as tensões desequilibradas foram aplicadas individualmente à cada uma das três fases de alimentação utilizando a fonte trifásica programável. As subtensões de fase foram ajustadas entre 90 e 10% do valor nominal do motor em etapas de 10% por experimento, resultando em nove níveis de desequilíbrio. Estes passos foram repetidos para cada uma das três fases e os sinais foram adquiridos para

todas as porcentagens descritas, resultando em 30 experimentos diferentes (Tabela 1). Mais detalhes sobre a aquisição e o processamento dos sinais estão detalhados nas próximas subseções.

Tabela 1 – Valores desequilibrados aplicados ao MIT durante os ensaios

Desequilíbrio na fase A				Desequilíbrio na fase B				Desequilíbrio na fase C			
n°	Va (%)	Vb (%)	Vc (%)	n°	Va (%)	Vb (%)	Vc (%)	n°	Va (%)	Vb (%)	Vc (%)
01	100	100	100	11	100	100	100	21	100	100	100
02	90	100	100	12	100	90	100	22	100	100	90
03	80	100	100	13	100	80	100	23	100	100	80
04	70	100	100	14	100	70	100	24	100	100	70
05	60	100	100	15	100	60	100	25	100	100	60
06	50	100	100	16	100	50	100	26	100	100	50
07	40	100	100	17	100	40	100	27	100	100	40
08	30	100	100	18	100	30	100	28	100	100	30
09	20	100	100	19	100	20	100	29	100	100	20
10	10	100	100	20	100	10	100	30	100	100	10

Fonte: Próprio autor


Os valores nominais e os modelos dos equipamentos utilizados neste trabalho são:

- a) **Motor de indução trifásico com rotor gaiola de esquilo:** potência nominal: 4 cv; alimentação: 220/380 V; corrente: 11,8/6,83 A; quatro polos; 1725 RPM; FP: 0,8.
- b) **Máquina CC:** potência nominal: 10 kW; tensão de campo: 400 V; tensão de armadura: 380 V corrente de armadura: 26 A; corrente de campo: 0,75 A;
- c) **Fonte Trifásica Programável Pacific Power 360AMX:** potência nominal 12 kW.
- d) **Variac Trifásico:** tensão de operação: 0 - 440 V.
- e) **Carga resistiva:** 4 resistores individuais de 1,5 kW.

### 5.1.2 Sistema de aquisição de dados


Para este trabalho, os sinais de EA foram obtidos pelos sensores piezoelétricos descritos na Seção 3.8.2 e apresentados na Figura 24, e que foram fixados ao MIT usando uma cola à base de cianoacrilato, como na Figura 38. Além disso, em destaque, está um sensor do tipo termopar que foi utilizado para monitorar a temperatura do motor. Oito destes sensores foram posicionados radialmente ao longo do motor de indução. Eles foram distribuídos em quatro sensores na parte frontal e quatro sensores na parte traseiro, como ilustrado na Figura 39. A escolha das posições dos sensores foi baseada na disposição geométrica interna dos enrolamentos das fases do motor. Com o intuito de criar disparidades entre os sinais dos sensores de cada posição, os sensores 3, 4, 7 e 8 (parte inferior) foram fixados mais próximos da altura média do estator do que os sensores 1, 2, 5 e 6 (parte superior), gerando assimetrias entre suas posições geométricas (Figura 39). Para avaliar a interferência da posição dos sensores ao longo do eixo axial, os sinais dos sensores frontais (1 a 4) foram aqusitados e estudados separadamente dos sinais dos sensores traseiros (5 a 8).

Figura 38 – Sensores fixados ao MIT



Fonte: Próprio autor


Figura 39 – Posição dos sensores no MIT



Fonte: Próprio autor

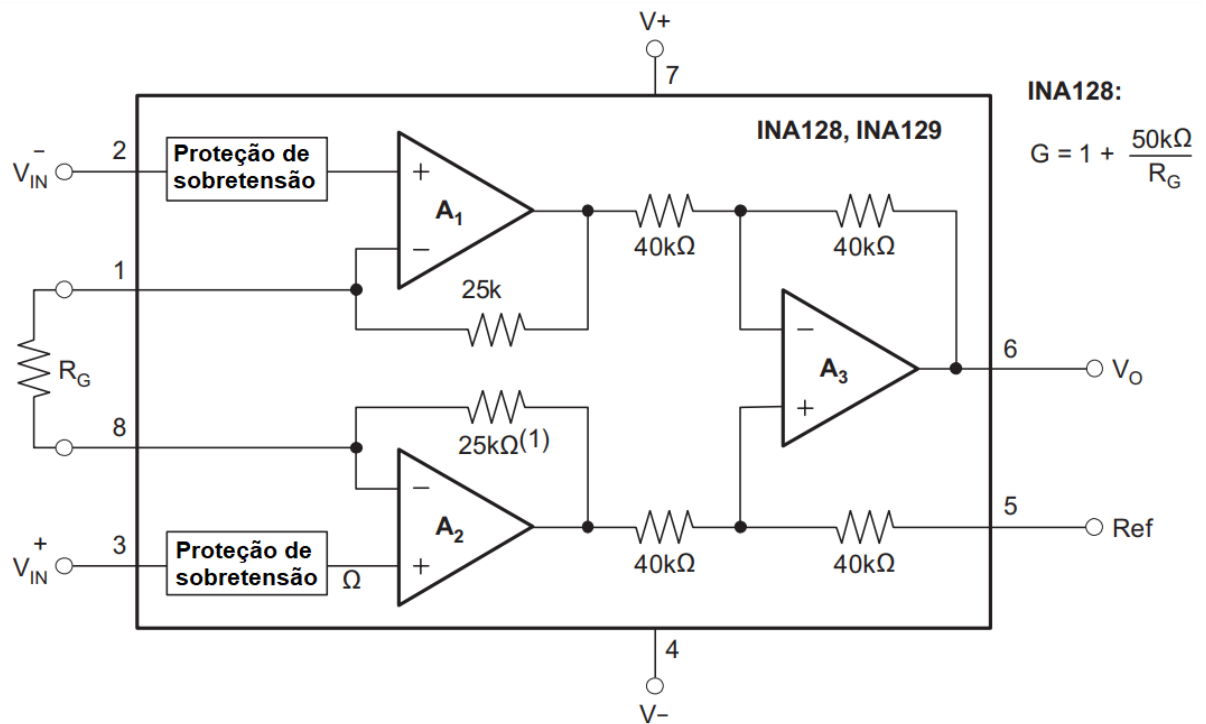
Os sinais obtidos pelos sensores piezoelétricos foram condicionados por uma placa especialmente projetada com base no CI amplificador de instrumentação INA128p (Texas Instruments, 2020), que atua como um filtro *anti-aliasing* passa-baixas de 400 kHz (Figura 40) e que foi alimentada por uma fonte CC simétrica Politerm - POL 16B. O amplificador de instrumentação tem a função de amplificar os sinais de baixa tensão dos sensores piezoelétricos além de diminuir os problemas relacionados ao casamento de impedância e ao ruído em modo comum. O esquemático interno do CI está disposto na Figura 41. A aquisição dos sinais amplificados foi realizada por um osciloscópio digital Yokogawa 850DL ajustado a uma frequência de amostragem de 2 MS/s, satisfazendo o teorema de Nyquist. Finalmente, os dados foram transferidos para um computador pessoal (PC) por meio de uma rede Ethernet e o processamento dos sinais foi realizado utilizando o software MATLAB®. Por fim, para fim de controle adicional do experimento, a corrente de armadura e a corrente de campo da máquina CC foram monitoradas por multímetros digitais com o intuito de evitar anomalias durante os ensaios.

Figura 40 – Placa de condicionamento de sinais



Fonte: Próprio autor

Figura 41 – Esquemático interno de amplificação do CI INA128p



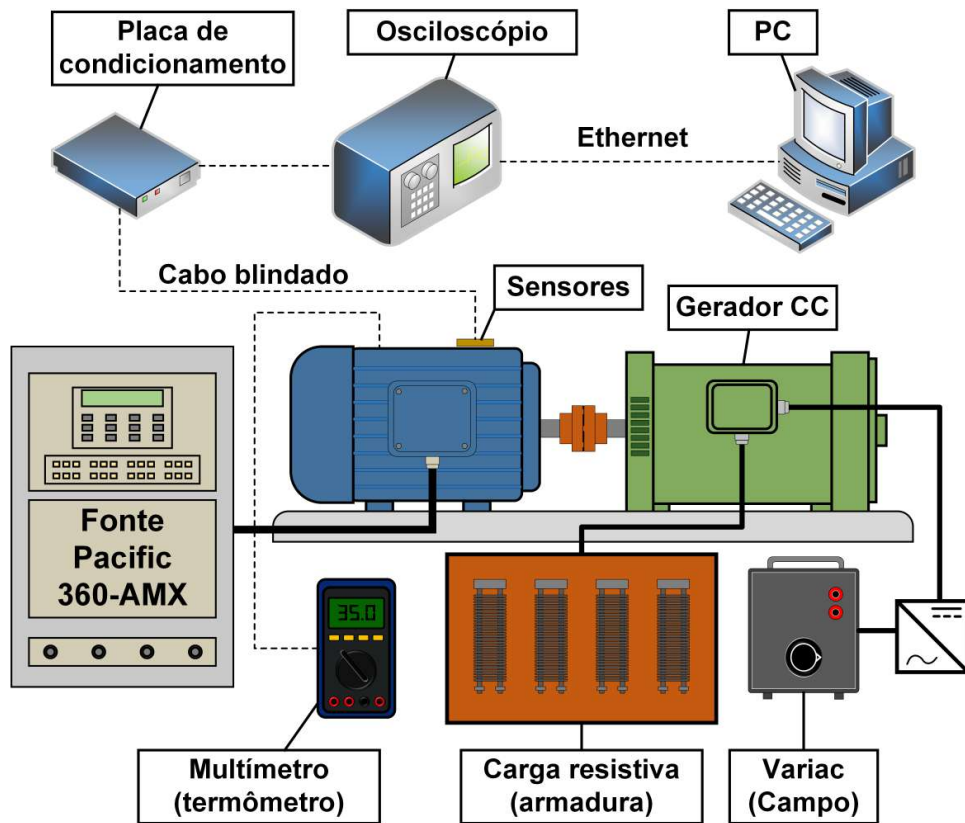
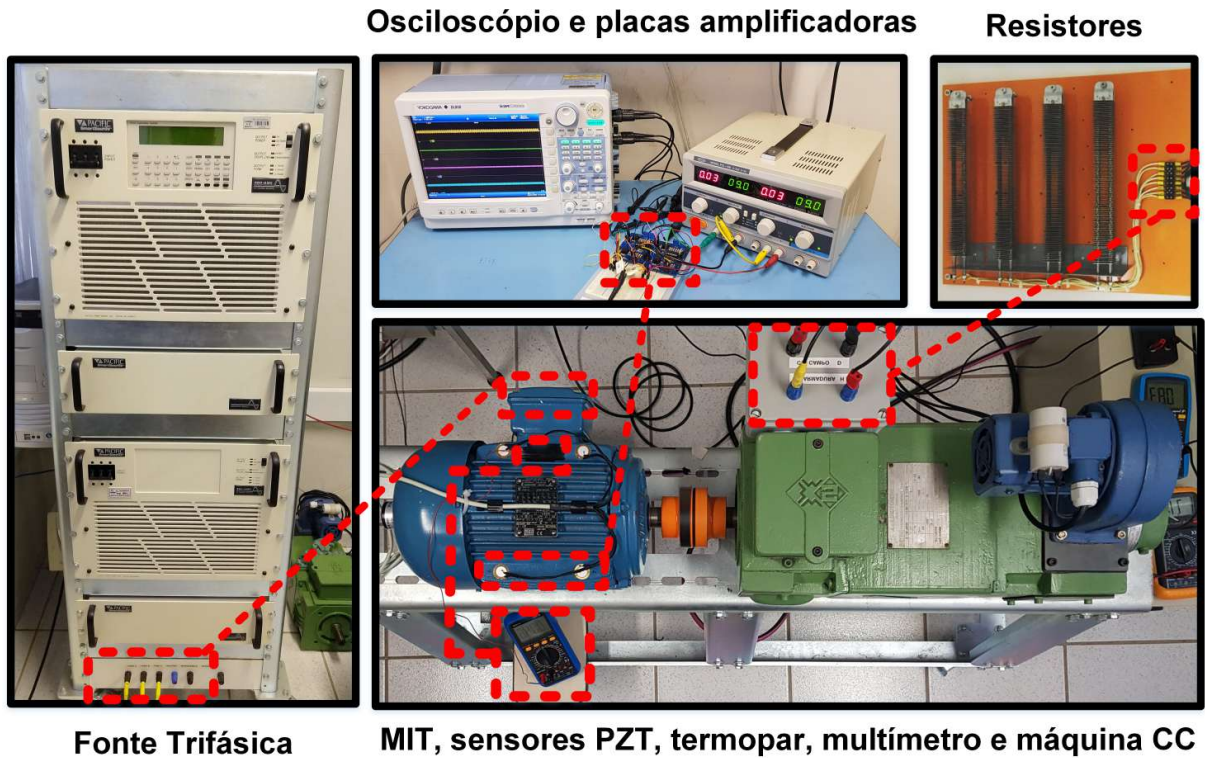
Fonte: Adaptado de Texas Instruments (2020)

Algumas ações preventivas foram tomadas para evitar medidas incorretas e para minimizar interferências de todas as naturezas:

- a) As malhas de todos os cabos blindados utilizados nos experimentos foram aterradas, assim como a bancada de teste e a carcaça do motor de indução, evitando interferências eletromagnéticas.
- b) Devido à sensibilidade do sensor à variação da temperatura, o motor de indução foi acionado até que sua temperatura operacional atingisse um valor constante (cerca de  $46 \pm 0,1$  °C) , que foi monitorado por um sensor do tipo termopar.
- c) Para aumentar a precisão das medidas, cada um dos trinta experimentos foi repetido 100 vezes, com o objetivo de assegurar a repetibilidade dos resultados.
- d) Foi assegurado que o motor elétrico estava livre de qualquer outro tipo de falha mecânica ou elétrica.

As fotos dos elementos utilizados nos ensaios, assim como a ilustração do esquemático geral contendo o sistema de aquisição em conjunto com a montagem das máquinas elétricas podem ser visualizados na Figura 42.

Figura 42 – Fotografias dos elementos utilizados nos ensaios e suas ligações



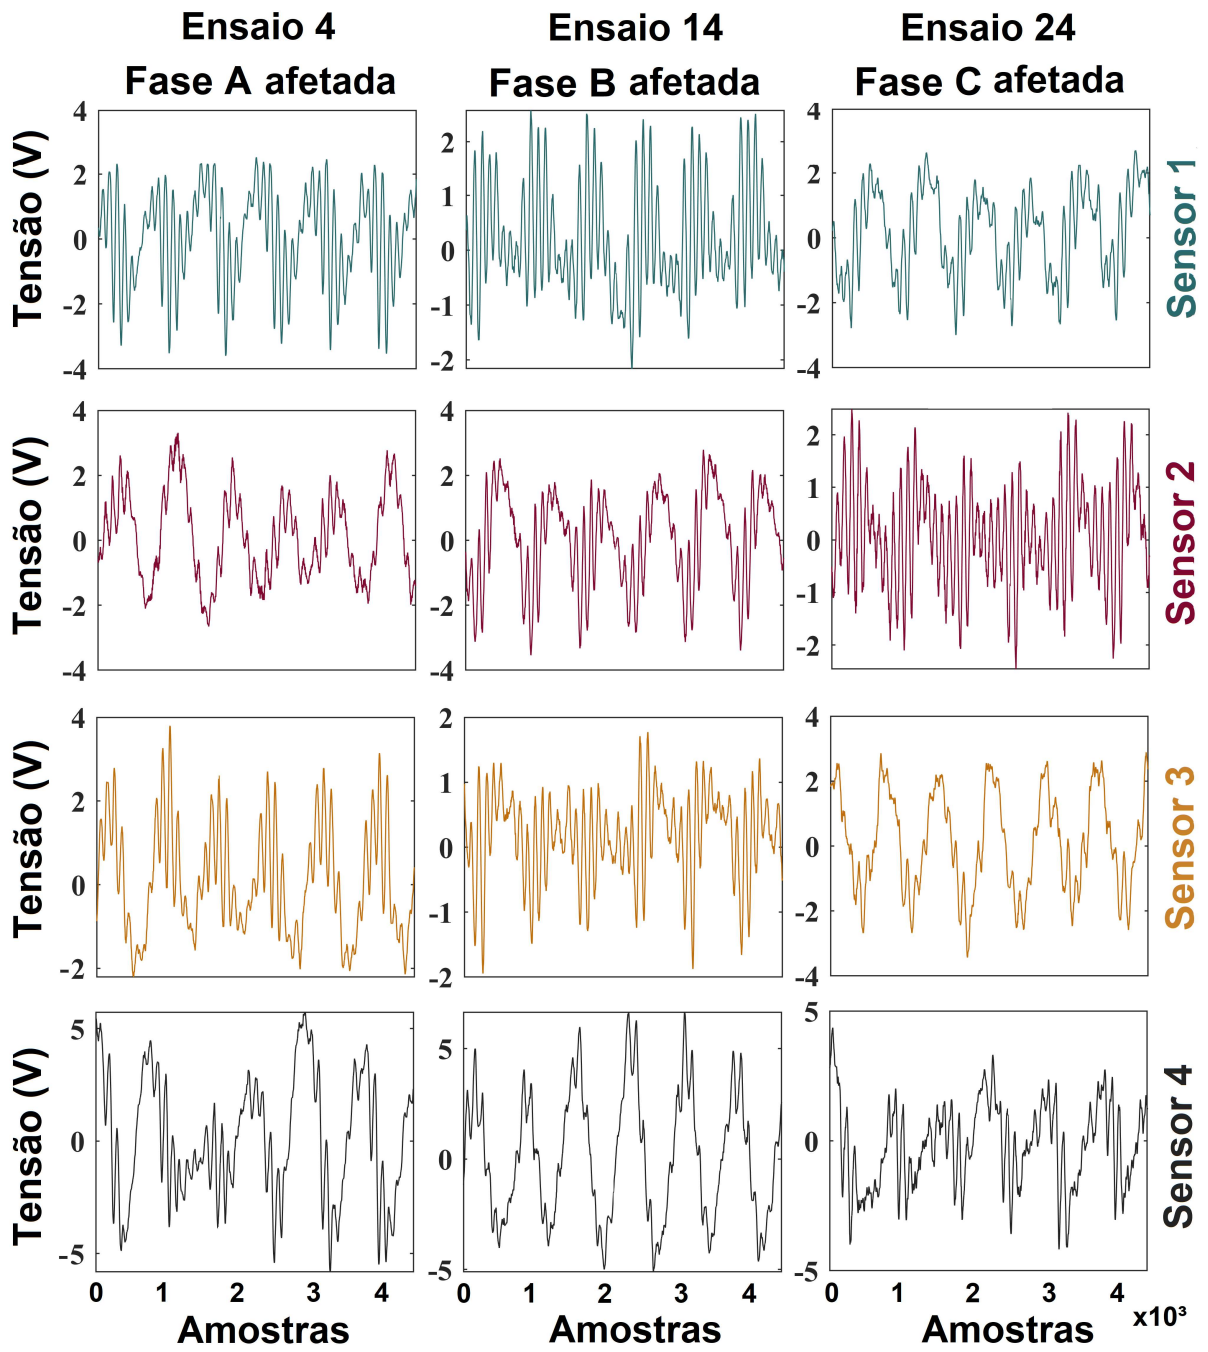
## 5.2 Nova abordagem para detecção de desequilíbrios de tensão

A necessidade do desenvolvimento de um novo índice originou-se, principalmente, da complexidade de análise dos sinais amostrados pelos sensores piezoelétricos e que podem ser vistos na Figura 43. Nela, são apresentados os sinais de EA captados por quatro sensores piezoelétricos (sensores 1, 2, 3 e 4) fixados a quatro posições diferentes do MIT. Estes sinais foram obtidos de acordo com a configuração descrita na Figura 39. Os gráficos posicionados na mesma linha apresentam os sinais fornecidos pelo mesmo sensor para diferentes ensaios, enquanto os gráficos na mesma coluna apresentam os sinais obtidos por cada um dos quatro sensores para o mesmo ensaio. A primeira coluna apresenta os sinais resultantes do ensaio n° 4 (70% da tensão nominal na fase A); a segunda coluna apresenta os sinais resultantes do ensaio n° 14 (70% da tensão nominal na fase B); a terceira coluna apresenta os sinais resultantes do ensaio n° 24 (70% da tensão nominal na fase C).

Ainda na Figura 43, observa-se que há variações de amplitude e forma entre os sinais de cada um dos sensores mesmo sob condições de DT idênticas, ou seja, os sensores apresentaram respostas diferentes para o mesmo ensaio (diferença de gráficos na mesma coluna). Também é possível identificar diferenças entre os sinais do mesmo sensor quando a fase afetada se altera (variação na mesma linha). No entanto, após examinar a Figura 43 e realizar testes preliminares, notou-se que o diagnóstico proposto não é trivial e que técnicas no domínio do tempo ou frequência não são suficientes para identificar ou classificar os DTs. Portanto, o desenvolvimento de abordagens de análise no domínio tempo-frequência é crucial para caracterizar de maneira mais ampla a condição de desequilíbrio de tensão.

O novo índice proposto baseia-se na Transformada Wavelet, valores de energia e da taxa de cruzamento por zero, que são conhecidos como ferramentas eficientes para processamento de sinais, capazes de analisar sinais não-estacionários e transitórios, como descrito no Capítulo 4. Adicionalmente, foram aplicados índices estatísticos auxiliares para avaliar o desempenho da proposta. As subseções seguintes descrevem, respectivamente, o novo índice e as técnicas estatísticas para avaliar a sua performance.

Figura 43 – Diferenças nos sinais de acordo com a fase afetada



Fonte: Próprio autor

### 5.2.1 Um novo índice baseado na Energia Ponderada pela Passagem por Zero

Como mostrado na subseção anterior, os sinais de cada sensor apresentaram mudanças de amplitude e forma em relação às fases afetadas. Considerando esse fato, uma vez que foram detectadas diferenças na composição de frequência entre os sinais, a TWD foi aplicada devido à sua capacidade de extrair características no domínio do tempo-frequência utilizando os coeficientes Wavelet. Além disso, foi avaliado qual nível Wavelet é mais sensível aos DTs. Após a aplicação da TWD, foram adotadas técnicas que avaliam a magnitude (valores de energia) e a composição de frequência (TCZ) dos sinais, objetivando a criação de um índice capaz de detectar, identificar e classificar o DT no MIT. É importante citar que a WM utilizada foi do tipo *Debauche*, muito utilizada para aplicações gerais e o número de níveis Wavelet máximo foi determinado como 12, sendo esse o limite máximo de níveis para o vetor adquirido de acordo com os cálculos realizados a partir do tamanho do vetor original como demonstrado na bibliografia (MALLAT, 1989).

O novo índice pode ser matematicamente obtido baseado nas Equações (4.17), (4.18), (4.2) and (4.7), como mostrado a seguir:

$$EZ_{aj}^{S_K} = E_{aj}^{S_K} \cdot Z_{aj}^{S_K} \quad (5.1)$$


para os coeficientes de aproximação e

$$EZ_{dj}^{S_K} = E_{dj}^{S_K} \cdot Z_{dj}^{S_K} \quad (5.2)$$

para os coeficientes de detalhe. Onde  $EZ$  é a Energia Ponderada pela Passagem por zero e  $j$  é o nível Wavelet. Como os ensaios para este trabalho foram realizados com quatro sensores diferentes, o sobrescrito  $S_K$  indica para qual dos  $K$  sensores o valor foi calculado.

Para melhor elucidação, foi elaborado um diagrama esquemático que representa o cálculo do novo índice, visto na Figura 44.


Figura 44 – Diagrama de cálculo do novo índice para cada um dos experimentos



Fonte: Próprio autor

Em testes preliminares, ao atribuir os valores de  $EZ$  de três sensores diferentes à cada um dos três eixos coordenados, observou-se que a técnica produziu agrupamentos de dados bem distintos para cada uma das fases afetadas. Apenas para exemplificar esse comportamento, os valores de  $EZ$  relativos aos sensores 2, 3 e 4 para os ensaios n° 6 (50% de tensão na fase A), n° 16 (50% de tensão na fase B) e n° 26 (50% de tensão na fase C) foram atribuídos aos eixos  $x$ ,  $y$  e  $z$ , assim como os centroides de cada agrupamento formado. O resultado está disposto na Figura 45. Este estudo preliminar indica que o novo índice possui a capacidade de identificação da fase específica afetada pelo DT. Por fim, no próximo capítulo, o uso do valor  $EZ$  será melhor ilustrado.

Figura 45 – Exemplo de clusterização dos valores de  $EZ$



Fonte: Próprio autor

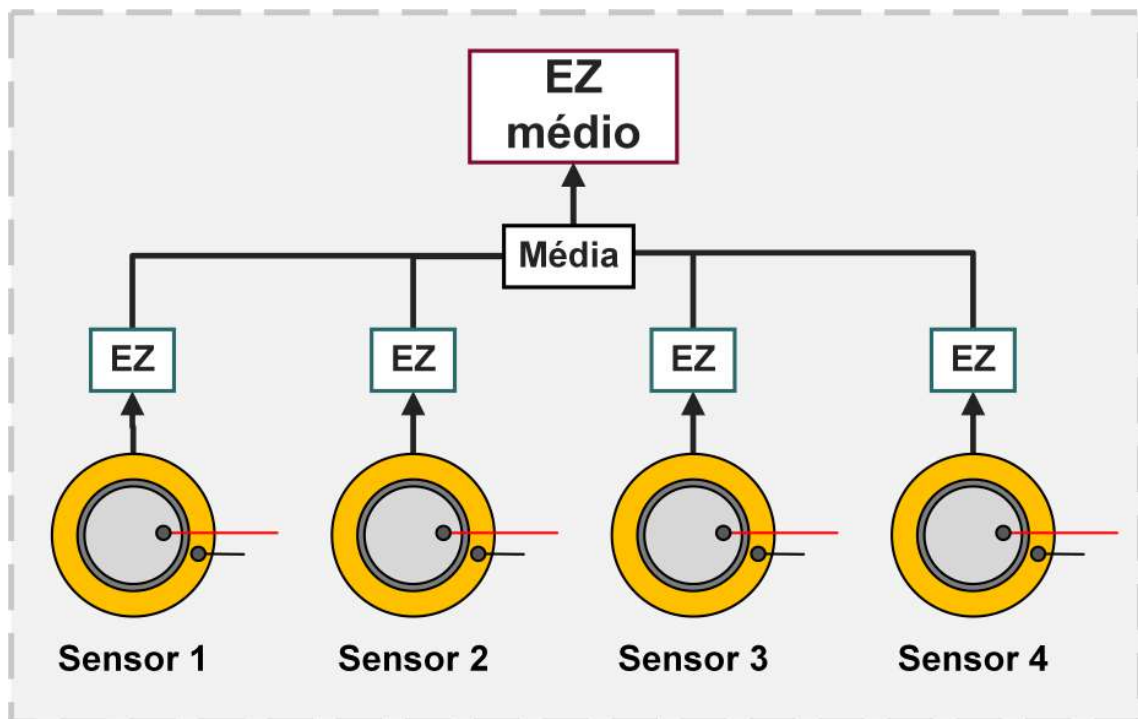
Adicionalmente, por meio da monitorização do valor médio de  $EZ$  entre os quatro sensores, foi possível diferenciar um DT de magnitude qualquer de uma situação de alimentação balanceada (*baseline*), como será também demonstrado nos resultados. Este valor pode ser alcançado por:

$$\bar{EZ} = \frac{1}{K} \sum_{n=1}^K EZ^{S_n} \quad (5.3)$$

onde  $\bar{EZ}$  é o valor médio de  $EZ$  e  $K$  representa o número de sensores utilizados no cálculo.

Novamente, para melhor elucidação, foi elaborado um diagrama esquemático que representa o cálculo do valor de  $\bar{EZ}$ , visto na Figura 46.

Figura 46 – Diagrama de cálculo de  $\bar{EZ}$  para cada um dos experimentos



Fonte: Próprio autor

## 5.2.2 Clusterização de dados e índice Silhouette

A fim de validar e solidificar os resultados obtidos pela aplicação do novo índice  $EZ$ , foram calculadas métricas estatísticas a respeito da performance da clusterização (ou agrupamento) de dados. Para tal, foi aplicado o algoritmo *K-means* que foi utilizado para calcular as posições dos centroides para cada cluster de pontos. Os centroides não só suportam o diagnóstico, mas também são utilizados para implementar as estatísticas de desempenho. Além disso, esta ferramenta não depende de aprendizagem supervisionada e é um método de agrupamento amplamente utilizado (QIN *et al.*, 2017; ALHAWARAT; HEGAZI, 2018).

O conceito básico do algoritmo *k-means* é minimizar iterativamente os valores de erro ao quadrado entre os centroides e os pontos de um mesmo cluster. Assumindo que  $D = \{x_1, \dots, x_n\}$  é um conjunto de dados com  $n$  pontos em  $\mathbb{R}^d$  que será agrupado em  $K$  centroides  $C = \{c_1, \dots, c_k\}$ , o valor do erro ao quadrado pode ser alcançado por:

$$E(c_k) = \sum_{x_i \in c_k} \|x_i - \mu_k\|^2 \quad (5.4)$$

onde  $\mu_k$  é a média do cluster  $c_k$ . Portanto, o valor do erro para todos os  $K$  clusters é dado por:

$$E(C) = \sum_{k=1}^K \sum_{x_i \in c_k} \|x_i - \mu_k\|^2 \quad (5.5)$$

Uma vez identificados os centroides, uma técnica de análise de desempenho conhecida como *Silhouette* foi implementada. Esta métrica avalia quão próximo um ponto está dos pontos de seu cluster e quão longe esse mesmo ponto está dos pontos dos outros clusters. Assim, a *Silhouette* cria um índice de desempenho com valor entre -1 e 1. Um valor mais próximo de 1 indica que o ponto está fortemente ligado ao cluster em análise, enquanto um valor mais próximo de -1 mostra que o ponto está fortemente desassociado ao cluster em análise (KAUFMAN; ROUSSEEUW, 1990; ALVAREZ *et al.*, 2020). Finalmente, a expressão matemática usada para obter estes valores é dada por:

$$S(i) = \frac{a(i) - b(i)}{\max\{a(i), b(i)\}} \quad (5.6)$$

onde  $a$  é a distância média calculada do  $i$ -ésimo ponto para os outros pontos no mesmo cluster, e  $b$  é a distância média mínima calculada do  $i$ -ésimo ponto para todos os outros pontos dos outros clusters.

Como a *Silhouette* retorna um valor para cada ponto, sendo 27 o número de ensaios onde foram aplicados os DTs (Tabela 1) e 100 pontos por ensaio, foi proposto um valor médio e o desvio padrão de *Silhouette* para cada nível Wavelet, considerando todos os pontos:

$$Sm_j = \frac{1}{N} \sum_{i=1}^N S_j(i) \quad (5.7)$$

onde  $N$  é o número total de pontos e  $S_j$  é o valor de *Silhouette* dos pontos dos coeficientes de aproximação ou detalhe do nível Wavelet  $j$  e

$$\sigma_j = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - Sm_j)^2} \quad (5.8)$$

onde  $N$  é o número total de pontos e  $\sigma_j$  é o valor do desvio padrão dos pontos dos coeficientes de aproximação ou detalhe do nível Wavelet  $j$ .

## Capítulo 6

# Análise dos resultados

*Neste trabalho, a Transformada Wavelet Discreta foi aplicada aos sinais de EA obtidos pelos sensores piezoelétricos. A seguir, os valores da Energia Ponderada pela Passagem por Zero (EZ) dos coeficientes de aproximação e detalhe foram calculados com a finalidade de detectar, identificar e classificar as condições de DT na alimentação de um MIT por meio de um método de agrupamento de dados. Neste Capítulo, os resultados dos experimentos e da aplicação das técnicas de processamento serão apresentados. Por fim, os gráficos e valores resultantes da aplicação do novo índice desenvolvido serão analisados e discutidos.*

## 6.1 Resposta em frequência do sensor piezoelétrico de baixo custo


Como este trabalho propõe uma nova abordagem de EA utilizando um sensor não-comercial, é obrigatório certificar-se previamente se a resposta em frequência deste sensor é adequada para a experiência proposta. O teste da quebra do grafite, do inglês, *Pencil Lead Break* (PLB) é um método bem conhecido para estimar a resposta por impulso para um sensor específico (MARCHI *et al.*, 2015; LATHI, 2003).

Quando o grafite do lápis rompe na superfície do estator, é gerado um sinal intenso que pode ser assumido como um impulso. No domínio da frequência, este impulso representa uma função degrau que cobre todas os valores de frequência, permitindo estimar qual banda o sensor é capaz de detectar (MARCHI *et al.*, 2015; LATHI, 2003).

Na Figura 47, a resposta ao impulso para os sensores piezoelétricos de baixo custo pode ser observada. A Densidade Espectral de Potência, do inglês, *Power Spectral Density* (PSD) apresenta uma atenuação de 3 dB para cerca de 100 kHz,

o que valida este sensor para aplicações de som e ultra-som além de ser um valor satisfatório para a detecção de falhas nos MITs, sendo que a informação relevante é normalmente confinada até 20 kHz (CUSIDO *et al.*, 2008; ROMERO-TRONCOSO *et al.*, 2016).

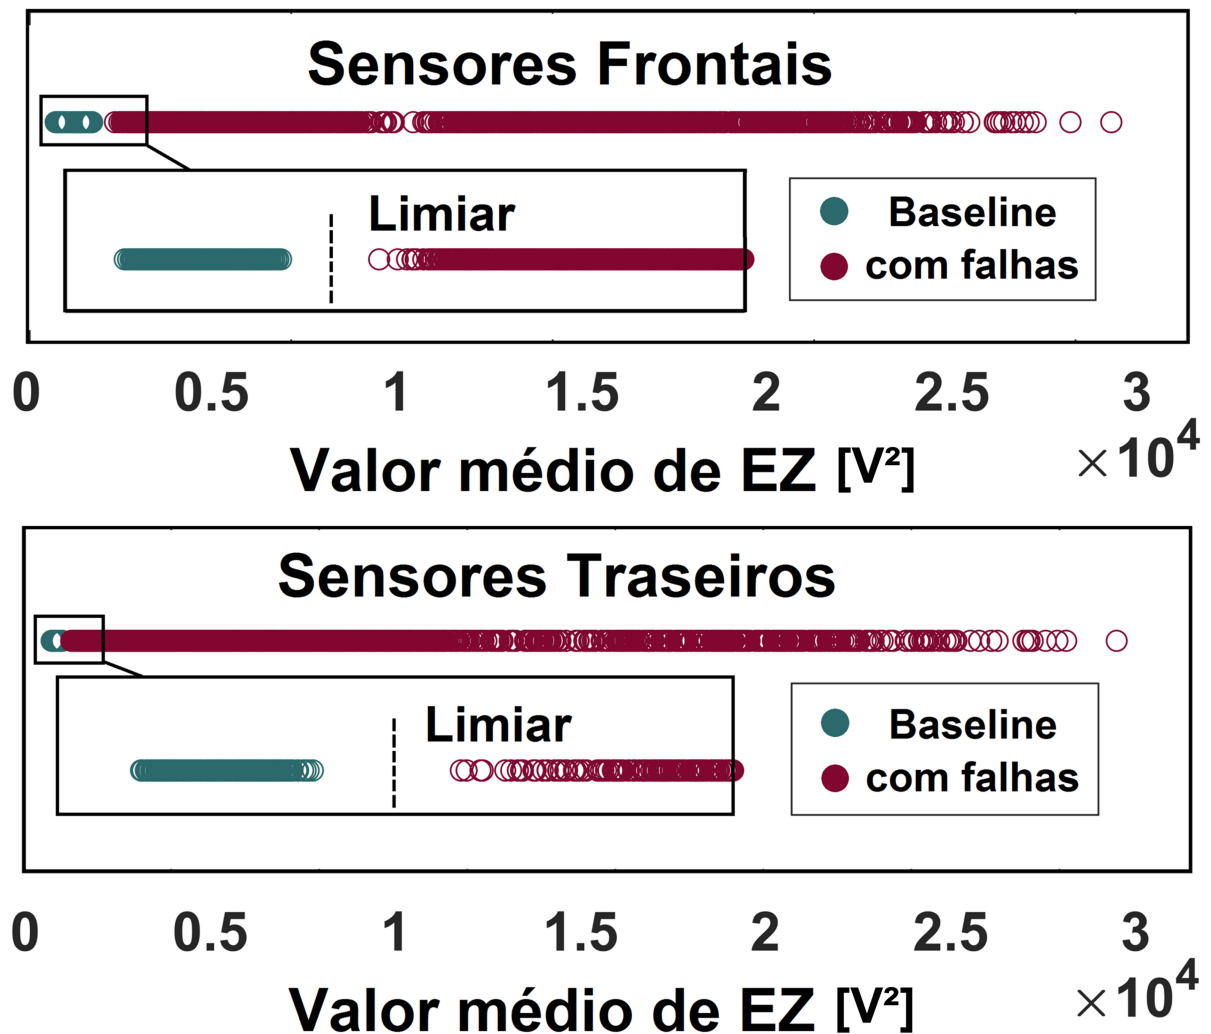
Figura 47 – PSD do PLB aplicado ao sensor piezoelétrico



Fonte: Próprio autor

## 6.2 Detecção do desequilíbrio de tensão

Antes de identificar qual fase foi afetada por uma tensão desequilibrada, é necessário detectar a ocorrência do desequilíbrio em si. A detecção foi realizada por meio dos valores médios de  $\bar{EZ}$  (Equação 5.3) para os quatro sensores frontais. Estes valores foram calculados para a *baseline* (situação sem falha: ensaios n° 1, 11, 21) e para todas as situações de DT propostas neste trabalho. Na Figura 48, os valores de  $\bar{EZ}$  para cada ensaio são apresentados ao longo de uma reta, mostrando que existe um valor limiar de  $\bar{EZ}$  que permite detectar a ocorrência de uma falha, independente de sua magnitude. Como descrito na metodologia, todos os ensaios foram repetidos para os sensores na posição traseira (Sensores 5, 6, 7 e 8), os resultados para essa configuração também estão ilustrados na Figura 48. Finalmente, se alguma falha for detectada, o índice desenvolvido também é capaz de identificar qual fase foi afetada, conforme será descrito na subseção seguinte.

Figura 48 – Valores limiares de  $EZ$  para detecção de DT


Fonte: Próprio autor

### 6.3 Identificação da fase desequilibrada


Como visto durante a investigação preliminar (Figura 45), os valores  $EZ_{d1}$  para três sensores diferentes foram associados a cada eixo de um gráfico 3D. Feito isso, foi possível observar o comportamento notável de agrupamento em relação a cada fase afetada pelo DT. Na Figura 49, são apresentados os três clusters para porcentagem de desequilíbrio de tensão de 50% para as três fases (ensaios n° 6, n° 16 e n° 26) e seus respectivos centroides, contendo 100 pontos cada (relembrando que cada ensaio foi repetido 100 vezes).

Figura 49 – Agrupamento obtido durante os testes preliminares

### Sensores dianteiros



### Sensores traseiros




Fonte: Próprio autor

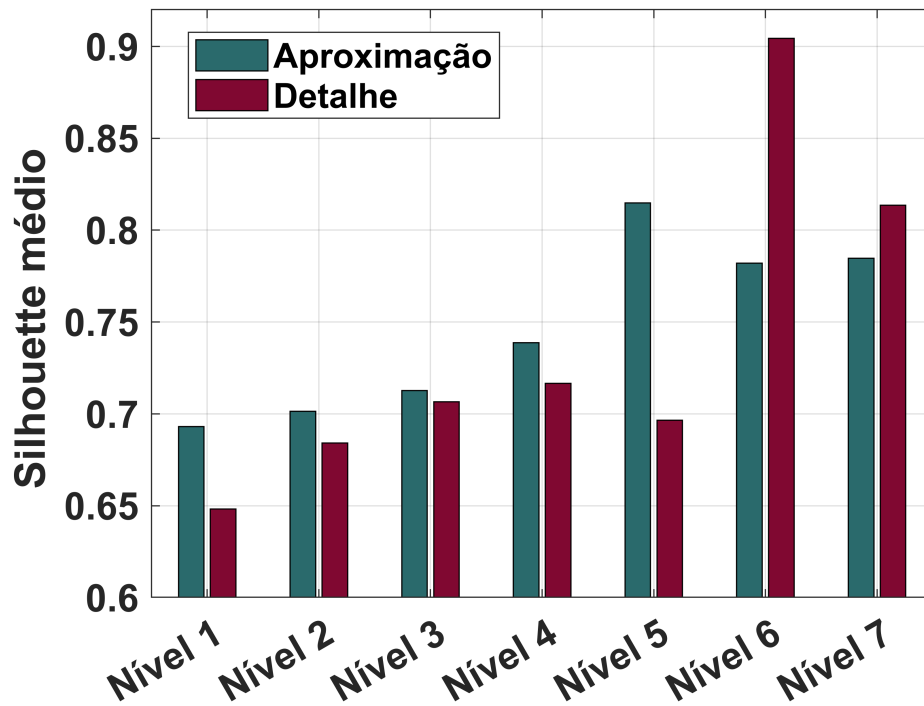
No entanto, com o objetivo de estabelecer qual o nível e coeficiente Wavelet mais eficiente para a identificação de fase, foram calculados os parâmetros estatísticos propostos. Através dos centroides (vistos na Figura 45), é possível calcular os índices *Silhouette* médio e o desvio padrão para cada coeficiente e nível de Wavelet, utilizando as Equações (5.7) e (5.8). Os resultados desta avaliação são apresentados nas Figuras 50, 51, 52 e 53.

Estas Figuras revelam que os coeficientes de detalhe ao nível 6 mostram os valores de *Silhouette* mais próximos de 1 e os menores valores de desvio padrão tanto para os sensores frontais como para os sensores traseiros. A principal razão para o melhor desempenho dos coeficientes de detalhe deve-se às componentes de EA que os DTs impõem ao sistema. Estas componentes possuem valores mais elevados em frequência quando comparadas com a frequência fundamental do motor operando em condições idealmente balanceadas. Por conseguinte, todos os resultados seguintes se baseiam nos coeficientes de detalhe de nível 6.

Figura 50 – Índice *Silhouette* médio para os sensores frontais

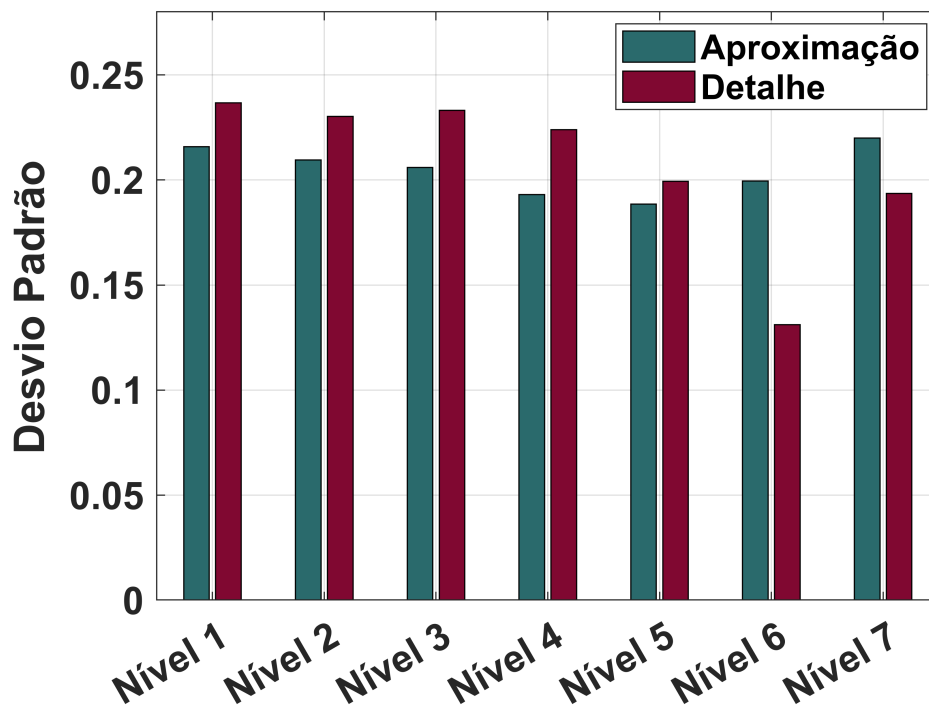


Fonte: Próprio autor

Figura 51 – Índice *Silhouette* médio para os sensores traseiros


Fonte: Próprio autor

Figura 52 – Desvio padrão médio para os sensores frontais



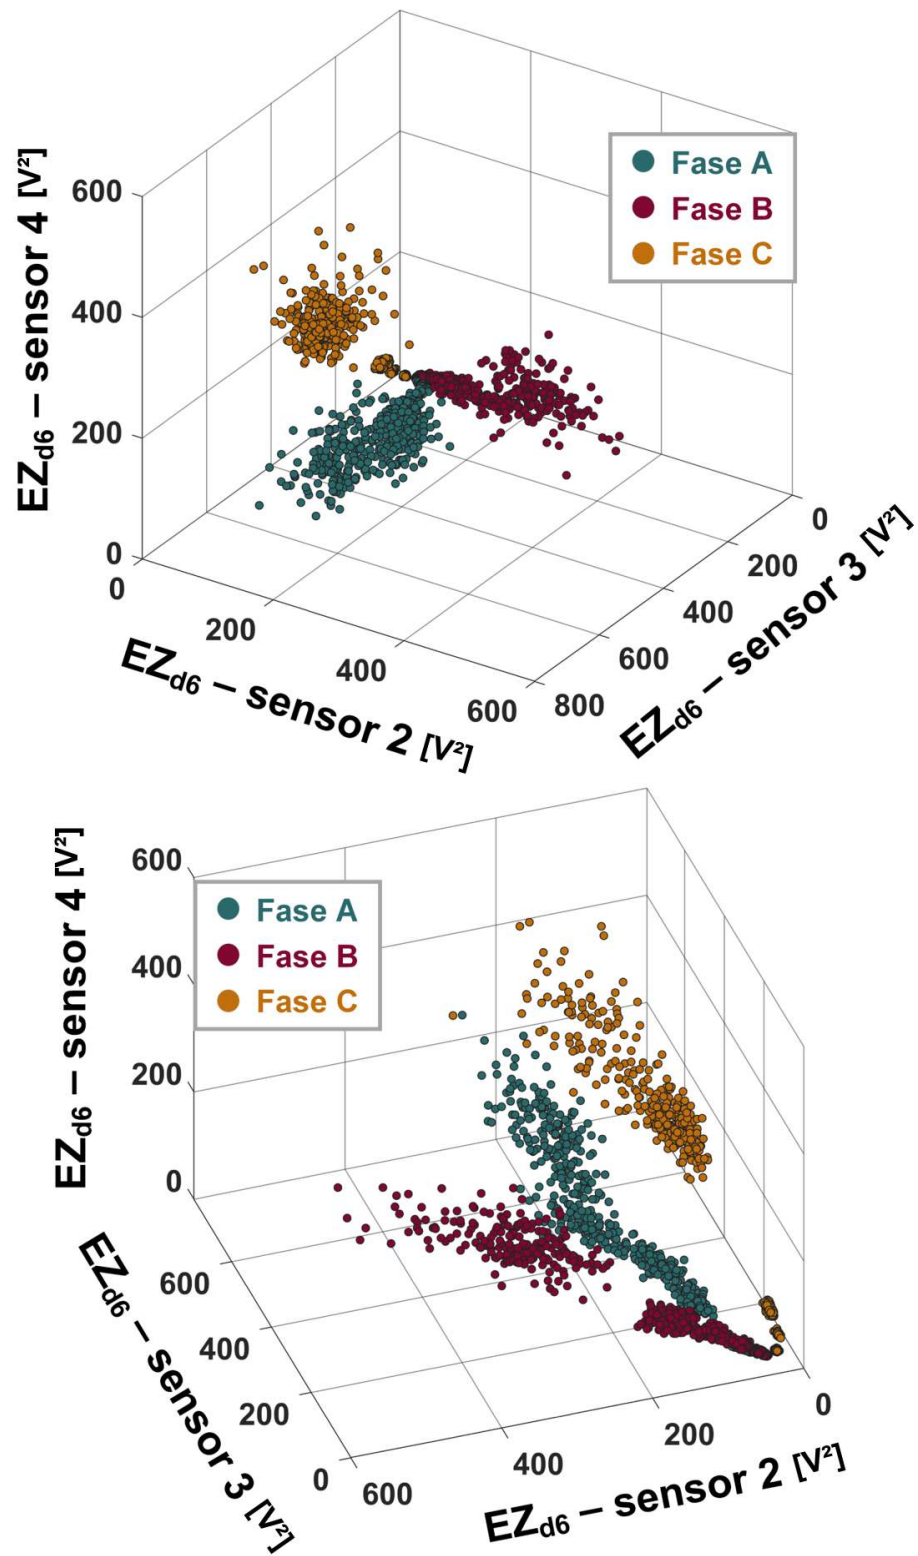
Fonte: Próprio autor

Figura 53 – Desvio padrão médio para os sensores frontais




Fonte: Próprio autor

Como a Figura 49 apresenta o agrupamento entre as fases A, B e C para apenas uma porcentagem de DT, o mesmo algoritmo foi aplicado para todos os ensaios, resultando em um gráfico 3D. Considerando os 27 ensaios onde foram aplicados os DTs (Tabela 1) e os 100 pontos por ensaio, o número total de pontos é de 2700. As Figuras 54 e 55 contêm os valores de  $EZ$  para os sensores frontais com quatro posições diferentes de rotação do mesmo gráfico. A figura mostra que, mesmo quando todos os níveis de falhas foram plotados no mesmo espaço cartesiano, as distâncias euclidianas entre os clusters para cada fase elétrica foram mantidas, resultando em altos valores de *Silhouette* e permitindo a identificação da fase afetada. Além disso, pode-se notar que os pontos mostraram maior dispersão à medida que as falhas se tornaram mais graves. Entretanto, o agrupamento não foi afetado, como mostra o índice de *Silhouette*, como visto nas Figuras 50 e 51. Da mesma forma, as Figuras 56 e 57 apresentam os valores de  $EZ$  para os sensores traseiros com quatro posições de rotação diferentes. As mesmas afirmações estabelecidas para os sensores frontais podem ser feitas para os sensores traseiros.

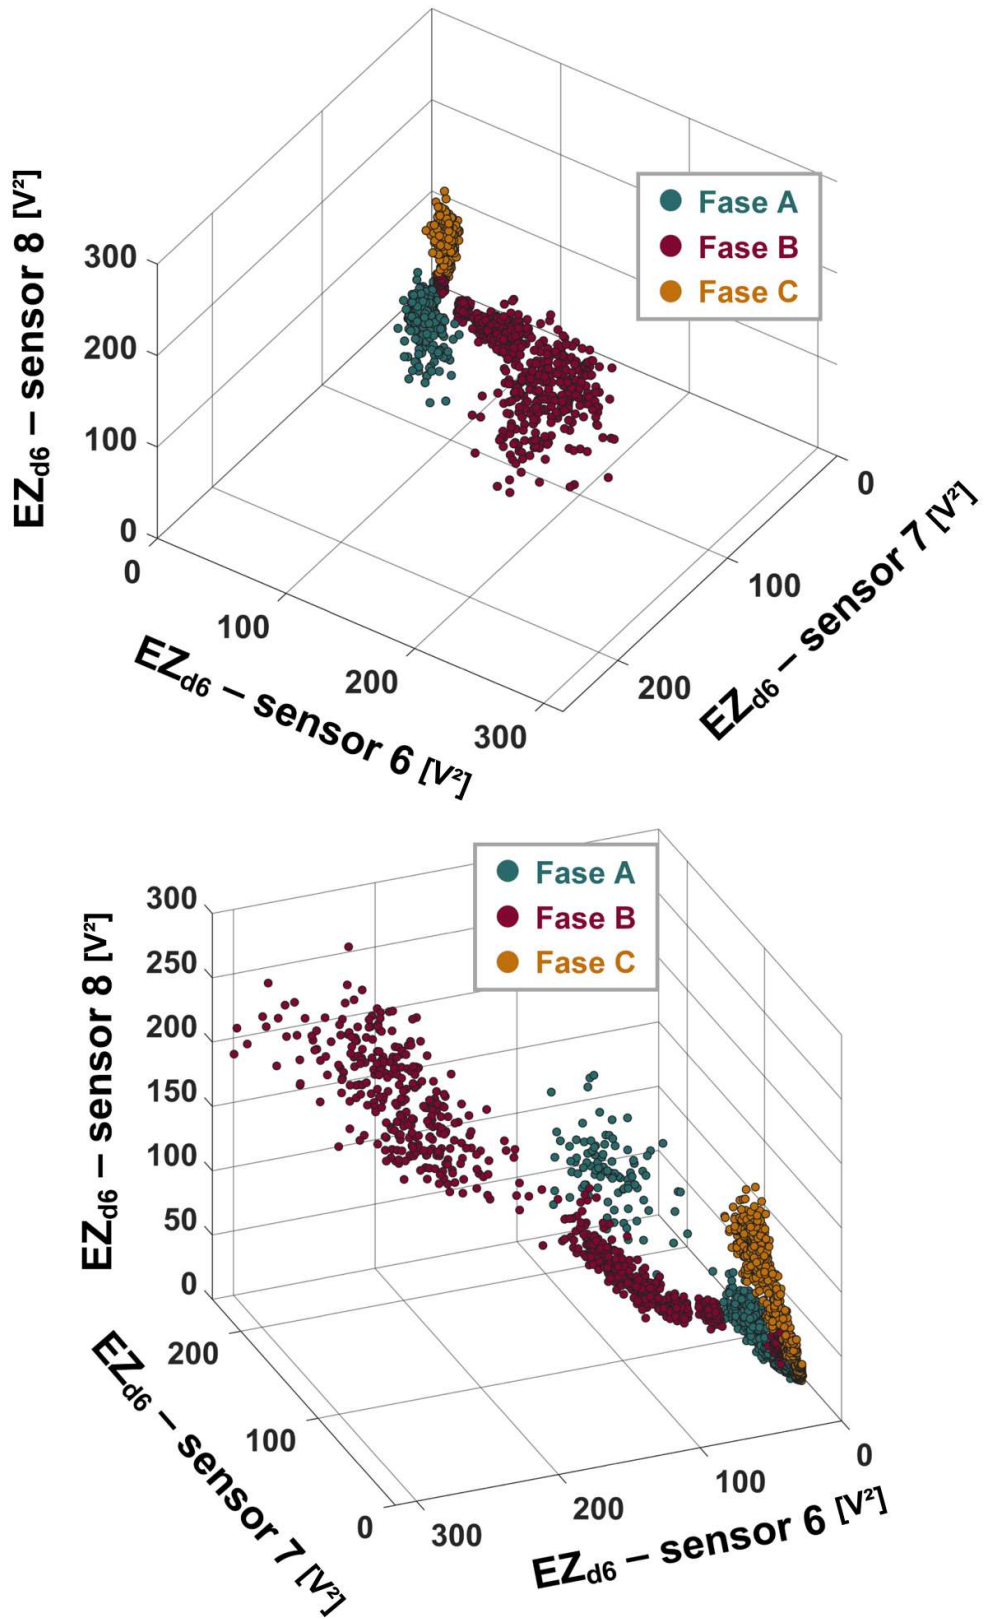
Figura 54 – Agrupamento das fases afetadas utilizando o valor de  $EZ_{d6}$  nos sensores frontais

Fonte: Próprio autor

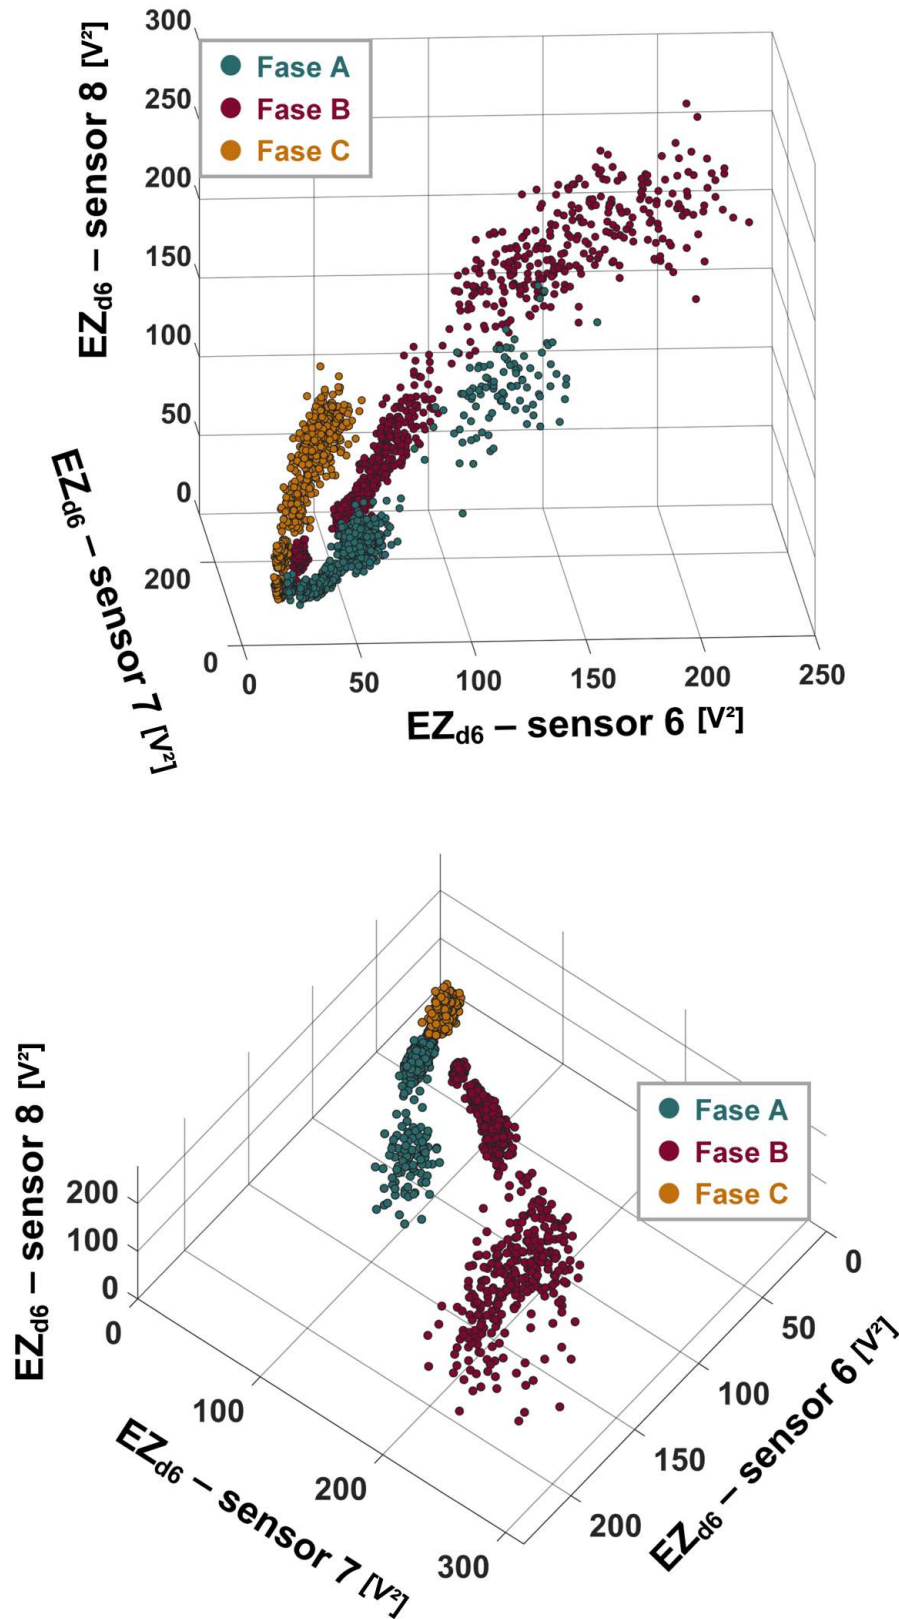
Figura 55 – Agrupamento das fases afetadas utilizando o valor de  $EZ_{d6}$  nos sensores frontais



Fonte: Próprio autor

Figura 56 – Agrupamento das fases afetadas utilizando o valor de  $EZ_{d6}$  nos sensores traseiros

Fonte: Próprio autor

Figura 57 – Agrupamento das fases afetadas utilizando o valor de  $EZ_{d6}$  nos sensores traseiros

Fonte: Próprio autor

A análise visual destas Figuras reitera os elevados valores de *Silhouette* apresentados nas Figuras 50 e 51. Além disso, afirma a ausência de interdependência entre a posição do sensor (frente ou verso) e a eficácia do método proposto. Além disso, após o processamento do sinal, verificou-se que qualquer combinação de três dos sensores apresentava valores de *Silhouette* muito semelhantes. Por conseguinte, foram escolhidos aleatoriamente os sensores 2, 3 e 4 (frontal) e 6, 7 e 8 (traseiro).


Por fim, conhecendo os centroides relativos a cada fase afetada, é possível identificar a fase afetada de uma amostra qualquer. Para isto, basta realizar o cálculo do valor de  $EZ_{d6}$  de três sensores, obter a coordenada  $(EZ_{d6}^{S_1}, EZ_{d6}^{S_2}, EZ_{d6}^{S_3})$  e verificar a qual centroide essa coordenada está mais próxima.

### 6.3.1 Classificação da porcentagem de DT

Após a detecção do DT e da identificação da fase afetada, a porcentagem de DT pode ser avaliada utilizando uma regressão dos valores de energia dos coeficientes de aproximação dos quatro sensores (Equação 4.2). Uma vez que foram realizados 100 experimentos para cada porcentagem de desequilíbrio, os coeficientes de determinação  $R^2$  médios para as curvas de Energia *vs* Porcentagem de DT foram calculados e comparados para todos os níveis de Wavelet. As Figuras 58, 59, 60, 61, 62 e 63 apresentam os valores médios de  $R^2$  para todos os sensores (frontais e traseiros) e para as três fases. Os coeficientes de aproximação demonstraram melhores resultados pois, ao contrário da identificação das fases afetadas, a magnitude do DT está mais fortemente correlacionado com a amplitude dos sinais do que com a sua forma.


Nota-se que cada sensor apresentou desempenhos diferentes dependendo da fase afetada, reiterando o comportamento descrito anteriormente em relação às variações de sinal para o mesmo sensor dependendo da natureza do DT (Figura 43). Portanto, a identificação da fase definida na seção anterior é um pré-requisito para se atingir a classificação de porcentagem. Por fim, cada fase contém ao menos um sensor e nível de Wavelet com um valor suficiente de  $R^2$ , permitindo a regressão e classificando a magnitude do DT para qualquer situação possível.

Figura 58 –  $R^2$  da curva Energia *vs* Porcentagem de DT para a Fase A utilizando os valores referentes aos sensores frontais




Fonte: Próprio autor

Figura 59 –  $R^2$  da curva Energia *vs* Porcentagem de DT para a Fase B utilizando os valores referentes aos sensores frontais




Fonte: Próprio autor

Figura 60 –  $R^2$  da curva Energia *vs* Porcentagem de DT para a Fase C utilizando os valores referentes aos sensores frontais




Fonte: Próprio autor

Figura 61 –  $R^2$  da curva Energia *vs* Porcentagem de DT para a Fase A utilizando os valores referentes aos sensores traseiros




Fonte: Próprio autor

Figura 62 –  $R^2$  da curva Energia *vs* Porcentagem de DT para a Fase B utilizando os valores referentes aos sensores traseiros



Fonte: Próprio autor

Figura 63 –  $R^2$  da curva Energia *vs* Porcentagem de DT para a Fase C utilizando os valores referentes aos sensores traseiros




Fonte: Próprio autor

Como exemplos, utilizando o nível Wavelet 1, as regressões para as Fase A, B e C foram apresentadas nas Figuras 64, 65 e 66 para os sensores frontais e nas Figuras 67, 68 e 69 para os sensores traseiros.

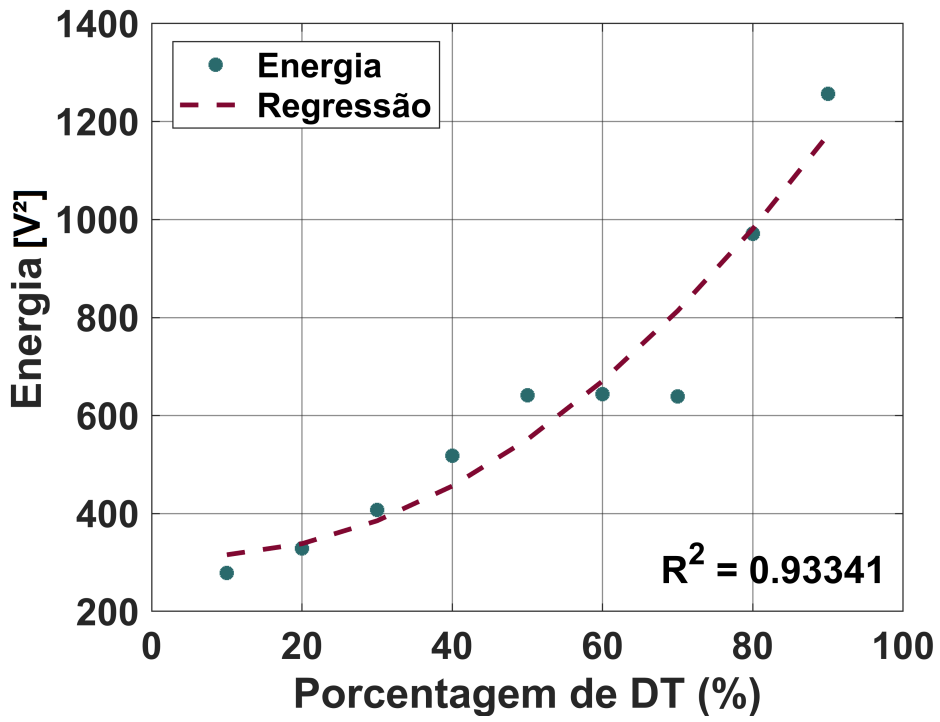
Portanto, a classificação da porcentagem do DT aplicado ao MIT pode ser atingida através dos valores de energia dos coeficientes Wavelet, uma vez que os valores de  $R^2$  demonstraram forte correlação desses valores com a magnitude do desequilíbrio de tensão.

Figura 64 – Regressão linear para Fase A utilizando o sensor frontal 4




Fonte: Próprio autor

Figura 65 – Regressão linear para Fase B utilizando o sensor frontal 2




Fonte: Próprio autor

Figura 66 – Regressão linear para Fase C utilizando o sensor frontal 1




Fonte: Próprio autor

Figura 67 – Regressão linear para Fase A utilizando o sensor traseiro 6




Fonte: Próprio autor

Figura 68 – Regressão linear para Fase B utilizando o sensor traseiro 7



Fonte: Próprio autor

Figura 69 – Regressão linear para Fase C utilizando o sensor traseiro 8



Fonte: Próprio autor

## Capítulo 7

# Conclusão

Devido ao papel crucial dos MITs nos processos industriais, qualquer paralisação pode resultar em diversas perdas econômicas e de produtividade. Portanto, é fundamental desenvolver técnicas que sejam capazes de monitorar esses dispositivos. Além disso, são de grande vantagem as técnicas não destrutivas que permitam detectar, identificar e classificar as situações não ideais de trabalho, sem que o funcionamento da máquina seja alterado. Dentro deste contexto, o desequilíbrio de tensão se destaca como uma condição potencialmente prejudicial, não só por ser frequente, mas também porque leva ao desgaste mecânico dos enrolamentos, sobreaquecimento, ruído excessivo e resulta na redução do torque na máquina. Reiterando, desta forma, a relevância do desenvolvimento de sistemas para análise dos DTs.

Sendo assim, a técnica de análise das emissões acústicas mostra-se como uma solução adequada para o estudo dos DTs pois, além de ser um TNI, também se mostrou promissora em trabalhos anteriores envolvendo diagnóstico de falhas em máquinas elétricas. Adicionalmente, neste trabalho, os sinais de EA foram obtidos por meio de sensores piezoelétricos de baixo custo, que são uma alternativa para viabilizar os sistemas baseados nesta técnica, uma vez que os sensores comerciais de EA tem custo elevado. É importante também frisar que os resultados alcançados neste trabalho confirmaram a eficácia destes sensores na obtenção de sinais de EA visando o diagnóstico de MITs.

Neste contexto, o ponto fundamental desta dissertação foi a elaboração do índice de Energia Ponderada pela Passagem por Zero (*EZ*). Esse parâmetro, que se utiliza da aplicação da Transformada Wavelet, foi essencial para que o objetivo de diagnosticar o DT em motores de indução através dos sensores piezoelétricos fosse alcançado. Além de garantir a independência de sistemas inteligentes e de inteligências artificiais, o novo índice permitiu um diagnóstico inédito e simultâneo de detecção, identificação e classificação da magnitude dos DTs.

Após os experimentos e o processamento de dados, o método baseado no novo parâmetro *EZ* provou ser capaz de realizar o diagnóstico proposto, por meio da técnica de agrupamento de dados. Detectou com sucesso a ocorrência do DT, identificou qual fase elétrica foi afetada pela tensão desequilibrada e classificou a porcentagem de desequilíbrio. Ainda, o sistema proposto permite detectar, com rápido tempo de resposta, anormalidades na alimentação de tensão. Também é relevante notar que a nova técnica aplicada neste trabalho não depende das posições dos sensores ao longo do eixo axial, uma vez que, tanto os ensaios com o grupo de sensores traseiros, tanto com os ensaios com o grupo de sensores dianteiros geraram resultados igualmente satisfatórios.

Como a aplicação do novo parâmetro *EZ* na análise dos sinais de EA obtidos por sensores piezoelétricos mostraram resultados satisfatórios para o diagnóstico de DTs, esta técnica pode ser testada para outros tipos de falhas mecânicas e elétricas em trabalhos futuros relacionados a máquinas elétricas. O diagnóstico de DTs em mais de uma fase simultaneamente também pode ser estudado. Além disso, as sobretensões podem ser estudadas, uma vez que o desequilíbrio de tensão neste trabalho foi aplicado apenas por subtensão nas fases elétricas. Por fim, como este trabalho tem como principal foco o desenvolvimento de uma técnica de processamento de sinal, não foi proposto um sistema embarcado capaz de realizar o monitoramento de DTs. No entanto, esse tipo de aplicação também pode ser abordada em um trabalho futuro.

## REFERÊNCIAS

- ADEKITAN, A. I.; SAMUEL, I.; AMUTA, E. Dataset on the performance of a three phase induction motor under balanced and unbalanced supply voltage conditions. **Data in Brief**, Elsevier BV, v. 24, p. 103947, jun. 2019. Disponível em: <<https://doi.org/10.1016/j.dib.2019.103947>>.
- AKCAY, H.; GERMEN, E.; TURKAY, S. Induction motor identification from acoustic noise spectrum by a covariance subspace algorithm. In: **2018 IEEE 14th International Conference on Control and Automation (ICCA)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/icca.2018.8444181>>.
- AL-BADRI, M.; PILLAY, P.; ANGERS, P. A novel technique for *In situ* efficiency estimation of three-phase IM operating with unbalanced voltages. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 52, n. 4, p. 2843–2855, jul. 2016. Disponível em: <<https://doi.org/10.1109/tia.2016.2533599>>.
- ALHAWARAT, M.; HEGAZI, M. Revisiting K-Means and Topic Modeling, a Comparison Study to Cluster Arabic Documents. **IEEE Access**, v. 6, p. 42740–42749, 2018. ISSN 2169-3536.
- ALI, M. Z. *et al.* Machine learning-based fault diagnosis for single- and multi-faults in induction motors using measured stator currents and vibration signals. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 55, n. 3, p. 2378–2391, maio 2019. Disponível em: <<https://doi.org/10.1109/tia.2019.2895797>>.
- 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**, v. 11, n. 1, p. 524–533, jan. 2020. ISSN 1949-3037.
- AMEID, T. *et al.* Rotor resistance estimation using extended kalman filter and spectral analysis for rotor bar fault diagnosis of sensorless vector control induction motor. **Measurement**, Elsevier BV, v. 111, p. 243–259, dez. 2017. Disponível em: <<https://doi.org/10.1016/j.measurement.2017.07.039>>.
- Analog Devices. **Small, Low Power, 3-Axis +-3 g Accelerometer**. 2010. <<https://www.analog.com/media/en/technical-documentation/data-sheets/ADXL335.pdf>>. [Online; Acessado em 04/05/2020].
- ANEEL. Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST - Módulo 8 – Qualidade da Energia Elétrica. **PRODIST - Módulo 8**, 2018. Disponível em: <<http://app.aneel.gov.br/modulo-8>>.
- ARATO, A. **Manutenção Preditiva Utilizando Análise de Vibrações**. Barueri, SP: Manole, 2004. ISBN 85-204-1596-2.

AREE, P. Effects of unbalanced voltage on induction motor operating points under different load torque profiles. In: **2016 13th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)**. IEEE, 2016. Disponível em: <<https://doi.org/10.1109/ecticon.2016.7561443>>.

ARNAU, A. **Piezoelectric transducers and applications**. New York: Springer, 2008. ISBN 978-3-540-77507-2.

AZAMFAR, M. *et al.* Multisensor data fusion for gearbox fault diagnosis using 2-d convolutional neural network and motor current signature analysis. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 144, p. 106861, out. 2020. Disponível em: <<https://doi.org/10.1016/j.ymssp.2020.106861>>.

BAGGINI, A. **Handbook of power quality**. Chichester, England Hoboken, NJ: John Wiley & Sons, 2008. ISBN 978-0-470-06561-7.

BOASHASH, B. **Time frequency signal analysis and processing : a comprehensive reference**. Amsterdam Boston: Academic Press, 2016. ISBN 978-0-12-398499-9.

BRIGHAM, E. O.; MORROW, R. E. The fast fourier transform. **IEEE Spectrum**, Institute of Electrical and Electronics Engineers (IEEE), v. 4, n. 12, p. 63–70, dez. 1967. Disponível em: <<https://doi.org/10.1109/mspec.1967.5217220>>.

BURRUS, C. S. **Introduction to wavelets and wavelet transforms : a primer**. Upper Saddle River, N.J: Prentice Hall, 1998. ISBN 0134896009.

CAMPBELL, M.; ARCE, G. Effect of motor voltage unbalance on motor vibration: Test and evaluation. In: **2016 Petroleum and Chemical Industry Technical Conference (PCIC)**. IEEE, 2016. Disponível em: <<https://doi.org/10.1109/pcicon.2016.7589243>>.

CAMPBELL, M.; ARCE, G. Effect of motor voltage unbalance on motor vibration: Test and evaluation. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 54, n. 1, p. 905–911, jan. 2018. Disponível em: <<https://doi.org/10.1109/tia.2017.2759085>>.

CARVALHO, L. *et al.* Undervoltage identification in three phase induction motor using low-cost piezoelectric sensors and STFT technique. **Proceedings**, MDPI AG, v. 42, n. 1, p. 72, nov. 2019. Disponível em: <<https://doi.org/10.3390/ecsa-6-06644>>.

CASTRO, B. A. de; BAPTISTA, F. G.; CIAMPA, F. Comparative analysis of signal processing techniques for impedance-based SHM applications in noisy environments. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 126, p. 326–340, jul. 2019. Disponível em: <<https://doi.org/10.1016/j.ymssp.2019.02.034>>.

CASTRO, B. A. de *et al.* A chromatic technique for structural damage detection under noise effects based on impedance measurements. **Measurement Science and Technology**, IOP Publishing, v. 30, n. 7, p. 075601, maio 2019. Disponível em: <<https://doi.org/10.1088/1361-6501/ab0fe2>>.

CASTRO, B. A. de *et al.* Assessment of macro fiber composite sensors for measurement of acoustic partial discharge signals in power transformers. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 17, n. 18, p. 6090–6099, set. 2017. Disponível em: <<https://doi.org/10.1109/jsen.2017.2735858>>.

CHAUDHURY, S. B.; GUPTA, S. Online identification of AC motor misalignment using current signature analysis and modified k-mean clustering technique. In: **2006 IEEE International Conference on Industrial Technology**. IEEE, 2006. Disponível em: <<https://doi.org/10.1109/icit.2006.372621>>.

CHAUHAN, S.; SINGH, S. B. Effects of voltage unbalance and harmonics on 3-phase induction motor during the condition of undervoltage and overvoltage. In: **2019 6th International Conference on Signal Processing and Integrated Networks (SPIN)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/spin.2019.8711753>>.

CHAWLA, R.; VINAYAK, B. A.; JAGADANAND, G. Modelling and detection of stator incipient open circuit fault in three-phase induction motor. In: **2018 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/pedes.2018.8707681>>.

CHEN, B. *et al.* Fault diagnosis method based on integration of RSSD and wavelet transform to rolling bearing. **Measurement**, Elsevier BV, v. 131, p. 400–411, jan. 2019. Disponível em: <<https://doi.org/10.1016/j.measurement.2018.07.043>>.

CHEN, P.-Y.; CHAO, K.-H.; TSENG, Y.-C. A motor fault diagnosis system based on cerebellar model articulation controller. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 120326–120336, 2019. Disponível em: <<https://doi.org/10.1109/access.2019.2937103>>.

CHEN, X.; FENG, Z. Time-frequency space vector modulus analysis of motor current for planetary gearbox fault diagnosis under variable speed conditions. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 121, p. 636–654, abr. 2019. Disponível em: <<https://doi.org/10.1016/j.ymssp.2018.11.049>>.

CHEN, X.; FENG, Z. Induction motor stator current analysis for planetary gearbox fault diagnosis under time-varying speed conditions. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 140, p. 106691, jun. 2020. Disponível em: <<https://doi.org/10.1016/j.ymssp.2020.106691>>.

CHEN, X.; YANG, Y. Analysis of the partial discharge of ultrasonic signals in large motor based on hilbert-huang transform. **Applied Acoustics**, Elsevier BV, v. 131, p. 165–173, fev. 2018. Disponível em: <<https://doi.org/10.1016/j.apacoust.2017.10.028>>.

CHENG, Y. *et al.* Open-circuit fault diagnosis of traction inverter based on compressed sensing theory. **Chinese Journal of Electrical Engineering**, Institute of Electrical and Electronics Engineers (IEEE), v. 6, n. 1, p. 52–60, mar. 2020. Disponível em: <<https://doi.org/10.23919/cjee.2020.000004>>.

CHERNYAVSKA, I.; VITEK, O. Analysis of air-gap eccentricity in inverter fed induction motor by means of motor current signature analysis and stray flux of motor. In: **2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)**. IEEE, 2017. Disponível em: <<https://doi.org/10.1109/demped.2017.8062336>>.

COHEN, L. **Time-frequency analysis**. Englewood Cliffs, N.J: Prentice Hall PTR, 1995. ISBN 0135945321.

CRISTALLI, C.; PAONE, N.; RODRÍGUEZ, R. Mechanical fault detection of electric motors by laser vibrometer and accelerometer measurements. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 20, n. 6, p. 1350–1361, ago. 2006. Disponível em: <<https://doi.org/10.1016/j.ymssp.2005.11.013>>.

CURIE, J.; CURIE, P. Développement par compression de l'électricité polaire dans les cristaux hémihédres à faces inclinées. **Bulletin de minéralogie**, Persée-Portail des revues scientifiques en SHS, v. 3, n. 4, p. 90–93, 1880.

CUSIDO, J. *et al.* Fault detection in induction machines using power spectral density in wavelet decomposition. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 55, n. 2, p. 633–643, 2008. Disponível em: <<https://doi.org/10.1109/tie.2007.911960>>.

DAINTITH, J. **A dictionary of physics**. Oxford New York: Oxford University Press, 2009. ISBN 9780199233991.

DASH, R. N.; SAHU, S.; PANIGRAHI, C. K. Effect and analysis of unbalanced voltage on induction motor torque. In: **2018 International Conference on Recent Innovations in Electrical, Electronics & Communication Engineering (ICRIEECE)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/icrieece44171.2018.9009287>>.

DHAMAL, S. S.; BHATKAR, M. V. Modelling and simulation of three-phase induction motor to diagnose the performance on inter-turn short circuit fault in stator winding. In: **2018 International Conference on Computing, Power and Communication Technologies (GUCON)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/gucon.2018.8674900>>.

DIAS, C. G.; PEREIRA, F. H. Broken rotor bars detection in induction motors running at very low slip using a hall effect sensor. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 18, n. 11, p. 4602–4613, jun. 2018. Disponível em: <<https://doi.org/10.1109/jsen.2018.2827204>>.

DONOLO, P.; BOSSIO, G.; ANGELO, C. D. Analysis of voltage unbalance effects on induction motors with open and closed slots. **Energy Conversion and Management**, Elsevier BV, v. 52, n. 5, p. 2024–2030, maio 2011. Disponível em: <<https://doi.org/10.1016/j.enconman.2010.10.045>>.

DONOLO, P. *et al.* Voltage unbalance and harmonic distortion effects on induction motor power, torque and vibrations. **Electric Power Systems Research**, Elsevier BV, v. 140, p. 866–873, nov. 2016. Disponível em: <<https://doi.org/10.1016/j.epsr.2016.04.018>>.

DROZG, A. *et al.* On the performance of direct piezoelectric rotational accelerometers in experimental structural dynamics. **Measurement**, Elsevier BV, v. 127, p. 292–298, out. 2018. Disponível em: <<https://doi.org/10.1016/j.measurement.2018.05.081>>.

FAIZ, J. **Fault diagnosis of induction motors**. London: Institution of Engineering and Technology, 2017. ISBN 978-1-78561-328-9.

FAIZ, J.; EBRAHIMPOUR, H. Precise derating of three phase induction motors with unbalanced voltages. **Energy Conversion and Management**, Elsevier BV, v. 48, n. 9, p. 2579–2586, set. 2007. Disponível em: <<https://doi.org/10.1016/j.enconman.2007.03.023>>.

FERREIRA, F. J. T. E.; ALBERTO, J.; ALMEIDA, A. T. de. Voltage unbalance impact on coil-side temperature rise in a delta-connected, dual-winding induction motor. In: **2020 IEEE International Conference on Industrial Technology (ICIT)**. IEEE, 2020. Disponível em: <<https://doi.org/10.1109/icit45562.2020.9067201>>.

FERREIRA, F. J. T. E.; LEPRETTRE, B.; ALMEIDA, A. T. de. Comparison of protection requirements in IE2-, IE3-, and IE4-class motors. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 52, n. 4, p. 3603–3610, jul. 2016. Disponível em: <<https://doi.org/10.1109/tia.2016.2545647>>.

FIRETEANU, V. *et al.* Analysis of the evolution of stator short-circuit and rotor bar breakage faults in a squirrel-cage induction motor. In: **2018 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/speedam.2018.8445226>>.

FIRETEANU, V.; TARAS, P. Diagnosis of induction motor rotor faults based on finite element evaluation of voltage harmonics of coil sensors. In: **2012 IEEE Sensors Applications Symposium Proceedings**. IEEE, 2012. Disponível em: <<https://doi.org/10.1109/sas.2012.6166292>>.

FLUKE. **Câmera de infravermelho Fluke TiS65**. 2020. <<https://dam-assets.fluke.com/s3fs-public/flukeig/products/images/infrared-camera/jpeg/f-tis65-08a-1500x1000.jpg>>. [Online; Acessado em 04/05/2020].

FLUKE. **Fluke 80i-110s AC/DC Current Clamp**. 2020. <[https://dam-assets.fluke.com/s3fs-public/flukeig/products/images/accessories/jpeg/80i110s\\_01h-1500x1000.jpg](https://dam-assets.fluke.com/s3fs-public/flukeig/products/images/accessories/jpeg/80i110s_01h-1500x1000.jpg)>. [Online; Acessado em 04/05/2020].

FLUKE. **Fluke i400S AC Current Clamp**. 2020. <[https://res.cloudinary.com/iwh/image/upload/q\\_auto,g\\_center/w\\_1024,h\\_768,c\\_lpad/assets/1/26/FlukeI400S.jpg](https://res.cloudinary.com/iwh/image/upload/q_auto,g_center/w_1024,h_768,c_lpad/assets/1/26/FlukeI400S.jpg)>. [Online; Acessado em 04/05/2020].

FLUKE. **Sonda de temperatura DMM integrada 80BK-A**. 2020. <[https://dam-assets.fluke.com/s3fs-public/flukeig/products/images/accessories/jpeg/f-80bk-a\\_01a\\_h-1500x1000.jpg](https://dam-assets.fluke.com/s3fs-public/flukeig/products/images/accessories/jpeg/f-80bk-a_01a_h-1500x1000.jpg)>. [Online; Acessado em 04/05/2020].

FLUKE. **Termômetro digital HVAC infravermelho 561**. 2020. <[https://dam-assets.fluke.com/s3fs-public/flukeig/products/images/temperature/jpeg/f-561\\_01b\\_1500x1000.jpg](https://dam-assets.fluke.com/s3fs-public/flukeig/products/images/temperature/jpeg/f-561_01b_1500x1000.jpg)>. [Online; Acessado em 04/05/2020].

FLUKE. **Termômetro Fluke 1551a**. 2020. <[https://dam-assets.fluke.com/s3fs-public/styles/slideshow\\_thumbnail/public/flukeig/products/images/ptools-temperature/jpeg/f-1551ex-01a-1500x1000.jpg](https://dam-assets.fluke.com/s3fs-public/styles/slideshow_thumbnail/public/flukeig/products/images/ptools-temperature/jpeg/f-1551ex-01a-1500x1000.jpg)>. [Online; Acessado em 04/05/2020].

FORTESCUE, C. L. Method of symmetrical co-ordinates applied to the solution of polyphase networks. **Transactions of the American Institute of Electrical Engineers**, Institute of Electrical and Electronics Engineers (IEEE), XXXVII, n. 2, p. 1027–1140, jul. 1918. Disponível em: <<https://doi.org/10.1109/t-aiee.1918.4765570>>.

FOURIER, J.-B. J. Memoire sur la propagation de la chaleur dans les corps solides. In: **21 Institut national - Nouveau Bulletin des sciences par la Societe philomatique de Paris**). [S.l.: s.n.], 1807.

FRADEN, J. **Handbook of modern sensors : physics, designs, and applications**. Cham New York: Springer, 2016. ISBN 978-3-319-19302-1.

FREEDMAN, D. **Statistics**. New York: W.W. Norton, 1998. ISBN 0393929728.

FU, P. *et al.* Dynamic routing-based multimodal neural network for multi-sensory fault diagnosis of induction motor. **Journal of Manufacturing Systems**, Elsevier BV, v. 55, p. 264–272, abr. 2020. Disponível em: <<https://doi.org/10.1016/j.jmsy.2020.04.009>>.

FULNECCK, J.; MISAK, S. Stator current and axial magnetic flux analysis of induction motor. In: **2018 International Conference on Diagnostics in Electrical Engineering (Dagnostika)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/diagnostika.2018.8526025>>.

GANDHI, P.; TURK, D. N.; DAHIYA, D. R. Health monitoring of induction motors through embedded systems-simulation of broken rotor bar fault and abnormal gear teeth fault. **Microprocessors and Microsystems**, Elsevier BV, v. 76, p. 103077, jul. 2020. Disponível em: <<https://doi.org/10.1016/j.micpro.2020.103077>>.

GANGSAR, P.; TIWARI, R. A support vector machine based fault diagnostics of induction motors for practical situation of multi-sensor limited data case. **Measurement**, Elsevier BV, v. 135, p. 694–711, mar. 2019. Disponível em: <<https://doi.org/10.1016/j.measurement.2018.12.011>>.

GANGSAR, P.; TIWARI, R. Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 144, p. 106908, out. 2020. Disponível em: <<https://doi.org/10.1016/j.ymssp.2020.106908>>.

GAUTSCHI, G. **Piezoelectric sensorics : force, strain, pressure, acceleration and acoustic emission sensors, materials and amplifiers**. Berlin New York: Springer, 2002. ISBN 978-3-642-07600-8.

GENG, Q. S.; WANG, F. H.; ZHOU, D. X. Mechanical fault diagnosis of power transformer by GFCC time-frequency map of acoustic signal and convolutional neural network. In: **2019 IEEE Sustainable Power and Energy Conference (ISPEC)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/ispec48194.2019.8975318>>.

GHANBARI, T.; FARJAH, A. Application of rogowski search coil for stator fault diagnosis in electrical machines. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 14, n. 2, p. 311–312, fev. 2014. Disponível em: <<https://doi.org/10.1109/jsen.2013.2288607>>.

GLOWACZ, A. Fault diagnosis of single-phase induction motor based on acoustic signals. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 117, p. 65–80, fev. 2019. Disponível em: <<https://doi.org/10.1016/j.ymssp.2018.07.044>>.

GLOWACZ, A.; GLOWACZ, Z. Diagnostics of stator faults of the single-phase induction motor using thermal images, MoASoS and selected classifiers. **Measurement**, Elsevier BV, v. 93, p. 86–93, nov. 2016. Disponível em: <<https://doi.org/10.1016/j.measurement.2016.07.008>>.

GNACIŃSKI, P. *et al.* Induction cage machine thermal transients under lowered voltage quality. **IET Electric Power Applications**, Institution of Engineering and Technology (IET), v. 13, n. 4, p. 479–486, abr. 2019. Disponível em: <<https://doi.org/10.1049/iet-epa.2018.5242>>.

GONCALVES, A. M. J. *et al.* The design of multiple linear regression models using a genetic algorithm to diagnose initial short-circuit faults in 3-phase induction motors. **Applied Soft Computing**, Elsevier BV, v. 63, p. 50–58, fev. 2018. Disponível em: <<https://doi.org/10.1016/j.asoc.2017.11.015>>.

GOSBELL, V.; PERERA, S.; SMITH, V. **Voltage Unbalance**. [S.l.], 2002.

HAFIZ, F. *et al.* Identification of power quality events: selection of optimum base wavelet and machine learning algorithm. **IET Science, Measurement & Technology**, Institution of Engineering and Technology (IET), v. 13, n. 2, p. 260–271, mar. 2019. Disponível em: <<https://doi.org/10.1049/iet-smt.2018.5044>>.

HALL, E. H. On a new action of the magnet on electric currents. **American Journal of Mathematics**, JSTOR, v. 2, n. 3, p. 287, set. 1879. Disponível em: <<https://doi.org/10.2307/2369245>>.

HAN, J. *et al.* A low cross-axis sensitivity piezoresistive accelerometer fabricated by masked-maskless wet etching. **Sensors and Actuators A: Physical**, Elsevier BV, v. 283, p. 17–25, nov. 2018. Disponível em: <<https://doi.org/10.1016/j.sna.2018.09.040>>.

HAN, S.-B. *et al.* Development of diagnosis algorithm for induction motor using flux sensor. In: **2008 International Conference on Condition Monitoring and Diagnosis**. IEEE, 2008. Disponível em: <<https://doi.org/10.1109/cmd.2008.4580249>>.

HARDY, G. H. On Hilbert Transforms. **The Quarterly Journal of Mathematics**, Oxford University Press (OUP), os-3, n. 1, p. 102–112, 1932. Disponível em: <<https://doi.org/10.1093/qmath/os-3.1.102>>.

HASAN, M. J.; ISLAM, M. M.; KIM, J.-M. Acoustic spectral imaging and transfer learning for reliable bearing fault diagnosis under variable speed conditions. **Measurement**, Elsevier BV, v. 138, p. 620–631, maio 2019. Disponível em: <<https://doi.org/10.1016/j.measurement.2019.02.075>>.

HE, Z. *et al.* Kernel flexible and displaceable convex hull based tensor machine for gearbox fault intelligent diagnosis with multi-source signals. **Measurement**, Elsevier BV, p. 107965, maio 2020. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.107965>>.

HU, Q. *et al.* Fault diagnosis based on weighted extreme learning machine with wavelet packet decomposition and KPCA. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 18, n. 20, p. 8472–8483, out. 2018. Disponível em: <<https://doi.org/10.1109/jsen.2018.2866708>>.

HU, Q. *et al.* Machinery fault diagnosis scheme using redefined dimensionless indicators and mRMR feature selection. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 8, p. 40313–40326, 2020. Disponível em: <<https://doi.org/10.1109/access.2020.2976832>>.

HUJARE, D. P.; KARNIK, M. G. Vibration responses of parallel misalignment in a shaft rotor bearing system with rigid coupling. **Materials Today: Proceedings**, Elsevier BV, v. 5, n. 11, p. 23863–23871, 2018. Disponível em: <<https://doi.org/10.1016/j.matpr-2018.10.178>>.

HUSSEIN, R.; EL-HAG, A. H.; SHABAN, K. B. Energy conservation-based thresholding for effective wavelet denoising of partial discharge signals. **IET Science, Measurement & Technology**, Institution of Engineering and Technology (IET), v. 10, n. 7, p. 813–822, out. 2016. Disponível em: <<https://doi.org/10.1049/iet-smt.2016.0168>>.

IEC : 60034-14. Rotating electrical machines part 14: Measurement, evaluation and limits of the mechanical vibration severity of machines with shaft heights 56 mm and higher. **IEC 60034-14**, 2011. Disponível em: <<https://www.abntcatalogo.com.br/norma.aspx?ID=087066>>.

IEC : 60034-26. Effects of unbalanced voltages on the performance of three-phase induction motors. **IEC 60034-26**, 2006. Disponível em: <<https://www.abntcatalogo.com.br/norma.aspx?ID=64225>>.

IEEE : 519-2014. IEEE recommended practices and requirements for harmonic control in electrical power systems. **IEEE Std. 519-2014**, 2014. Disponível em: <<https://standards.ieee.org/standard/519-1992.html>>.

INSPECT, T. J. S. for N.-D. (Ed.). **Practical Acoustic Emission Testing**. Springer Japan, 2016. Disponível em: <<https://doi.org/10.1007/978-4-431-55072-3>>.

JOUANNE, A. von; BANERJEE, B. Assessment of voltage unbalance. **IEEE Transactions on Power Delivery**, Institute of Electrical and Electronics Engineers (IEEE), v. 16, n. 4, p. 782–790, 2001. Disponível em: <<https://doi.org/10.1109/61-956770>>.

KAHINGALA, T. D. *et al.* Estimation of voltage unbalance attenuation caused by three-phase induction motors: An extension to distribution system state estimation. **IEEE Transactions on Power Delivery**, Institute of Electrical and Electronics Engineers (IEEE), v. 34, n. 5, p. 1853–1864, out. 2019. Disponível em: <<https://doi.org/10.1109/tpwr.2019.2904505>>.

KARMAKAR, S. **Induction motor fault diagnosis : approach through current signature analysis**. Singapore: Springer, 2016. ISBN 978-981-10-0623-4.

KAUFMAN, L.; ROUSSEEUW, P. J. **Finding Groups in Data: An Introduction to Cluster Analysis**. 1. ed. New York: Wiley-Blackwell, 1990. ISBN 978-0-471-87876-6.

KAVANA, V.; NEETHI, M. Fault analysis and predictive maintenance of induction motor using machine learning. In: **2018 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECCOT)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/iceeccot43722-2018.9001543>>.

KHELFI, H. *et al.* Stator current demodulation using hilbert transform for inverter-fed induction motor at low load conditions. In: **2018 International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/cistem.2018.8613439>>.

KINDERMANN, G. **Curto circuito**. Porto Alegre (RS: Sagra-DC Luzzatto, 1992. ISBN 852410368X.

KUMAR, T. C. A.; SINGH, G.; NAIKAN, V. Sensitivity of rotor slot harmonics due to inter-turn fault in induction motors through vibration analysis. In: **2018 International Conference on Power, Instrumentation, Control and Computing (PICC)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/picc.2018.8384809>>.

LASHKARI, N.; POSHTAN, J.; AZGOMI, H. F. Simulative and experimental investigation on stator winding turn and unbalanced supply voltage fault diagnosis in induction motors using artificial neural networks. **ISA Transactions**, Elsevier BV, v. 59, p. 334–342, nov. 2015. Disponível em: <<https://doi.org/10.1016/j.isatra.2015.08.001>>.

LATHI, B. P. **Modern digital and analog communication systems**. New York: Oxford University Press, 1998. ISBN 9780195110098.

LATHI, B. P. **Signals, Systems And Communication**. London: BPS, 2003. ISBN 8178000164.

LEE, C.-Y. Effects of unbalanced voltage on the operation performance of a three-phase induction motor. **IEEE Transactions on Energy Conversion**, Institute of Electrical and Electronics Engineers (IEEE), v. 14, n. 2, p. 202–208, jun. 1999. Disponível em: <<https://doi.org/10.1109/60.766984>>.

LIU, R. *et al.* Artificial intelligence for fault diagnosis of rotating machinery: A review. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 108, p. 33–47, ago. 2018. Disponível em: <<https://doi.org/10.1016/j.ymssp.2018.02.016>>.

LU, S. *et al.* Online fault diagnosis of motor bearing via stochastic-resonance-based adaptive filter in an embedded system. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 47, n. 7, p. 1111–1122, jul. 2017. Disponível em: <<https://doi.org/10.1109/tsmc.2016.2531692>>.

LU, S. *et al.* Condition monitoring and fault diagnosis of motor bearings using undersampled vibration signals from a wireless sensor network. **Journal of Sound and Vibration**, Elsevier BV, v. 414, p. 81–96, fev. 2018. Disponível em: <<https://doi.org/10.1016/j.jsv.2017.11.007>>.

LUCAS, G. B. *et al.* Study of a three phase induction motor load estimation system by low-cost piezoelectric sensor. In: **2018 13th IEEE International Conference on Industry Applications (INDUSCON)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/induscon.2018.8627075>>.

LUCAS, G. B. *et al.* Study of a low-cost piezoelectric sensor for three phase induction motor load estimation. **Proceedings**, MDPI AG, v. 4, n. 1, p. 46, fev. 2019. Disponível em: <<https://doi.org/10.3390/ecsa-5-05723>>.

LUCAS, G. B. *et al.* Three-phase induction motor loading estimation based on wavelet transform and low-cost piezoelectric sensors. **Measurement**, Elsevier BV, v. 164, p. 107956, nov. 2020. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.107956>>.

LUO, G. *et al.* Impulsive noise reduction for transient earth voltage-based partial discharge using wavelet-entropy. **IET Science, Measurement & Technology**, Institution of Engineering and Technology (IET), v. 10, n. 1, p. 69–76, jan. 2016. Disponível em: <<https://doi.org/10.1049/iet-smt.2014.0203>>.

LUSUARDI, L. *et al.* The impact of test voltage waveform in determining the repetitive partial discharge inception voltage of type i turn/turn insulation used in inverter-fed induction motors. In: **2018 IEEE Electrical Insulation Conference (EIC)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/eic.2018.8481018>>.

MAGNETS, G. **Magsys HGM0900**. 2020. <<https://www.goudsmitmagnets.com/en/solutions/accessories/magnetic-field-meters/gauss-meter-teslameter>>. [Online; Acessado em 04/05/2020].

MALEK, M. A. el; ABDELSALAM, A. K.; HASSAN, O. E. Induction motor broken rotor bar fault location detection through envelope analysis of start-up current using hilbert transform. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 93, p. 332–350, set. 2017. Disponível em: <<https://doi.org/10.1016/j.ymsp.2017.02.014>>.

MALEK, M. B. A. el; ABDELSALAM, A. K.; HASSAN, O. E. Novel approach using hilbert transform for multiple broken rotor bars fault location detection for three phase induction motor. **ISA Transactions**, Elsevier BV, v. 80, p. 439–457, set. 2018. Disponível em: <<https://doi.org/10.1016/j.isatra.2018.07.020>>.

MALLAT, S. A theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Institute of Electrical and Electronics Engineers (IEEE), v. 11, n. 7, p. 674–693, jul. 1989. Disponível em: <<https://doi.org/10.1109/34.192463>>.

MARCHI, M. *et al.* Grinding process monitoring based on electromechanical impedance measurements. **Measurement Science and Technology**, IOP Publishing, v. 26, n. 4, p. 045601, mar. 2015. Disponível em: <<https://doi.org/10.1088/0957-0233/26/4/045601>>.

MARTIN-DIAZ, I. *et al.* Hybrid algorithmic approach oriented to incipient rotor fault diagnosis on induction motors. **ISA Transactions**, Elsevier BV, v. 80, p. 427–438, set. 2018. Disponível em: <<https://doi.org/10.1016/j.isatra.2018.07.033>>.

MARUTHI, G.; HEGDE, V. Application of MEMS accelerometer for detection and diagnosis of multiple faults in the roller element bearings of three phase induction motor. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 16, n. 1, p. 145–152, jan. 2016. Disponível em: <<https://doi.org/10.1109/jsen.2015.2476561>>.

Meggitt Sensing. **SE120 piezoresistive accelerometer**. 2020. <[https://catalogue.meggittsensing.com/pub/media/catalog/product/cache/2/image/e9c3970ab036de70892d86c6d221abfe/s/e/se120\\_sensor\\_product\\_photo\\_01\\_1.jpg](https://catalogue.meggittsensing.com/pub/media/catalog/product/cache/2/image/e9c3970ab036de70892d86c6d221abfe/s/e/se120_sensor_product_photo_01_1.jpg)>. [Online; Acessado em 04/05/2020].

MENZHI, L. E.; SAAD, A. Induction motor fault diagnosis using voltage park components of an auxiliary winding - voltage unbalance. In: **2009 International Conference on Electrical Machines and Systems**. IEEE, 2009. Disponível em: <<https://doi.org/10.1109/icems.2009.5382715>>.

MONDAL, D. *et al.* Airborne acoustic signature analysis for fault diagnosis of reciprocating compressors using modulation signal bi-spectrum. In: **2019 25th International Conference on Automation and Computing (ICAC)**. IEEE, 2019. Disponível em: <<https://doi.org/10.23919/iconac.2019.8895097>>.

MURATA. **7BB-20-6L0 Piezoelectric Diaphragm**. 2020. <<https://www.murata.com/en-us/products/productdetail.aspx?cate=cgsubDiaphragms&partno=7BB-20-6L0>>. [Online; Acessado em 04/05/2020].

NEMA : MG 1-2016. Information guide for general purpose industrial ac small and medium squirrel-cage induction motor standards. **NEMA : MG 1-2016**, 2016. Disponível em: <<https://www.nema.org/Standards/Pages/Motors-and-Generators.aspx>>.

NIKPAYAM, M. *et al.* Fault-tolerant control of y-connected three-phase induction motor drives without speed measurement. **Measurement**, Elsevier BV, v. 149, p. 106993, jan. 2020. Disponível em: <<https://doi.org/10.1016/j.measurement.2019.106993>>.

NIVESRANGSAN, P.; JANTARAJIROJKUL, D. Bearing fault monitoring by comparison with main bearing frequency components using vibration signal. In: **2018 5th International Conference on Business and Industrial Research (ICBIR)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/icbir.2018.8391209>>.

OJAGHI, M.; SABOURI, M.; FAIZ, J. Analytic model for induction motors under localized bearing faults. **IEEE Transactions on Energy Conversion**, Institute of Electrical and Electronics Engineers (IEEE), v. 33, n. 2, p. 617–626, jun. 2018. Disponível em: <<https://doi.org/10.1109/tec.2017.2758382>>.

OLIVEIRA, J. E. A. de. **Modelagem De Um Motor De Indução Trifásico Operando Com Tensões Desequilibradas Por Meio De Redes Neurais Artificiais**. Dissertação (Mestrado) — Faculdade de Engenharia de Bauru – UNESP, 2011.

OPPENHEIM, A. **Signals & systems**. Upper Saddle River, N.J: Prentice Hall, 1997. ISBN 0136511759.

OPPENHEIM, A. **Discrete-time signal processing**. Upper Saddle River: Pearson, 2010. ISBN 0131988425.

OTT, H. **Noise reduction techniques in electronic systems**. New York: Wiley, 1976. ISBN 0-471-65726-3.

OUMAAMAR, M. E. K. *et al.* Static air-gap eccentricity fault diagnosis using rotor slot harmonics in line neutral voltage of three-phase squirrel cage induction motor. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 84, p. 584–597, fev. 2017. Disponível em: <<https://doi.org/10.1016/j.ymssp.2016.07.016>>.

PAREY, A.; SINGH, A. Gearbox fault diagnosis using acoustic signals, continuous wavelet transform and adaptive neuro-fuzzy inference system. **Applied Acoustics**, Elsevier BV, v. 147, p. 133–140, abr. 2019. Disponível em: <<https://doi.org/10.1016/j.apacoust.2018.10.013>>.

- Physical Acoustics. **R15I-AST - 150 KHZ INTEGRAL PREAMP AE SENSOR**. 2020. <<https://www.physicalacoustics.com/by-product/sensors/R15I-AST-150-kHz-Integral-Preamp-AE-Sensor>>. [Online; Acessado em 15/09/2020].
- PONCELAS, O. *et al.* Motor fault detection using a rogowski sensor without an integrator. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 56, n. 10, p. 4062–4070, out. 2009. Disponível em: <<https://doi.org/10.1109/tie.2009.2025715>>.
- PRAMANICK, S. *et al.* A harmonic suppression scheme for full speed range of a two-level inverter fed induction motor drive using switched capacitive filter. **IEEE Transactions on Power Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 32, n. 3, p. 2064–2071, mar. 2017. Disponível em: <<https://doi.org/10.1109/tpel.2016.2561964>>.
- QIN, J. *et al.* Distributed  $k$ -Means Algorithm and Fuzzy  $c$ -Means Algorithm for Sensor Networks Based on Multiagent Consensus Theory. **IEEE Transactions on Cybernetics**, v. 47, n. 3, p. 772–783, mar. 2017. ISSN 2168-2275.
- QUATIERI, T. F. **Discrete-Time Speech Signal Processing: Principles and Practice**. 1. ed. Upper Saddle River, NJ: Prentice Hall, 2001. ISBN 978-0-13-242942-9.
- QUISPE, E. C. *et al.* Experimental study of the effect of positive sequence voltage on the derating of induction motors under voltage unbalance. In: **2011 IEEE International Electric Machines & Drives Conference (IEMDC)**. IEEE, 2011. Disponível em: <<https://doi.org/10.1109/iemdc.2011.5994936>>.
- QUISPE, E. C.; LOPEZ, I. D. Effects of unbalanced voltages on the energy performance of three-phase induction motors. In: **2015 IEEE Workshop on Power Electronics and Power Quality Applications (PEPQA)**. IEEE, 2015. Disponível em: <<https://doi.org/10.1109/pepqa.2015.7168237>>.
- RABINER, L. R.; SCHAFER, R. W. **Digital Processing of Speech Signals**. 1. ed. Englewood Cliffs, N.J: Prentice Hall, 1978. ISBN 978-0-13-213603-7.
- RAJ, C. T.; AGARWAL, P.; SRIVASTAVA, S. P. Performance analysis of a three-phase squirrel-cage induction motor under unbalanced sinusoidal and balanced non-sinusoidal supply voltages. In: **2006 International Conference on Power Electronic, Drives and Energy Systems**. IEEE, 2006. Disponível em: <<https://doi.org/10.1109/pedes.2006.344353>>.
- RAKESH, P. R.; NARAYANAN, G. Investigation on zero-sequence signal injection for improved harmonic performance in split-phase induction motor drives. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 64, n. 4, p. 2732–2741, abr. 2017. Disponível em: <<https://doi.org/10.1109/tie.2016.2643620>>.
- RANGEL-MAGDALENO, J. *et al.* Hilbert spectrum analysis of induction motors for the detection of incipient broken rotor bars. **Measurement**, Elsevier BV, v. 109, p. 247–255, out. 2017. Disponível em: <<https://doi.org/10.1016/j.measurement.2017.05.070>>.

RIBEIRO, D. A. *et al.* Mechanical fault detection in electric motors measured by a digital signal processing device in an optical mouse. **Measurement**, Elsevier BV, v. 138, p. 350–355, maio 2019. Disponível em: <<https://doi.org/10.1016/j.measurement.2019.02-.050>>.

RIPKA, P. Electric current sensors: a review. **Measurement Science and Technology**, IOP Publishing, v. 21, n. 11, p. 112001, set. 2010. Disponível em: <<https://doi.org/10.1088/0957-0233/21/11/112001>>.

RIVERA-GUILLEN, J. R. *et al.* Enhanced FFT-based method for incipient broken rotor bar detection in induction motors during the startup transient. **Measurement**, Elsevier BV, v. 124, p. 277–285, ago. 2018. Disponível em: <<https://doi.org/10.1016/j.measurement.2018.04.039>>.

ROMERO-TRONCOSO, R. *et al.* Rotor unbalance and broken rotor bar detection in inverter-fed induction motors at start-up and steady-state regimes by high-resolution spectral analysis. **Electric Power Systems Research**, Elsevier BV, v. 133, p. 142–148, abr. 2016. Disponível em: <<https://doi.org/10.1016/j.epsr.2015.12.009>>.

ROMERO-TRONCOSO, R. de J. Multirate signal processing to improve FFT-based analysis for detecting faults in induction motors. **IEEE Transactions on Industrial Informatics**, Institute of Electrical and Electronics Engineers (IEEE), v. 13, n. 3, p. 1291–1300, jun. 2017. Disponível em: <<https://doi.org/10.1109/tii.2016.2603968>>.

SAAD, N. **Condition monitoring and faults diagnosis of induction motors : electrical signature analysis**. Boca Raton, FL: CRC Press/Taylor & Francis Group, 2018. ISBN 978-0-8153-8995-8.

SACHAN, S.; SHUKLA, S.; SINGH, S. K. Two level de-noising algorithm for early detection of bearing fault using wavelet transform and zero frequency filter. **Tribology International**, Elsevier BV, v. 143, p. 106088, mar. 2020. Disponível em: <<https://doi.org/10.1016/j.triboint.2019.106088>>.

SALAH, A. A.; DORRELL, D. G.; GUO, Y. A review of the monitoring and damping unbalanced magnetic pull in induction machines due to rotor eccentricity. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 55, n. 3, p. 2569–2580, maio 2019. Disponível em: <<https://doi.org/10.1109/tia.2019.2892359>>.

SANGEETHA, P.; HEMAMALINI. Rational-dilation wavelet transform based torque estimation from acoustic signals for fault diagnosis in a three-phase induction motor. **IEEE Transactions on Industrial Informatics**, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 6, p. 3492–3501, jun. 2019. Disponível em: <<https://doi.org/10.1109/tii.2018.2874463>>.

SAPENA-BANO, A. *et al.* Induction machine model with space harmonics for the diagnosis of rotor eccentricity, based on the convolution theorem. **International Journal of Electrical Power & Energy Systems**, Elsevier BV, v. 117, p. 105625, maio 2020. Disponível em: <<https://doi.org/10.1016/j.ijepes.2019.105625>>.

SAPUTRA, P. *et al.* Combination of quadratic discriminant analysis and daubechis wavelet for classification level of misalignment on induction motor. In: **2019**

**International Symposium on Electronics and Smart Devices (ISESD)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/isesd.2019.8909431>>.

SCHENCK. **Vibration Accelerometer Sensor SR 100**. 2020. <[https://schenck-worldwide.com/in-en1/Vibration\\_Monitoring\\_Systems/VMS\\_Images/SR100.png](https://schenck-worldwide.com/in-en1/Vibration_Monitoring_Systems/VMS_Images/SR100.png)>. [Online; Acessado em 04/05/2020].

SCHIEWALDT, K. *et al.* Identification of stator winding insulation faults in three-phase induction motors using MEMS accelerometers. **Proceedings**, MDPI AG, v. 42, n. 1, p. 66, nov. 2019. Disponível em: <<https://doi.org/10.3390/ecsa-6-06630>>.

SHEIKH, M. A. *et al.* An analytical and experimental approach to diagnose unbalanced voltage supply. **Arabian Journal for Science and Engineering**, Springer Science and Business Media LLC, v. 43, n. 6, p. 2735–2746, ago. 2017. Disponível em: <<https://doi.org/10.1007/s13369-017-2769-7>>.

SHEIKH, M. A. *et al.* Unsupervised on-line method to diagnose unbalanced voltage in three-phase induction motor. **Neural Computing and Applications**, Springer Science and Business Media LLC, v. 30, n. 12, p. 3877–3892, abr. 2017. Disponível em: <<https://doi.org/10.1007/s00521-017-2973-0>>.

SIEMENS. **SMART 7KT, PAC 3120 e PAC 3220**. 2020. <<https://new.siemens.com/br/pt/produtos/energia/baixa-tensao/monitoramento-de-energia.html>>. [Online; Acessado em 04/05/2020].

SINGH, A.; PAREY, A. Gearbox fault diagnosis under fluctuating load conditions with independent angular re-sampling technique, continuous wavelet transform and multilayer perceptron neural network. **IET Science, Measurement & Technology**, Institution of Engineering and Technology (IET), v. 11, n. 2, p. 220–225, mar. 2017. Disponível em: <<https://doi.org/10.1049/iet-smt.2016.0291>>.

SINGH, G.; NAIKAN, V. Detection of half broken rotor bar fault in VFD driven induction motor drive using motor square current MUSIC analysis. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 110, p. 333–348, set. 2018. Disponível em: <<https://doi.org/10.1016/j.ymssp.2018.03.001>>.

SIRAKI, A. G.; PILLAY, P. An in situ efficiency estimation technique for induction machines working with unbalanced supplies. **IEEE Transactions on Energy Conversion**, Institute of Electrical and Electronics Engineers (IEEE), v. 27, n. 1, p. 85–95, mar. 2012. Disponível em: <<https://doi.org/10.1109/tec.2011.2168563>>.

SIVAKUMAR, A.; SELVAN, N. M. Reduction of source current harmonics in ANN controlled induction motor. **Alexandria Engineering Journal**, Elsevier BV, v. 57, n. 3, p. 1489–1499, set. 2018. Disponível em: <<https://doi.org/10.1016/j.aej.2017.03.048>>.

SOLODKIY, E.; DADENKOV, D.; SALNIKOV, S. Detection of stator inter-turn short circuit in three-phase induction motor using current coordinate transformation. In: **2019 26th International Workshop on Electric Drives: Improvement in Efficiency of Electric Drives (IWED)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/iwed-2019.8664353>>.

SON, J.-D. *et al.* An availability of MEMS-based accelerometers and current sensors in machinery fault diagnosis. **Measurement**, Elsevier BV, v. 94, p. 680–691, dez. 2016. Disponível em: <<https://doi.org/10.1016/j.measurement.2016.08.035>>.

SONG, X.; WANG, Z.; HU, J. Detection of bearing outer race fault in induction motors using motor current signature analysis. In: **2019 22nd International Conference on Electrical Machines and Systems (ICEMS)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/icems.2019.8922036>>.

SONG, Y. *et al.* A fault diagnosis method for roller bearing based on empirical wavelet transform decomposition with adaptive empirical mode segmentation. **Measurement**, Elsevier BV, v. 117, p. 266–276, mar. 2018. Disponível em: <<https://doi.org/10.1016/j.measurement.2017.12.029>>.

STEPANIC, P.; LATINOVIC, I. V.; DJUROVIC, Z. A new approach to detection of defects in rolling element bearings based on statistical pattern recognition. **The International Journal of Advanced Manufacturing Technology**, Springer Science and Business Media LLC, v. 45, n. 1-2, p. 91–100, fev. 2009. Disponível em: <<https://doi.org/10.1007/s00170-009-1953-7>>.

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**, Institute of Electrical and Electronics Engineers (IEEE), v. 54, n. 1, p. 866–872, jan. 2018. Disponível em: <<https://doi.org/10.1109/tia.2017.2740280>>.

SU, N.; LI, X.; ZHANG, Q. Fault diagnosis of rotating machinery based on wavelet domain denoising and metric distance. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 73262–73270, 2019. Disponível em: <<https://doi.org/10.1109/access.2019.2920939>>.

SUNDARARAJAN, D. **Discrete wavelet transform : a signal processing approach**. Singapore: John Wiley & Sons, Inc, 2015. ISBN 9781119046066.

Texas Instruments. **INA12x Precision, Low-Power Instrumentation Amplifiers**. 2020. <<https://www.ti.com/lit/ds/symlink/ina128.pdf>>. [Online; Acessado em 04/05/2020].

TOLEDO-PEREZ, D. C.; RODRIGUEZ-RESENDIZ, J.; GOMEZ-LOENZO, R. A. A study of computing zero crossing methods and an improved proposal for emg signals. **IEEE Access**, v. 8, p. 8783–8790, 2020. ISSN 2169-3536.

TOLIYAT, H. **Electric machines : modeling, condition monitoring, and fault diagnosis**. Boca Raton, FL: CRC Press, 2013. ISBN 978-1-4200-0628-5.

TRIGEASSOU. **Electrical machines diagnosis**. London Hoboken, NJ: ISTE Wiley, 2011. ISBN 978-1-84821-263-3.

TRUJILLO-GUAJARDO, L. A. *et al.* A multiresolution taylor–kalman approach for broken rotor bar detection in cage induction motors. **IEEE Transactions on Instrumentation and Measurement**, Institute of Electrical and Electronics Engineers (IEEE), v. 67, n. 6, p. 1317–1328, jun. 2018. Disponível em: <<https://doi.org/10.1109/tim.2018.2795895>>.

UMANS, S. **Fitzgerald & Kingsley's electric machinery**. New York: McGraw-Hill Companies, 2014. ISBN 978-0-07-338046-9.

VAIMANN, T. *et al.* Induction machine fault detection using smartphone recorded audible noise. **IET Science, Measurement & Technology**, Institution of Engineering and Technology (IET), v. 12, n. 4, p. 554–560, jul. 2018. Disponível em: <<https://doi.org/10.1049/iet-smt.2017.0104>>.

VIITALA, R.; WIDMAIER, T.; KUOSMANEN, P. Subcritical vibrations of a large flexible rotor efficiently reduced by modifying the bearing inner ring roundness profile. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 110, p. 42–58, set. 2018. Disponível em: <<https://doi.org/10.1016/j.ymssp.2018.03.010>>.

VINAYA, A. A. *et al.* Fault diagnosis of water pump based on acoustic emission signal using fast fourier transform technique and fuzzy logic inference. In: **2019 International Conference on Engineering, Science, and Industrial Applications (ICESI)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/icesi.2019.8863023>>.

VOLOKHIN, V.; DIAHOVCHENKO, I. Peculiarities of current sensors used in contemporary electric energy metering devices. **Energetika**, Lithuanian Academy of Sciences, v. 63, n. 1, ago. 2017. Disponível em: <<https://doi.org/10.6001/energetika.v63i1.3504>>.

WALNUT, D. **An introduction to wavelet analysis**. Boston: Birkhauser, 2002. ISBN 0817639624.

WANG, C. *et al.* Early fault diagnosis for planetary gearbox based on adaptive parameter optimized VMD and singular kurtosis difference spectrum. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 31501–31516, 2019. Disponível em: <<https://doi.org/10.1109/access.2019.2903204>>.

WANG, J. *et al.* Multilevel information fusion for induction motor fault diagnosis. **IEEE/ASME Transactions on Mechatronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 5, p. 2139–2150, out. 2019. Disponível em: <<https://doi.org/10.1109/tmech.2019.2928967>>.

WEG. **Danos em enrolamentos**. [S.l.], 2019. Disponível em: <<https://static.weg.net/medias/downloadcenter/h0b/hbf/WEG-danos-em-enrolamentos-motores-trifasicos-50009255-brochure-portuguese-web.pdf>>.

WU, X.; ZHU, Z.-Q. Simple mechanical rotor position estimation method based on rotor eccentricity. In: **2019 IEEE International Electric Machines & Drives Conference (IEMDC)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/iemdc.2019.8785173>>.

WU, Y.; JIANG, B.; WANG, Y. Incipient winding fault detection and diagnosis for squirrel-cage induction motors equipped on CRH trains. **ISA Transactions**, Elsevier BV, v. 99, p. 488–495, abr. 2020. Disponível em: <<https://doi.org/10.1016/j.isatra.2019.09.020>>.

XIA, Y.; KANNA, S.; MANDIC, D. P. Maximum likelihood parameter estimation of unbalanced three-phase power signals. **IEEE Transactions on Instrumentation and Measurement**, Institute of Electrical and Electronics Engineers (IEEE), v. 67, n. 3, p. 569–581, mar. 2018. Disponível em: <<https://doi.org/10.1109/tim.2017.2782980>>.

- XIE, Y. *et al.* Electromagnetic forces signature and vibration characteristic for diagnosis broken bars in squirrel cage induction motors. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 123, p. 554–572, maio 2019. Disponível em: <<https://doi.org/10.1016/j.ymssp.2019.01.030>>.
- XU, Y. *et al.* An adaptive spectrum segmentation method to optimize empirical wavelet transform for rolling bearings fault diagnosis. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 30437–30456, 2019. Disponível em: <<https://doi.org/10.1109/access.2019.2902645>>.
- 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**, Institute of Electrical and Electronics Engineers (IEEE), v. 65, n. 3, p. 549–558, mar. 2016. Disponível em: <<https://doi.org/10.1109/tim.2015.2498978>>.
- YUAN, P. *et al.* Characteristic research on the sensor for inter-turn partial discharge measurement of inverter-fed motor winding. In: **2019 IEEE Electrical Insulation Conference (EIC)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/eic43217-2019.9046528>>.
- ZHANG, D. *et al.* Intelligent acoustic-based fault diagnosis of roller bearings using a deep graph convolutional network. **Measurement**, Elsevier BV, v. 156, p. 107585, maio 2020. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.107585>>.
- ZHANG, P. *et al.* A survey of condition monitoring and protection methods for medium-voltage induction motors. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 47, n. 1, p. 34–46, jan. 2011. Disponível em: <<https://doi.org/10.1109/tia.2010.2090839>>.
- ZHANG, S. *et al.* Doppler correction using short-time MUSIC and angle interpolation resampling for wayside acoustic defective bearing diagnosis. **IEEE Transactions on Instrumentation and Measurement**, Institute of Electrical and Electronics Engineers (IEEE), v. 66, n. 4, p. 671–680, abr. 2017. Disponível em: <<https://doi.org/10.1109/tim.2017.2650718>>.
- ZHAO, M.; XU, G. Feature extraction of power transformer vibration signals based on empirical wavelet transform and multiscale entropy. **IET Science, Measurement & Technology**, Institution of Engineering and Technology (IET), v. 12, n. 1, p. 63–71, jan. 2018. Disponível em: <<https://doi.org/10.1049/iet-smt.2017.0188>>.
- 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**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 86798–86809, 2019. Disponível em: <<https://doi.org/10.1109/access.2019.2924056>>.
- ZHOU, H.; LIU, Z.; YANG, X. Motor torque fault diagnosis for four wheel independent motor-drive vehicle based on unscented kalman filter. **IEEE Transactions on Vehicular Technology**, Institute of Electrical and Electronics Engineers (IEEE), v. 67, n. 3, p. 1969–1976, mar. 2018. Disponível em: <<https://doi.org/10.1109/tvt.2017.2751750>>.

## APÊNDICE A

### Lista de publicações realizadas durante o período de mestrado

#### - Artigos completos publicados em periódicos

LUCAS, G. B., CASTRO, B. A., M. A, ROCHA, M. A, ANDREOLI, A. L. Three-phase induction motor loading estimation based on wavelet transform and low-cost piezoelectric sensors. **Measurement**, Elsevier BV, v. 164, p.107956, nov. 2020. doi: 10.1016/j.measurement.2020-.107956

LUCAS, G. B., CASTRO, B. A., M. A, ROCHA, M. A, ANDREOLI, A. L. A New Acoustic Emission-based Approach for Supply Disturbances Evaluation in Three-Phase Induction Motors. **IEEE Transactions on Instrumentation & Measurement**, IEEE. doi: 10.1109/TIM.2020.3047492

#### - Trabalhos completos publicados em anais de congressos internacionais

LUCAS, G. B. *et al.* Study of a three phase induction motor load estimation system by low-cost piezoelectric sensor. In: **2018 13th IEEE International Conference on Industry Applications (INDUSCON)**. IEEE, 2018. doi: 10.1109/induscon.2018.8627075

LUCAS, G. B. *et al.* Study of a low-cost piezoelectric sensor for three phase induction motor load estimation. **Proceedings**, MDPI AG, v. 4, n. 1, p. 46, fev. 2019. doi:10.3390/ecsa-5-05723

SCHIEWALDT, K.; LUCAS, G. B.; ROCHA, M. A.; FRAGA, C.; ANDREOLI, A. L. Identification of stator winding insulation faults in three-phase induction motors using MEMS accelerometers. **Proceedings**, MDPI AG, v. 42, n. 1, p. 66, nov. 2019. doi: 10.3390/ecsa-6-06630.

CARVALHO, L. LUCAS, G. B.; ROCHA, M. A.; FRAGA, C.; ANDREOLI, A. L. Undervoltage identification in three phase induction motor using low-cost piezoelectric sensors and STFT technique. **Proceedings**, MDPI AG, v. 42, n. 1, p. 72, nov. 2019. doi: 10.3390/ecsa-6-06644.

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, nov. 2019. doi: 10.3390/ecsa-6-06633