



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"



MARCO AURÉLIO ROCHA

**IDENTIFICAÇÃO E CLASSIFICAÇÃO DE CURTO ENTRE ESPIRAS
E DESBALANÇO DE TENSÃO EM MOTORES DE INDUÇÃO
TRIFÁSICOS UTILIZANDO SENSORES DE CORRENTE, EMISSÃO
ACÚSTICA E VIBRAÇÃO COM EMPREGO DE TRANSFORMADA
HILBERT E TRANSFORMADA WAVELET**

BAURU

2022

MARCO AURÉLIO ROCHA

**IDENTIFICAÇÃO E CLASSIFICAÇÃO DE CURTO ENTRE ESPIRAS
E DESBALANÇO DE TENSÃO EM MOTORES DE INDUÇÃO
TRIFÁSICOS UTILIZANDO SENSORES DE CORRENTE, EMISSÃO
ACÚSTICA E VIBRAÇÃO COM EMPREGO DE TRANSFORMADA
HILBERT E TRANSFORMADA WAVELET**

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

Orientador: Prof. Dr. André Luiz Andreoli

**BAURU
2022**

Rocha, Marco Aurélio

Identificação e classificação de curto entre espiras e desbalanço de tensão em motores de indução trifásicos utilizando sensores de corrente, emissão acústica e vibração com emprego de Transformada Hilbert e Transformada Wavelet/ Marco Aurélio Rocha, 2022

125 f. : il.

Orientador: Prof. Dr. André Luiz Andreoli

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

1. Tensão desequilibrada. 2. Curto entre espiras. 3. Transformada Hilbert. I. Universidade Estadual Paulista. Faculdade de Engenharia de Bauru. II. Título

ATA DA DEFESA PÚBLICA DA TESE DE DOUTORADO DE MARCO AURELIO ROCHA, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 02 dias do mês de agosto do ano de 2022, às 14:00 horas, por meio de Videoconferência, realizou-se a defesa de TESE DE DOUTORADO de MARCO AURELIO ROCHA, intitulada **IDENTIFICAÇÃO E CLASSIFICAÇÃO DE CURTO ENTRE ESPIRAS E DESBALANÇO DE TENSÃO EM MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO SENSORES DE CORRENTE, EMISSÃO ACÚSTICA E VIBRAÇÃO COM EMPREGO DE TRANSFORMADA HILBERT E TRANSFORMADA WAVELET**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. ANDRE LUIZ ANDREOLI (Orientador(a) - Participação Virtual) do(a) Departamento de Engenharia Eletrica / Faculdade de Engenharia de Bauru UNESP, Prof. Dr. PAULO JOSÉ AMARAL SERNI (Participação Virtual) do(a) Departamento de Engenharia Elétrica - docente voluntario / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. BRUNO ALBUQUERQUE DE CASTRO (Participação Virtual) do(a) Departamento de Engenharia Eletrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. MARCELO SUETAKE (Participação Virtual) do(a) Departamento de Engenharia Elétrica / Universidade Federal de São Carlos - UFSCar, Prof. Dr. MARCELO FAVORETTO CASTOLDI (Participação Virtual) do(a) Departamento de Engenharia Elétrica / Universidade Tecnológica Federal do Paraná. Após a exposição pelo doutorando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: _ _ _ _ _ **APROVADO** _ _ _ _ _ . Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.


Prof. Dr. ANDRE LUIZ ANDREOLI

AGRADECIMENTOS

Primeiramente, a Deus por mais esta conquista.

Ao professor Dr. André Luiz Andreoli, pela amizade, dedicação e apoio em todos os momentos deste trabalho. Agradeço também por acreditar no potencial deste trabalho, além do profundo aprendizado que absorvi durante o período de doutorado. Agradeço todos os conselhos e pela disponibilidade de sempre me atender com as minhas dúvidas.

Aos meus amados pais Antônio e Rosa, pelo grande incentivo e apoio, estando ao meu lado nos momentos mais importantes e decisivos de minha vida.

Agradeço pelo apoio e pela paciência de minha esposa, Anna Carolina Nunes Barbosa, que esteve ao meu lado nos momentos mais importantes e decisivos deste trabalho.

Aos meus amigos e companheiros do Laboratório de Qualidade de Energia Elétrica (LAQEE) da Unesp.

RESUMO

O motor de indução trifásico (MIT) é amplamente empregado em aplicações industriais para o acionamento de diversos tipos de cargas. Caso haja qualquer tipo de interrupção indesejada causada por falhas elétricas e mecânicas neste tipo de máquina, poderá haver prejuízos financeiros e produtivos diversos. Com isso, técnicas de monitoramento não invasivas vêm ganhando cada vez mais destaque no cenário industrial e acadêmico. Essas técnicas utilizam sensores que obtêm informações físicas sobre a operação da máquina, tais como vibração, corrente e emissão acústica. A análise desses sinais se destacam como ferramentas tradicionais para a obtenção de características operacionais do motor de indução trifásico e diagnóstico de falhas. Dentre as falhas elétricas, o desequilíbrio de tensão (DT), bem como o curto entre espiras (ITSC, do inglês *Inter-Turn Short-Circuit*) de curta duração são falhas frequentes no MIT e que podem afetar o desempenho da máquina, gerando paradas inesperadas. Portanto, o objetivo deste trabalho é a proposição de técnicas de diagnóstico de falhas DT e ITSC utilizando sensores de corrente de efeito Hall, sensor MEMS e sensores piezoelétricos. Deste modo, o diagnóstico proposto permite a detecção da falha, a identificação da fase elétrica afetada e a classificação da magnitude da falta. Para isso, foram desenvolvidas duas técnicas de processamento baseadas no envelope do sinal analítico proveniente da Transformada Hilbert e na energia do sinal dos coeficientes de aproximação e detalhe da Transformada Wavelet Discreta (TWD). Por fim, verificou-se qual a influência que a variação do carregamento tem sobre as técnicas propostas para cada um dos três sensores utilizados. Os resultados demonstraram que tanto o sensor de corrente quanto o sensor piezoelétrico foram sensíveis para o diagnóstico das falhas elétricas ITSC e DT. No entanto, verificou-se que o sensor MEMS não apresentou resultados promissores para o diagnóstico completo de falhas elétricas levando em consideração todos os níveis de carregamento aplicados. Por fim, o principal resultado é o desempenho do sensores PZT juntamente com a TWD em comparação ao sensor de corrente, uma vez que o sensor acústico apresenta custo muito reduzido e mede indiretamente a variável afetada pela falha.

Palavras-chave: Tensão desequilibrada; Curto entre espiras; Transformada Hilbert; Transformada Wavelet; Motor de Indução.

ABSTRACT

The three-phase induction motor (TIM) is widely used in industrial applications to drive various types of loads. If there is any kind of unexpected interruption caused by electrical and mechanical failures in this type of machine, there may be several financial and productive losses. Therefore, non-invasive monitoring techniques have been gaining more and more prominence in the industrial and academic scenario. These techniques use sensors that obtain physical information about machine operation, such as vibration, current, and acoustic emissions. The analysis of these signals stand out as traditional tools for obtaining operational characteristics of the three-phase induction motor and fault diagnosis. Among the electrical faults, voltage unbalance (VU), as well as the short duration inter-turn short circuit (ITSC) are frequent faults in the MIT and can affect the performance of the machine, generating unexpected stops. Thus, the objective of this work is the proposition of VU and ITSC fault diagnosis techniques using Hall effect current sensors, MEMS sensor and piezoelectric sensors. In this way, the proposed diagnostics allow the detection of the fault, the identification of the affected electrical phase and the classification of the fault magnitude. For this, two processing techniques were developed based on the envelope of the analytical signal originating from the Hilbert Transform and the signal energy of the approximation and detail coefficients of the Discrete Wavelet Transform (TWD). Finally, it was verified what influence the loading variation has on the proposed techniques for each of the three sensors used. The results showed that both the current sensor and the piezoelectric sensor were sensitive for the diagnosis of ITSC and DT electrical faults. However, it was found that the MEMS sensor did not show promising results for the complete diagnosis of electrical faults considering all applied loading levels. Finally, the main result is the performance of the PZT sensor combined with the TWD compared to the current sensor, since the acoustic sensor has very low cost and indirectly measures the variable affected by the fault.

Keywords: Unbalanced voltages, Inter-Turn Short-Circuit Fault, Hilbert Transform, Wavelet Transform, Induction Motor

LISTA DE FIGURAS

Figura 1 – Distribuição de diferentes falhas de um motor de indução trifásico	17
Figura 2 – Resumo dos diferentes tipos de fontes de falhas em um motor de indução	25
Figura 3 – Principais tipos de curtos-circuitos em MIT	26
Figura 4 – Desequilíbrio de Tensão	27
Figura 5 – Efeito Hall sem a presença de campo magnético perpendicular	29
Figura 6 – Efeito Hall com a presença de campo magnético perpendicular	30
Figura 7 – Garra de corrente baseada no efeito Hall	30
Figura 8 – Circuito equivalente de um TC	31
Figura 9 – Garra de corrente baseada em TC	32
Figura 10 – Construção do sensor MEMS (a) construção do acelerômetro MEMS baseado no efeito capacitivo (b) diagrama em blocos do ADXL335	33
Figura 11 – Sensor MEMS	34
Figura 12 – Sensor Piezoelétrico	37
Figura 13 – Decomposição do sinal por meio da DWT em três níveis	46
Figura 14 – Diagrama da Metodologia Utilizada	52
Figura 15 – Acoplamento do Motor de Indução à máquina CC	52
Figura 16 – Diagrama representativo da bancada experimental	53
Figura 17 – Componentes da bancada experimental	54
Figura 18 – Placa de condicionamento de sinais	54
Figura 19 – Detalhes experimentais. (a) Terminais de conexão; (b) Seções na bobina	55
Figura 20 – Padrão da corrente de falta ITSC	55
Figura 21 – Posicionamento dos sensores PZT e MEMS no Motor de Indução	57
Figura 22 – Fluxograma da análise de processamento de sinais	60
Figura 23 – Valor limiar da função correlação cruzada normalizada para a detecção de DT	62
Figura 24 – Agrupamento das fases afetadas e grau de severidade para 100% de carregamento	63
Figura 25 – Índice Silhouette para os agrupamentos obtidos	64

Figura 26 – Agrupamento da falha DT para todos os níveis de carregamento . .	65
Figura 27 – Regressão linear para Fase A	65
Figura 28 – Regressão linear para Fase B	66
Figura 29 – Regressão linear para Fase C	66
Figura 30 – Valor limiar da função correlação cruzada normalizada para a detecção de ITSC	67
Figura 31 – Agrupamento das fases afetadas por ITSC e grau de severidade para 100% de carregamento	68
Figura 32 – Índice Silhouette para os agrupamentos obtidos	69
Figura 33 – Agrupamento das fases afetadas por ITSC e grau de severidade para 50% de carregamento	69
Figura 34 – Índice Silhouette para os agrupamentos obtidos com 50% de carregamento	70
Figura 35 – Agrupamento da falha ITSC para todos os níveis de carregamento .	70
Figura 36 – Regressão linear para Fase A - falta ITSC	71
Figura 37 – Regressão linear para Fase B - falta ITSC	71
Figura 38 – Regressão linear para Fase C - Falta ITSC	72
Figura 39 – Valor limiar da função correlação cruzada normalizada para a detecção de DT utilizando a TWD	72
Figura 40 – Agrupamento das fases afetadas por DT e grau de severidade para 100% de carregamento utilizando TWD	73
Figura 41 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento	74
Figura 42 – Agrupamento da falha DT para todos os níveis de carregamento utilizando TWD	74
Figura 43 – Regressão linear para Fase A - falta DT - TWD	75
Figura 44 – Regressão linear para Fase B - falta DT - TWD	75
Figura 45 – Regressão linear para Fase C - Falta DT - TWD	76
Figura 46 – Valor limiar da função correlação cruzada normalizada para a detecção de ITSC utilizando a TWD	77
Figura 47 – Agrupamento das fases afetadas por ITSC e grau de severidade para 100% de carregamento utilizando TWD	78

Figura 48 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento - falta ITSC	79
Figura 49 – Agrupamento das fases afetadas por ITSC e grau de severidade para 50% de carregamento utilizando TWD	79
Figura 50 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 50% de carregamento - falta ITSC	80
Figura 51 – Regressão linear para Fase A - falta ITSC - TWD	80
Figura 52 – Regressão linear para Fase B - falta ITSC - TWD	81
Figura 53 – Regressão linear para Fase C - Falta ITSC - TWD	81
Figura 54 – Detecção da ocorrência da falha DT para técnica utilizando TH e aquisição por sensor MEMS	82
Figura 55 – Agrupamento das fases afetadas e grau de severidade para 100% de carregamento utilizando TH e sensor MEMS	83
Figura 56 – Índice Silhouette para TH utilizando MEMS - 100% de carregamento	84
Figura 57 – Agrupamento das fases afetadas e grau de severidade para 50% de carregamento utilizando TH e sensor MEMS	84
Figura 58 – Valor limiar da função correlação cruzada normalizada para a detecção de ITSC utilizando TH e sensor MEMS	85
Figura 59 – Agrupamento das fases afetadas por ITSC e grau de severidade para 100% de carregamento utilizando TH e sensor MEMS	86
Figura 60 – Índice Silhouette para os agrupamentos obtidos por meio da TH e sensor MEMS	86
Figura 61 – Agrupamento das fases afetadas por 5,5% de ITSC e para 100% de carregamento utilizando TH e sensor MEMS	87
Figura 62 – Índice Silhouette para os agrupamentos obtidos por meio da TH e sensor MEMS - 5,5% de severidade de ITSC	87
Figura 63 – Agrupamento das fases afetadas por 5,5% de ITSC e para 100% de carregamento utilizando TH e sensor MEMS	88
Figura 64 – Índice Silhouette para os agrupamentos obtidos por meio da TH e sensor MEMS - 5,5% de severidade de ITSC	88
Figura 65 – Regressão linear para Fase A - falta ITSC	89
Figura 66 – Regressão linear para Fase B - falta ITSC	89
Figura 67 – Regressão linear para Fase C - Falta ITSC	90

Figura 68 – Valor limiar da função correlação cruzada normalizada para a detecção de DT utilizando a TWD	91
Figura 69 – Agrupamento das fases afetadas por DT e grau de severidade para 100% de carregamento utilizando TWD e sensor MEMS	92
Figura 70 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento	92
Figura 71 – Agrupamento das fases afetadas por DT e grau de severidade para 50% de carregamento utilizando TWD e sensor MEMS	93
Figura 72 – Valor limiar da função correlação cruzada normalizada para a detecção de ITSC utilizando a TWD e sensor MEMS	93
Figura 73 – Agrupamento das fases afetadas por ITSC e grau de severidade para 100% de carregamento utilizando TWD e sensor MEMS	94
Figura 74 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento - falta ITSC - uso de sensor MEMS	95
Figura 75 – Agrupamento das fases afetadas por ITSC de 5,5% e 100% de carregamento utilizando TWD e sensor MEMS	95
Figura 76 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento - falta ITSC de 5,5% - uso de sensor MEMS	96
Figura 77 – Agrupamento das fases afetadas por ITSC de 5,5% e 50% de carregamento utilizando TWD e sensor MEMS	96
Figura 78 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 50% de carregamento - falta ITSC de 5,5% - uso de sensor MEMS	97
Figura 79 – Agrupamento das fases afetadas por DT de 5% e 10% para 100% de carregamento utilizando TH e sensores PZT	99
Figura 80 – Índice Silhouette para os agrupamentos obtidos na aplicação da TH para 100% de carregamento - falta DT de 5,5% e 10 % - uso de sensores PZT	99
Figura 81 – Agrupamento das fases afetadas por DT de 5% e 10% para 90% de carregamento utilizando TH e sensores PZT	100
Figura 82 – Índice Silhouette para os agrupamentos obtidos na aplicação da TH para 100% de carregamento - falta DT de 5,5% e 10 % - uso de sensores PZT	100

Figura 83 – Agrupamento das fases afetadas por DT de 5% e 10% para 50% de carregamento utilizando TH e sensores PZT	101
Figura 84 – Detecção da ocorrência da Falha DT	102
Figura 85 – Agrupamento para identificação da fase afetada e classificação de severidade para falta DT utilizando TWD e sensores PZT - plena carga	103
Figura 86 – Índice Silhouete para identificação da fase afetada e classificação de severidade para falta DT utilizando TWD e sensores PZT - plena carga	103
Figura 87 – Agrupamento para identificação da fase afetada e classificação de severidade para falta DT utilizando TWD e sensores PZT - 50% de carregamento	104
Figura 88 – Índice Silhouete para identificação da fase afetada e classificação de severidade para falta DT utilizando TWD e sensores PZT - 50% de carregamento	104
Figura 89 – R^2 para a fase A sob falha DT	105
Figura 90 – R^2 para a fase B sob falha DT	105
Figura 91 – R^2 para a fase C sob falha DT	106
Figura 92 – Detecção da ocorrência da Falha ITSC utilizando sensores PZT e TWD	106
Figura 93 – Agrupamento para identificação da fase afetada e classificação de severidade para falta ITSC utilizando TWD e sensores PZT - plena carga	107
Figura 94 – Índice Silhouete para identificação da fase afetada e classificação de severidade para falta ITSC utilizando TWD e sensores PZT - plena carga	108
Figura 95 – Agrupamento para identificação da fase afetada e classificação de severidade para falta ITSC utilizando TWD e sensores PZT - 50% de carregamento	108
Figura 96 – Índice Silhouete para identificação da fase afetada e classificação de severidade para falta ITSC utilizando TWD e sensores PZT - 50% de carregamento	109
Figura 97 – R^2 para a fase A sob falha ITSC	109
Figura 98 – R^2 para a fase B sob falha ITSC	110
Figura 99 – R^2 para a fase C sob falha ITSC	110

LISTA DE TABELAS

Tabela 1 – Análise comparativa entre os sensores e técnicas de processamento de sinais.	113
---	-----

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Considerações iniciais	16
1.2	Objetivos e motivação	22
1.3	Estrutura da tese	23
2	FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS	24
2.1	Introdução	24
2.2	Curto-Circuito entre espiras	25
2.3	Desequilíbrio de Tensão	26
3	SENSORES	28
3.1	Sensores de corrente	28
3.2	Sensores de Vibração	32
3.3	Sensores Piezoelétricos	34
4	TÉCNICAS DE PROCESSAMENTO DE SINAIS PARA MONITORA- MENTO E DIAGNÓSTICO DE FALHAS	38
4.1	Funções de Correlação	38
4.1.1	Correlação Cruzada	38
4.1.2	Autocorrelação	40
4.2	Transformada de Hilbert	40
4.3	Transformada Wavelet	45
4.4	Energia	47
4.5	Índice Silhouette e Algoritmo <i>K-means</i>	47
5	MATERIAIS E MÉTODOS	49
5.1	Introdução	49
5.2	Montagem experimental	51
5.2.1	Montagem das máquinas elétricas	51
5.3	Sistema de aquisição de dados	56
5.4	Análise de Processamento Digital de Sinais	58

6	RESULTADOS E DISCUSSÃO	61
6.1	Sensores de corrente aplicado a diagnóstico de falhas ITSC e DT	61
6.1.1	Detecção do Desequilíbrio de Tensão utilizando TH	61
6.1.2	Identificação da fase desequilibrada e classificação de severidade utilizando TH	62
6.1.3	Detecção do ITSC utilizando TH	67
6.1.4	Identificação da fase afetada pelo curto entre espiras e classificação de severidade utilizando TH	67
6.1.5	Detecção do DT utilizando TWD	72
6.1.6	Identificação da fase afetada por DT e classificação de severidade utilizando TWD	73
6.1.7	Detecção do ITSC utilizando TWD	77
6.1.8	Identificação da fase afetada por ITSC e classificação de severidade utilizando TWD	77
6.2	Sensor MEMS aplicado a diagnóstico de falhas ITSC e DT	82
6.2.1	Detecção do Desequilíbrio de Tensão utilizando TH - sensor MEMS	82
6.2.2	Identificação da fase desequilibrada e classificação de severidade utilizando TH e Sensor MEMS	83
6.2.3	Detecção do ITSC utilizando TH e sensor MEMS	84
6.2.4	Identificação da fase afetada pela falta ITSC e classificação de severidade utilizando TH e sensor MEMS	85
6.2.5	Detecção do DT utilizando TWD e sensor MEMS	91
6.2.6	Identificação da fase afetada por DT e classificação de severidade utilizando TWD e sensor MEMS	91
6.2.7	Detecção do ITSC utilizando TWD e sensor MEMS	93
6.2.8	Identificação da fase afetada por ITSC e classificação de severidade utilizando TWD e sensor MEMS	94
6.3	Sensores PZT aplicados a diagnóstico de falhas ITSC e DT	98
6.3.1	Diagnóstico de falhas DT e ITSC utilizando Transformada Hilbert e sensores PZT	98
6.3.2	Diagnóstico de falhas DT utilizando Transformada Wavelet Discreta e sensores PZT	102

6.3.3	Diagnóstico de falhas ITSC utilizando Transformada Wavelet Discreta e sensores PZT	105
6.4	Análise comparativa	111
7	CONCLUSÃO	114
	REFERÊNCIAS	117
APÊNDICE A	LISTA DE PUBLICAÇÕES REALIZADAS DURANTE O PERÍODO DE DOUTORADO	124

Capítulo 1

Introdução

Neste capítulo é apresentada uma introdução geral sobre o trabalho realizado. Aqui serão apresentados conceitos sobre o diagnóstico de falhas em motores de indução trifásicos (MITs), diferenças entre tipos de falhas que acometem os MITs, tipos de sensores utilizados, bem como as técnicas utilizadas por esta tese. Além disso, será descrito o objetivo principal deste trabalho, salientando a relevância científica, justificativa e motivações.

1.1 Considerações iniciais


Motores de indução trifásicos apresentam uma alta empregabilidade em aplicações industriais. Isso se deve, principalmente, aos aspectos construtivos e características atrativas que fornecem, tais como robustez, baixo custo, e pouca necessidade de manutenção. A necessidade de manutenção desse tipo de máquina elétrica é baixa, uma vez que não dependem de partes desacopladas para ligações elétricas (escovas e anéis coletores), tais como os motores de corrente contínua. Além disso, são robustos e de baixo custo (OJAGHI; SABOURI; FAIZ, 2018; LIANG; ALI; ZHANG, 2020). Com isso, existem atualmente mais de 300 milhões de motores de indução trifásicos no mundo (GARCIA *et al.*, 2019). Este alto número de máquinas elétricas apresentam um consumo de, aproximadamente, 40% de toda a eletricidade produzida mundialmente, representando um consumo próximo de 80% da demanda de energia elétrica no setor industrial (GARCIA *et al.*, 2019).

Por mais que MITs possuam robustez, baixa necessidade de manutenção e baixo custo, as condições operacionais e longos períodos de funcionamento levam esses motores a condições inadequadas de operação. De fato, motores de indução trifásicos sofrem desgastes naturais, muitas vezes causados por sobrecarga mecânica, ambientes com excesso de umidade e elevada temperatura. Estes fatores aceleram

o processo de deterioração da máquina, reduzindo sua vida útil (GUEDES, 2019; YETGIN, 2019; YAMAN, 2021).

Dessa forma, os motores elétricos são susceptíveis a diversos tipos de falhas, dividindo-se em falhas elétricas e falhas mecânicas (SADEGHI; SAMET; GHANBARI, 2019). Estes tipos de faltas causam desgastes mecânicos, magnéticos e elétricos de diversas formas ao motor de indução (STIEF *et al.*, 2019). As falhas elétricas são relacionadas, principalmente a problemas no estator e no rotor, enquanto as falhas mecânicas estão relacionadas a problemas de rolamento, barras quebradas no rotor, desalinhamento e excentricidade (GUEDES, 2019). Com isso, cerca 36% das falhas que acometem o motor são relacionadas a falhas de enrolamento no estator e 41% relacionadas a falhas de rolamento. As falhas no rotor totalizam apenas 9%, enquanto que as demais, tais como excentricidade, acoplamento, desalinhamento correspondem a 14% do total de faltas. A Figura apresenta a distribuição de diferentes falhas de um motor de indução trifásico 1 (LIANG; ALI; ZHANG, 2020; YETGIN, 2019).

Figura 1 – Distribuição de diferentes falhas de um motor de indução trifásico



Fonte: Liang, Ali & Zhang (2020)

Conforme exposto, a presença de uma falha pode afetar o desempenho da máquina, gerando paradas inesperadas, custos de manutenção elevado, além de prejuízos ao processo produtivo. Portanto, condições de monitoramento do MIT e de seus componentes aliados a técnicas não invasivas para diagnóstico de falhas se tornam extremamente necessários para prevenção de danos, evitando perda de recursos

financeiros e operacionais (KHANJANI; EZOJI, 2021). As estratégias empregadas para evitar tais problemas incluem métodos de manutenção preditiva. Estas estratégias geralmente requerem estimações de condições da máquina elétrica que pode indicar situações de falha. Para isso, utiliza-se sensores para obtenção de informações sobre a condição de operação do MIT. Os sensores, normalmente, medem sinais de tensão e corrente elétrica, temperatura, vibração e emissão acústica. Portanto, é possível extrair características das máquinas de indução para distinção entre operação normal, em que o motor esteja em condições dentro das delimitadas pelo fabricante, e estado de falta, seja de natureza elétrica ou mecânica (CHERIF *et al.*, 2020). Com isso, com o objetivo de melhorar a predição de falhas em máquinas elétricas, o desenvolvimento de técnicas não invasivas (TNI) para diagnóstico de falhas em MITs tem se tornado, de maneira crescente, o foco de diversas áreas relacionadas a engenharia elétrica e mecânica (LUCAS *et al.*, 2020).

Diversas técnicas para diagnóstico de faltas em máquinas elétricas foram propostas em literatura, como monitoramento por vibração, emissão acústica (EA), e análise da assinatura de corrente do motor (MCSA, do inglês - *Motor Current Signature Analysis*) (ALMOUNAJJED; SAHOO; KUMAR, 2021; ALI *et al.*, 2019; ELBOUCHIKHI *et al.*, 2017; LUCAS *et al.*, 2021; GLOWACZ *et al.*, 2019). Dentre as diversas técnicas para diagnóstico de falhas publicadas recentemente, a MCSA é um método de análise espectral para diagnósticos de falhas elétricas e mecânicas em máquinas elétricas (JUNG; LEE; KWON, 2006; ELBOUCHIKHI *et al.*, 2017), apresentando um melhor desempenho na detecção de falhas mecânicas (ALI *et al.*, 2019). Análise de Emissão Acústica é uma das mais promissoras técnicas para diagnóstico de falhas em máquinas elétricas, capaz de fornecer diagnósticos de barras quebradas no rotor, falhas de rolamento, desbalanço de tensão e descargas parciais (LUCAS *et al.*, 2021; SANTOS *et al.*, 2020). A análise baseada em sinais de vibração é utilizada para detecção de falhas mecânicas e elétricas. Essa análise pode identificar barras quebradas, falhas ITSC e danos em rolamentos. Os sinais de vibração são normalmente utilizados em ambientes industriais para o estudo de desempenho de máquinas elétricas, sendo adquiridos por acelerômetros e medidos nos eixos X, Y e Z (ALI *et al.*, 2019; GLOWACZ *et al.*, 2019; SCHIEWALDT *et al.*, 2019).

Dentre as falhas em MITs mais conhecidas, os danos em enrolamentos de estator representam a segunda maior avaria, conforme pesquisas previamente rea-

lizadas (CHERIF *et al.*, 2020; KUMAR; SINGH; NAIKAN, 2018). De fato, faltas em enrolamentos de estator representam 36% do total de falhas em um motor de indução, conforme indicado na Figura 1. Elas geralmente iniciam-se por meio de curto entre espiras não detectados que culminam em danos mais severos (DEVI; SARMA; RAO, 2016). Este tipo de evento no estator normalmente é causado por estresse térmico, mecânico, elétrico e umidade. Neste contexto, o curto circuito entre espiras de curta duração gera a deterioração de isolamento e, conseqüentemente, um curto entre espiras mais severo devido a total perda da isolamento entre os enrolamentos. Na maioria dos casos, a falha de isolamento pode ocasionar danos severos nas bobinas do estator (CHERIF *et al.*, 2020).

O curto circuito entre espiras (ITSC, do inglês - *Inter-Turn Short-Circuit*) normalmente ocasiona danos consideráveis no funcionamento de um motor de indução. Para a condição de ITSC de pequena duração (alguns segundos), uma grande quantidade de espiras entram em contato uma com as outras. Esta falha gera um significativo aumento da corrente elétrica da bobina em relação a corrente de operação em regime, que, se frequente, pode acarretar em deterioração dos enrolamentos do estator, como perda de isolamento e posterior curto circuito permanente. Por essa razão, a detecção em estágios iniciais da falha ITSC é extremamente importante para a Engenharia, uma vez que minimiza os custos de manutenção e planejamento, além de aumentar a vida útil da máquina e reduzir custos operacionais. Além da detecção, a identificação e classificação da fase elétrica submetida a falha é extremamente importante para o bom planejamento de manutenção do sistema analisado. Entretanto, a detecção em estágios iniciais de falhas ITSC apresenta um alto nível de dificuldade, uma vez que este tipo de falha apresenta duração de alguns segundos, necessitando um alto esforço computacional das técnicas de processamento digital de sinais (CHERIF *et al.*, 2020; ALMOUNAJJED; SAHOO; KUMAR, 2021). Devido a significativa relevância que o motor de indução trifásico apresenta em aplicações industriais, bem como a importância de se aumentar o tempo em operação do MIT, a comunidade científica, de maneira geral, tem feito grandes esforços para técnicas de monitoramento capazes de detectar, em estágios iniciais, a falha ITSC, identificar em que fase elétrica a falta ocorreu além de classificar quanto sua intensidade (SAPENA-BANO *et al.*, 2017; LUCAS *et al.*, 2021; GONZALEZ-CORDOBA *et al.*, 2018).

Outro evento relacionado a falhas no estator, e que pode culminar em falhas

ITSC, é o desequilíbrio de tensão (DT) na alimentação do MIT. Essa anomalia faz com que correntes desbalanceadas percorram as espiras das fases do motor, causando sobreaquecimento, degradação do esmalte isolante dos enrolamentos, perda de torque, curtos-circuitos nos enrolamentos (fase/fase, fase/terra e fase/fase/terra) e, por fim, a diminuição de vida útil do equipamento (CARVALHO *et al.*, 2019; CHERIF *et al.*, 2020; WU; JIANG; WANG, 2020). Devido a partida de grandes motores, contatos elétricos danificados ou em condições irregulares, baixa qualidade do fornecimento de energia, defeitos construtivos em transformadores, inconformidades de cabos alimentadores e dispositivos de proteção, o DT é algo frequente em aplicações industriais. Dessa forma, sua identificação prévia e classificação é extremamente importante para o bom funcionamento do sistema. Além disso, se faz importante distinguir uma falha ITSC de uma falha DT, uma vez que as falhas ITSC podem ser ocasionadas por outros fatores, como umidade e sobrecarga mecânica (DASH; SAHU; PANIGRAHI, 2018; FERREIRA; ALBERTO; ALMEIDA, 2020). Outro ponto de destaque para o estudo de técnicas para detecção de desequilíbrio de tensão é que, em aplicações práticas, equipamentos de proteção podem não ser sensíveis, em curtos períodos de tempo, a tal evento (LUCAS *et al.*, 2021; CAMPBELL; ARCE, 2018).

Devido a importância da boa operação de uma máquina elétrica, e da representatividade que falhas elétricas no estator apresentam, várias técnicas de diagnóstico de falhas foram propostas em literatura. A determinação de falhas ITSC, bem como a estimativa de sua intensidade foram investigadas utilizando diversas metodologias. Em Moosavi *et al.* (2015), o autor identificou a falha ITSC em um motor síncrono de ímã permanente. A técnica proposta, fez uso de uma rede neural artificial para especificar a intensidade da falha por meio da análise da corrente do motor, utilizando transformada rápida de Fourier. Além disso, o trabalho é capaz de classificar a severidade da falta sob diferentes condições de carregamento e velocidade. No entanto, não houve a identificação da fase afetada. Já em Cherif *et al.* (2020), Bessam *et al.* (2015), o diagnóstico da falha ITSC foi alcançada por meio da razão de energia da Transformada Wavelet Discreta (TWD). Utilizou-se uma rede neural artificial para classificar a severidade. No entanto, a energia oriunda dos sinais da TWD mostrou variações aleatórias em relação ao aumento da intensidade da falha. Isso fez com que a técnica necessitasse de um maior esforço computacional. Em Almounajjed, Sahoo & Kumar (2021), utilizou-se a TWD e rede neural artificial para se identificar a falha ITSC e classificar sua severidade

sob diversas condições de carregamento. O trabalho fez uso de sensores de corrente como sinal de entrada para o desenvolvimento da técnica. Além disso, foi desenvolvido um modelo matemático, e a metodologia proposta foi validada computacional e experimentalmente. Embora os trabalhos supracitados tenham sido capazes de identificar a falha ITSC, e classificar sua severidade para diferentes condições de carregamento, não houve a identificação da fase afetada pelo curto entre espiras no enrolamento do estator. Além disso, os estudos analisaram apenas a falha em questão, sem influências de demais eventos, como o DT.

Para detecção de desequilíbrio de tensão, diversas são as técnicas propostas em literatura. Em Sheikh *et al.* (2017), é proposta uma técnica baseada na análise de sinais de corrente elétrica e força magnetomotriz. Esta metodologia foi capaz de classificar níveis de desequilíbrios de tensão (DTs). A principal técnica de processamentos de sinal digitais utilizada é a transformada rápida de Fourier, utilizada para classificar os níveis de DTs. No entanto, não há classificação da fase afetada. Em Chudasama, Shah & Shah (2016) é proposto um sistema *fuzzy* utilizando sinais elétricos de tensão e corrente para detecção da ocorrência do DT. Já em Lucas *et al.* (2021) é proposta uma nova técnica baseada na TWD utilizando sensores de emissão acústica. A proposta é capaz de identificar os diferentes níveis de DTs, classificar a fase afetada. No entanto, a influência do carregamento não é analisada.

Embora as técnicas supracitadas sejam capazes de realizar, individualmente, o diagnóstico da falha ITSC e DTs, nenhuma das metodologias propostas são capazes de realizar a distinção entre as falhas elétricas, investigar a influência de carregamento, classificar diferentes magnitudes de falha (seja ITSC ou DT) e identificar a fase elétrica afetada. Neste contexto, investigar a influência que a variação de carregamento tem sobre o diagnóstico de falhas é importante, pois conforme há variação de carregamento no eixo do motor, há mudanças no comportamento da máquina elétrica, podendo gerar falsos positivos no diagnóstico de falhas. Isso se dá pois, à medida em que a variação ocorre, as características físicas da máquina (variação, corrente, emissão acústica) também se alteram, podendo influenciar nas técnicas de diagnóstico (LUCAS *et al.*, 2020).

Dado que, em aplicações industriais há diversos cenários adversos e com características aleatórias que influenciam no correto funcionamento da máquina elétrica, tais como afundamentos de tensão, sobretensão, sobrecarga mecânica, umidade

e aquecimento, o monitoramento e diagnóstico é importante para o planejamento de manutenção e, conseqüentemente, para vida útil do MIT. Portanto, a principal contribuição deste trabalho é o estudo comparativo e a proposição de sistemas de monitoramento capazes de identificar o tipo de falha elétrica (ITSC ou DT), classificar a magnitude da falha e a fase afetada, além de investigar a influência do carregamento no eixo do motor de indução. Para isto, esta tese analisa três tipos de sensores, sensor de efeito Hall para aquisição das correntes elétricas de entrada, transdutores piezoelétricos para aquisição dos sinais de EA além de acelerômetros micro-eleto mecânicos (MEMS - do inglês, *Micro-Electro-Mechanical Systems*) para aquisição de sinais de vibração. Os sinais medidos são processados por meio de duas técnicas diferentes. Uma realizada com a utilização da Transformada Hilbert, e a segunda no domínio tempo-frequência, com a utilização da Transformada Wavelet Discreta. As duas técnicas, bem como os três sensores são comparados visando identificar qual apresenta o melhor desempenho. Este desempenho é analisado levando em consideração a capacidade de detecção da falha, a identificação da fase elétrica afetada e a classificação do grau de severidade para qualquer nível de carregamento. Para isso, índices estatísticos são utilizados para quantificar o grau de eficácia de cada processo estudado.

1.2 Objetivos e motivação

O motor de indução trifásico é a principal máquina elétrica utilizada hoje em ambientes industriais. Desta forma, qualquer parada indesejada pode ocasionar em perdas econômicas e operacionais (OJAGHI; SABOURI; FAIZ, 2018). Com isso, o desenvolvimento de técnicas não-invasivas que efetuem o diagnóstico de condições anormais de operação é cada vez mais crucial no âmbito de engenharia (AL-MUSAWI; ANAYI; PACKIANATHER, 2020).

As falhas elétricas de estator representam de 30 a 40% do total de falhas que acometem o MIT. Dentre elas, o DT e as falhas ITSC são significativas e podem levar a danos severos ao sistema de produção (LUCAS *et al.*, 2021; ALMOUNAJJED; SAHOO; KUMAR, 2021; CHERIF *et al.*, 2020), reiterando a relevância do tema de estudo.

Portanto, este trabalho propõe um estudo inédito de desempenho de metodologias capazes de detectar a ocorrência de DT e ITSC em MITs, identificar qual fase elétrica foi afetada e classificar sua magnitude. Além disso, tem-se o intuito de identificar o

carregamento no eixo da máquina elétrica, para se ter garantia de que a variação de carregamento não irá interferir no diagnóstico de falhas. Para isso, analisou-se três tipos de sensores: um para a aquisição da corrente elétrica de entrada (sensor de efeito-Hall), o segundo é baseado em Emissão Acústica (transdutor piezoelétrico baseado em Titanato Zirconato de Chumbo) e o terceiro é baseado no fenômeno de vibração (sensor MEMS). Na primeira técnica proposta, os dados são agrupados por meio do envelope do sinal analítico fornecido pela Transformada Hilbert dos sinais medidos pelos diferentes tipos de sensores. A segunda técnica analisada é realizada no tempo-frequência e é baseada na energia dos coeficientes Wavelet. Diversos ensaios foram realizados, com a aplicação de diferentes níveis de DTs, ITSC e carregamento e foi efetuada a comparação de desempenho das metodologias estudadas.

1.3 Estrutura da tese

O Capítulo 2 apresentará um estado da arte sobre as principais falhas elétricas às quais os MITs estão expostos, com destaque para falhas ITSC e desequilíbrio de tensão.

O Capítulo 3 abordará o princípio de funcionamento dos sensores de corrente, vibração e emissão acústica utilizados para análise de desempenho deste trabalho.

O Capítulo 4 tratará das técnicas de processamento de sinais utilizadas no desenvolvimento desta tese.

O Capítulo 5 descreverá com detalhes a metodologia e os conceitos utilizados especificamente neste trabalho. O desenvolvimento das técnicas propostas, a montagem experimental das máquinas elétricas e do sistema de aquisição de dados também serão detalhados.

Capítulo 6 irá tratar da análise de desempenho das técnicas e sensores estudados.

Por fim, apresenta-se a conclusão do trabalho no Capítulo 7.

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

Capítulo 2

Falhas em motores de indução Trifásicos


Os motores de indução trifásicos são amplamente utilizados em aplicações industriais, devido as suas características construtivas, como robustez e baixo custo. No entanto, estes são susceptíveis a diversos tipos de falhas que levam a paradas indesejadas, perdas econômicas e operacionais. Deste modo, o entendimento das falhas e a forma que esta afeta a máquina elétrica é essencial. Com isso, nos próximos subtópicos, serão descritos em detalhes as falhas elétricas no estator que são objeto de estudo desta tese (ITSC e DT).

2.1 Introdução

Devido as suas características construtivas, os motores de indução trifásicos (MITs) apresentam papel de destaque em plantas industriais. Neste contexto, quando este tipo de máquina elétrica é acometido por uma falha, paradas parciais ou totais do processo produtivo poderão ocorrer. Além disso, manutenção não planejada, tempo de parada da linha produtiva, ou substituições de equipamentos podem resultar em altos custos (STIEF *et al.*, 2019). Condições de monitoramento e técnicas para diagnóstico de falha em MITs são essenciais para a detecção prévia de condição de falta, reduzindo custos em manutenção e evitando paradas indesejadas (LIANG; ALI; ZHANG, 2020). Dada a enorme variedade de falhas que podem acometer a máquina elétrica, a Figura 2 apresenta os diferentes tipos de faltas causadas por distintas condições operacionais.

As falhas elétricas nos enrolamentos do estator representam cerca de 36% do total de falhas que acometem o MIT (LIANG; ALI; ZHANG, 2020). Devido a sua importância, os próximos subtópicos trarão um maior aprofundamento das faltas elétricas de origem externa causadas por desequilíbrio de tensão e faltas elétricas de origem interna causadas por curto-circuito entre espiras.

Figura 2 – Resumo dos diferentes tipos de fontes de falhas em um motor de indução



Fonte: adaptado de Liang, Ali & Zhang (2020)

2.2 Curto-Circuito entre espiras

A falha de curto-circuito no enrolamento do estator resulta do dano causado na isolação dos condutores da bobina, as quais são originadas principalmente devido ao sobreaquecimento, vibração, desequilíbrio de tensão e umidade. Este tipo de falha pode levar a paradas inesperadas e custo elevado de manutenção. Geralmente, a falha de curto-circuito no enrolamento do estator pode ser entre espiras, entre bobinas, entre fases e fase-terra. No caso de falhas ITSC, em curtos períodos de tempo, o motor continua em operação, no entanto, caso este tipo de falha não seja imediatamente detectada, ela pode evoluir para um curto circuito fase-fase ou fase-terra, tirando o motor de operação e impondo elevados custos de manutenção (SADEGHI; SAMET; GHANBARI, 2019; COSTA *et al.*, 2018). Esta evolução de curto-circuito é ocasionada principalmente devido a corrente de falta que circula pelas espiras danificadas. Com o efeito térmico gerado pela circulação da corrente de falta, o isolamento se degrada, ocasionando tais danos (GUEDES, 2019). Além da preocupação com a operação e vida útil da máquina elétrica, este tipo de falha, dependendo de sua severidade e duração, pode ocasionar focos de incêndio, trazendo riscos a segurança operacional (LUCAS, 2020). Com isso, a comunidade científica tem buscado desenvolver técnicas capazes de detectar, em estágios iniciais, a ocorrência de curtos-circuitos entre espiras de

um motor de indução trifásico (ALMOUNAJJED; SAHOO; KUMAR, 2021; KHANJANI; EZOJI, 2021; CHERIF *et al.*, 2020; STIEF *et al.*, 2019; SADEGHI; SAMET; GHANBARI, 2019).

A Figura 3 apresenta os principais tipos de curtos-circuitos em enrolamentos do estator que ocorrem em motores trifásicos. As possíveis causas que podem ocasionar curto entre espiras ou bobina curto-circuitada são a contaminação interna do motor, falha do esmalte de isolamento do fio, falha de verniz de impregnação e rápidas oscilações na tensão de alimentação. Já o curto entre fases pode ser ocasionado pela contaminação interna do motor, degradação do material isolante por ressecamento, ocasionada por excesso de temperatura, falha do material isolante e ITSC não detectados previamente (WEG, 2019).

Figura 3 – Principais tipos de curtos-circuitos em MIT



Fonte: adaptado de WEG (2019)

2.3 Desequilíbrio de Tensão

Os desequilíbrios de tensão são ocasionados por irregularidades na alimentação elétrica. Como se sabe, as tensões elétricas de fornecimento devem ser idênticas em amplitude e possuir defasamento de 120 graus entre si. No entanto, isso nem sempre é verdadeiro. Diversos são os fatores que ocasionam DTs em um sistema elétrico, tais como: maus contatos em conexões, chaves, contadores, disjuntores, transformadores de energia com desbalanço de enrolamentos, falhas em banco de capacitores, cargas

mal distribuídas, falhas em dispositivos de proteção, entre outros. Todos os fatores supracitados são contribuintes para ocasionar desequilíbrio de tensão nos sistemas elétricos (DASH; SAHU; PANIGRAHI, 2018; WEG, 2019).

Este tipo de falta pode causar danos irreversíveis para o funcionamento do MIT. Os DTs causam uma corrente elétrica nos enrolamentos de 6 a 10 vez maior do que em operação normal. Este fator aumenta as perdas na máquina elétrica, além de afetar o aquecimento dos enrolamentos do estator. Essa condição deteriora o isolamento dos condutores, podendo ocasionar curto entre-espiras, ou até mesmo, danos mais severos como curtos-circuitos fase-fase e fase-terra (JOUANNE; BANERJEE, 2001). A Figura 4 apresenta os danos causados nos enrolamentos do estator após a máquina de indução ser acometida por um DT.

Figura 4 – Desequilíbrio de Tensão



Fonte: adaptado de WEG (2019)

Capítulo 3

Sensores

Técnicas não-invasivas para o diagnóstico de falhas em motores de indução trifásicos se fazem necessárias, uma vez que este tipo de máquina elétrica possui uma enorme importância em aplicações industriais. Para a proposição de tais técnicas, o sensoriamento de vibração, corrente e emissão acústica do MIT, é extremamente importante para se realizar diagnósticos de falhas. Neste capítulo, serão abordados os sensores de corrente baseado em efeito-Hall, sensores acelerômetros MEMS e transdutores piezoelétricos utilizados neste trabalho para a realização da comparação de desempenho.

3.1 Sensores de corrente

Como as falhas estudadas nesta tese apresentam comportamento elétrico, o comportamento da corrente que circula nos enrolamentos do estator variam conforme a falha ITSC e o DT ocorrem. Deste modo, o sinal de corrente elétrica se torna atrativo para a identificação de tais eventos.


Este tipo de técnica de sensoriamento recebe o nome de análise da assinatura da corrente da máquina elétrica, e diversos trabalhos são propostos em literatura para a detecção das falhas elétricas no enrolamento do estator (ALMOUNAJJED; SAHOO; KUMAR, 2021; JUNG; LEE; KWON, 2006; ELBOUCHIKHI *et al.*, 2017). Nesta técnica, a corrente do motor é aquisitada por um sensor de corrente. Do sinal coletado, características são extraídas para a aplicação de técnicas de processamento de sinais no domínio do tempo, domínio da frequência ou no domínio tempo-frequência. E, com isso, é possível a realização do diagnóstico da falha (CHERIF *et al.*, 2020). A medição da corrente em uma planta industrial é muito utilizada para a análise e verificação de comportamento e desempenho do sistema. Neste contexto, a corrente elétrica é facilmente medida por meio de painéis de alimentação e é muito utilizada em sistemas

de diagnóstico de falhas que utilizam técnicas não-invasivas (FAIZ; EBRAHIMPOUR, 2005).

O sensor de corrente mais simples é baseado no efeito da Lei de Ohm, fazendo uso de um resistor *shunt*. Este resistor apresenta uma resistência conhecida, e através da medição da queda de tensão que ocorre, é possível calcular a medida do fluxo de corrente. Por ser de simples construção, apresenta como vantagem o baixo custo e robustez. No entanto, há a necessidade de interrupção do circuito, apresenta um alto consumo de energia e, por consequência, gera aquecimento. Desta forma, esta técnica para a realização da medição de corrente não é muito utilizada em aplicações em que há circulação de valores consideráveis de magnitude de tensão e corrente (RIPKA, 2010).


Além dos sensores baseados em resistores *shunt*, há sensores de campo magnético, sendo um dos mais populares o sensor de Efeito Hall. O efeito Hall se caracteriza basicamente pelo aparecimento de um campo elétrico transversal em um semicondutor percorrido por uma corrente elétrica, quando o mesmo se encontra mergulhado em um campo magnético. Considere a Figura 5, onde um filme de material semicondutor é percorrido por uma corrente elétrica constante. A distribuição de corrente sobre o mesmo é uniforme, e não existe diferença de potencial (ddp) (RAMSDEN, 2006). Na presença de um campo magnético perpendicular (Figura 6), o fluxo de corrente é distorcido. A distribuição resultante provoca o aparecimento de uma ddp entre os terminais de saída (RAMSDEN, 2006).

Figura 5 – Efeito Hall sem a presença de campo magnético perpendicular



Fonte: adaptado de Ramsden (2006)

Figura 6 – Efeito Hall com a presença de campo magnético perpendicular



Fonte: adaptado de Ramsden (2006)

Ou seja, Efeito Hall é uma propriedade que se manifesta em um condutor quando, sobre ele, é aplicado um campo magnético perpendicular ao fluxo de corrente. Quando isso ocorre, é gerada uma *ddp* nos condutores. Esta *ddp* tem uma direção perpendicular ao campo magnético e à corrente, e é proporcional à densidade de fluxo magnético e à corrente (ZIEGLER *et al.*, 2009; RAMSDEN, 2006). Este tipo de sensor de corrente apresenta vantagens como simplicidade, capacidade de medição de correntes contínuas e alternadas, além da alta exatidão. Portanto, trata-se de um sensor amplamente utilizado em aplicações industriais e para diagnóstico de falhas utilizando a técnica MCSA (JUNG; LEE; KWON, 2006; KHECHEKHOUCHE *et al.*, 2020). Este tipo de sensor de corrente foi utilizado neste trabalho e as garras de corrente baseadas no efeito Hall pode ser vista na Figura 7.

Figura 7 – Garra de corrente baseada no efeito Hall




Fonte: adaptado de Fluke (2020a)

Outro tipo de sensor de corrente bastante utilizado em aplicações industriais são os transformadores de corrente (TC). Estes tipos de sensores são baseados no efeito Faraday. A Lei de Indução de Faraday diz que a força eletromotriz induzida num circuito elétrico é diretamente proporcional à taxa de variação do fluxo magnético concatenado ao circuito. Ou seja, quando uma bobina fica sujeita a variação na intensidade do campo magnético, nesta surge uma corrente elétrica induzida que será maior quanto maior for a amplitude de variação (ALEXANDRE, 2018).

Os sensores baseados na Lei e Indução de Faraday apresentam como vantagens isolamento galvânico, simplicidade de funcionamento e ausência de fontes externas. O isolamento elétrico permite a aferição de corrente em um grande potencial de tensão (ZIEGLER *et al.*, 2009). Como desvantagem, estes sensores não são sensíveis a corrente contínua, e, dependendo do nível de corrente, podem apresentar estruturas complexas e tamanho elevando (RIPKA, 2010). O circuito equivalente de um transformador de corrente é apresentado na Figura 8. É possível observar o isolamento galvânico e o funcionamento por meio do princípio indutivo. Um exemplo de um TC comercial é apresentado na Figura 9.

Figura 8 – Circuito equivalente de um TC



Fonte: adaptado de Alexandre (2018)

Por fim, este trabalho optou pelo uso de sensores de corrente de Efeito Hall

para a medição da corrente elétrica de entrada do MIT. Estes sinais de corrente foram então processados, por meio das técnicas que serão propostas posteriormente, e seus resultados foram comparados com sensores de vibração e de emissão acústica.

Figura 9 – Garra de corrente baseada em TC



Fonte: adaptado de Fluke (2020b)

3.2 Sensores de Vibração


A medida em que o motor de indução trifásico é submetido à algum tipo de falha, trabalhos anteriores evidenciam alterações em seu padrão vibratório. Esta variação da vibração é ocasionada tanto por falhas mecânicas quanto por falhas elétricas. Com isso, a análise de vibração é uma das técnicas empregadas para o diagnóstico de falhas em máquinas elétricas. Os sinais de vibração podem ser adquiridos por acelerômetros medidos no eixo X, eixo Y e eixo Z. A principal vantagem dos acelerômetros se dão no fato de serem dispositivos não invasivos (ALI *et al.*, 2019; GLOWACZ *et al.*, 2019; SCHIEWALDT *et al.*, 2019).

Neste trabalho, o sensor utilizado para adquirir sinais de vibração presentes no MIT é o acelerômetro MEMS baseado em efeito capacitivo. Estes sensores possuem as vantagens de pequeno volume, baixo consumo de energia, baixo custo e alta precisão (SCHIEWALDT *et al.*, 2019; PEDOTTI; ZAGO; FRUETT, 2017; LIU; MA, 2018).

A operação do sensor é baseada no teste de movimento de massa. A capacitância entre a massa e o eletrodo condutivo fixado é modificada por este princípio de

operação. Portanto, a saída do sensor é proporcional a aceleração aplicada no teste de massa (LIU; MA, 2018). A construção do acelerômetro MEMS baseado no efeito capacitivo é mostrada na Figura 10.

Figura 10 – Construção do sensor MEMS (a) construção do acelerômetro MEMS baseado no efeito capacitivo (b) diagrama em blocos do ADXL335



Fonte: adaptado de Schiewaldt *et al.* (2019)

A dinâmica do acelerômetro é modelada através de um sistema de segunda ordem massa-mola (LIU; MA, 2018), como visto na equação 3.1:

$$m\ddot{a} + c\dot{x} + kx = m.a_{INPUT} \quad (3.1)$$

em que x é a massa teste de movimento, a_{INPUT} é a entrada de aceleração externa, m é a massa da massa de prova, c é o coeficiente de amortecimento do ar e k é rigidez de suspensão.

Após a aplicação da transformada de Laplace, a massa de prova de desloca-

mento é descrita conforme a equação 3.2 (LIU; MA, 2018):

$$\frac{x(s)}{a(s)} = \frac{1}{s^2 + \frac{c}{m}s + \frac{k}{m}} \quad (3.2)$$

A instabilidade *bias* do acelerômetro é o parâmetro chave para a medida do MEMS sobre um *bias* estável. O deslocamento estático da massa de prova é simplificado então, como mostra a equação 3.3 (LIU; MA, 2018):

$$\frac{x(0)}{a(0)} = \frac{m}{k} \quad (3.3)$$

O acelerômetro MEMS utilizado neste trabalho foi o ADXL335 da *Analog Devices*. Este tipo de sensor possui três eixos, X, Y e Z, e é mostrado na Figura 11. A largura de banda dos eixos X e Y estão entre 0,5 Hz e 1600 Hz, enquanto que a largura de banda do eixo Z é de 0,5 hz até 500 Hz.

Figura 11 – Sensor MEMS



Fonte: Analog Devices

3.3 Sensores Piezoelétricos

Os transdutores a base de titanato zirconato de chumbo de baixo custo tem sido bastante empregados em diagnóstico de falhas e monitoramento (CASTRO *et al.*, 2016; LUCAS *et al.*, 2021; TÁVORA *et al.*, 2021; VIERA *et al.*, 2019; JUNIOR;

D'ADDONA; AGUIAR, 2018). Este sensor se baseia no princípio da piezoeletricidade, que é a interação eletromecânica observada em certos cristais dielétricos. Estes transdutores tem a propriedade de converter a energia mecânica em elétrica (efeito piezoelétrico direto), bem como a energia elétrica em mecânica (efeito piezoelétrico reverso) (CASTRO, 2019).

A modelagem de um transdutor piezoelétrico pode ser caracterizada por um capacitor de placas paralela, em que se aplicam força e tensão elétrica. Ao se aplicar uma força F , serão produzidas uma deformação S e uma tensão mecânica T no material (ARNAU, 2008).

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

onde s representa o tensor de elasticidade do material.

Ao se aplicar uma tensão 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, ε_0 a permissividade no vácuo, cujo valor é $8,85pF/m$, e P o vetor polarização.

Agora, é possível fazer uma relação entre suas variáveis de natureza elétrica e mecânica. 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 elétrico constante, d como a constante dielétrica e ε^T como a constante de permissividade

dielétrica (ARNAU, 2008). Por fim, admitindo os subscritos i, j, k e $l = 1, 2, 3$ para representar o sistema natural de coordenadas dos materiais piezoelétricos tem-se (CASTRO, 2019):

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


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

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

Desta forma, os sensores piezoelétricos utilizados neste trabalho são de baixo custo, possuem simples instalação e também recebem o nome de diafragmas PZT (titanato zirconato de chumbo), devido a composição química da cerâmica piezoelétrica. Estes sensores piezoelétricos são compostos por um núcleo de cerâmica piezoelétrica e dois eletrodos em suas extremidades, possibilitando medições elétricas, e podem ser vistos na Figura 12.

Ao serem submetidos a ondas acústicas, estes sensores sofrem compressão e tração, e deste modo, os sinais elétricos de tensão podem ser medidos. Portanto, conforme o MIT é acometido por falhas elétricas, há variação no padrão acústico, e este sensor é capaz de fornecer sinais de tensão para tais variações, se mostrando uma excelente aplicação para diagnóstico de falhas em máquinas elétricas (CASTRO *et al.*, 2016; LUCAS *et al.*, 2021).

Figura 12 – Sensor Piezoelétrico



Fonte: Lucas (2020)

Capítulo 4

Técnicas de processamento de sinais para monitoramento e diagnóstico de falhas

O diagnóstico de falhas elétricas em motor de indução trifásico não é obtido apenas pela análise dos sinais brutos fornecidos pelos sensores. Para se detectar a ocorrência da falha, classificar sua magnitude, identificar a fase elétrica afetada, bem como entender a influência do carregamento no eixo do motor, são necessárias técnicas de processamento digital de sinais. Este capítulo trará as técnicas utilizadas no desenvolvimento desta tese.

4.1 Funções de Correlação

4.1.1 Correlação Cruzada

A função correlação cruzada é uma técnica de processamento digital de sinais utilizada em diversas aplicações com enfoque em similaridade, tais como radares e aplicação de reconhecimento de padrão (CASTRO, 2019). Trata-se de um método para estimação do grau de correlação entre dois sinais distintos (KEESMAN, 2011).

A função correlação cruzada é uma medida de similaridade entre dois sinais em função do deslocamento entre eles no eixo do tempo, ou seja, é capaz de representar o grau de similaridade entre dois sinais baseado no deslocamento temporal entre eles (GUREVICH *et al.*, 2018; OPPENHEIM, 2016).

A função correlação cruzada $R_{xy}(\tau, t)$ dos sinais $x(t)$ e $y(t)$ pode ser definida por (KEESMAN, 2011):

$$R_{xy}(\tau, t) = E[x(t).y(t - \tau)] \quad (4.1)$$

em que τ é o atraso no tempo. O operador $E[.]$ representa o operador de esperança

matemática, ou seja, significa o valor médio da função.

Dessa forma, o operador de esperança matemática será sempre interpretado como a média temporal, podendo ser representado por (KEESMAN, 2011):

$$R_{xy}(\tau, t) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t).y(t - \tau)dt \quad (4.2)$$

A função definida pela equação (4.2) é apenas uma função do atraso τ e não da variável t . Portanto, esta função apresenta características de invariância no tempo (KEESMAN, 2011).

A função correlação cruzada pode ser definida no tempo discreto para aplicações em processamento digital de sinais por meio da sequência correlação cruzada (KEESMAN, 2011):

$$R_{xy}[k] = \lim_{N \rightarrow \infty} \frac{1}{2N + 1} \sum_{m=-N}^N x[m].y[m - k] \quad (4.3)$$

Por fim, a sequência correlação cruzada entre um sinal x e um sinal y pode ser descrita como (OPPENHEIM, 2016):

$$R_{xy} = \sum_{m=-\infty}^{\infty} x[m].y[m - k] \quad (4.4)$$

em que R_{xy} é a função correlação cruzada, $x[m]$ e $y[m]$ são as duas variáveis analisadas.

Com o intuito de se obter uma estimação confiável para valores de correlação cruzada, o atraso k é escolhido para ser menor do que $N/4$, conforme definido em (KEESMAN, 2011). Para uma correlação cruzada normalizada, R_{xy} varia de -1 a 1. Estes valores limite indicam a máxima correlação (similaridade) entre os sinais e o valor 0 indica nenhuma similaridade (OPPENHEIM, 2016).

Dessa forma, a função correlação cruzada é uma ferramenta bastante utilizada para análise e processamento de sinais digitais, uma vez que retorna o grau de similaridade que os sinais apresentam entre si. Além disso, esta ferramenta funciona como um filtro, sendo capaz de mitigar ruídos. Isso se dá pois, sua função, conforme definida na equação (4.2), trata-se de uma média temporal (KEESMAN, 2011; OPPENHEIM, 2016).

4.1.2 Autocorrelação

Quando a correlação é calculada entre um sinal e o próprio sinal deslocado no tempo, tem-se a autocorrelação (KEESMAN, 2011).

Da mesma forma que a função correlação cruzada, a função autocorrelação pode ser definida por (OPPENHEIM, 2016):

$$R_{xx} = \sum_{m=-\infty}^{\infty} x[m].x[m - k] \quad (4.5)$$

Por fim, as funções de correlação, correlação cruzada e autocorrelação, foram escolhidas neste trabalho, para detectar a ocorrência das falhas ITSC e DT. Para isso, é feita a autocorrelação do sinal de referência (motor em estado saudável) e este resultado é comparado com a correlação cruzada dos sinais do motor em estado saudável e com motor em condição de falha.

O sinal de referência (*baseline*) é aquele referente ao motor em condições normais de operação, e caracterizado por $B[n]$. Com isso, analisando outro sinal de um motor em condição saudável $H[n]$, e um sinal de falha, $F[n]$, é observado que:

$$R_{B,H} > R_{B,F} \quad (4.6)$$

Pela análise da equação (4.6), é possível concluir que a detecção é dada uma vez que a correlação do sinal de referência com o sinal oriundo do motor em estado saudável é maior que a correlação cruzada do sinal de referência com o sinal do motor em estado de falha. Portanto, a métrica de correlação cruzada é aplicada para detectar a ocorrência da falha elétrica nos enrolamentos do estator.

4.2 Transformada de Hilbert

A Transformada de Hilbert (TH) é um método de análise de sinais usado em diferentes campos científicos tais como o diagnóstico de falhas em máquinas elétricas e transmissão de sinais (PUCHE-PANADERO *et al.*, 2009).

A TH se justifica como uma importante ferramenta para o diagnóstico de falhas em máquinas elétricas, uma vez que apresenta vantagens em comparação a Transformada de Fourier. Isso pois, a especificação da Transformada de Fourier de uma sequência requer pleno conhecimento das parte real e imaginária ou da magnitude e

da fase em todas as frequências no intervalo de $-\pi < \omega \leq \pi$. Entretanto, sob certas condições, essa transformada apresenta restrições. Por exemplo, se $x[n]$ é um sinal real, então sua transformada de Fourier é uma função com simetria conjugada, isto é, $X(e^{j\omega}) = X^*(e^{-j\omega})$. Por isso, segue que, para sequências reais, a especificação de $X(e^{j\omega})$ para $0 \leq \omega \leq \pi$ também a especifica para $-\pi \leq \omega \leq 0$. De modo similar, sob restrição de fase mínima, a magnitude e a fase da transformada de Fourier não são independentes, isto é, a especificação da magnitude determina a fase e a especificação da fase determina a magnitude. Além disso, para sequências de comprimento finito N , a especificação de $X(e^{j\omega})$ em N frequências igualmente espaçadas determina $X(e^{j\omega})$ em todas as frequências (OPPENHEIM ALAN E SCHAFER, 2012).

Nesse contexto, a transformada de Hilbert pode ser utilizada para criar sinais analíticos por meio de sinais reais (KONAR; CHATTOPADHYAY, 2015). Um sinal analítico é uma função de tempo complexo (que é analítica) que possui uma transformada de Fourier que desaparece em frequências negativas (OPPENHEIM ALAN E SCHAFER, 2012).

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 com elevada exatidão do sinal original. Esta função consiste em uma parte real, expressa pelo próprio sinal e uma parte imaginária, expressa pela TH do sinal. Portanto, atributos instantâneos dos sinais são obtidos (amplitude e fase). Matematicamente, a TH de um sinal qualquer representado por $x(t)$ pode ser expressa por (KONAR; CHATTOPADHYAY, 2015; RANGEL-MAGDALENO *et al.*, 2017):

$$\hat{y}(t) = \mathcal{H}\{x(t)\} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (4.7)$$

A Transformada de Hilbert é definida como a convolução do sinal contínuo $x(t)$ com a função matemática $(t\pi)^{-1}$, conforme mostrado na equação 4.7. Com isso, um sinal com parte real e imaginária, denominado sinal analítico, pode ser criado com sua parte real $r(t)$ sendo o próprio sinal $x(t)$ e sua parte imaginária $y(t)$ sendo a Transformada de Hilbert deste sinal, definido por $Z(t)$ (KONAR; CHATTOPADHYAY,

2015; RANGEL-MAGDALENO *et al.*, 2017):

$$z(t) = r(t) + i\hat{y}(t) = x(t) + i\hat{y}(t) \quad (4.8)$$

A equação anterior pode ser reescrita em sua forma polar(KONAR; CHATTO-PADHYAY, 2015):

$$z(t) = a(t)e^{i\theta(t)} \quad (4.9)$$

em $a(t)$ e $\theta(t)$ representam a amplitude e a fase instantânea do sinal analítico, respectivamente.

O valor absoluto instantâneo e a fase do sinal analítico são dados, respectivamente, por:

$$a(t) = \sqrt{x^2(t) + \hat{y}^2(t)} \quad (4.10)$$

$$\theta(t) = \arctg\left(\frac{\hat{y}(t)}{x(t)}\right) \quad (4.11)$$

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

$$\omega = \frac{d\theta(t)}{dt} \quad (4.12)$$

A seguir, será demonstrada a relação entre a TH e o sinal analítico. Aplicando o teorema da convolução à equação (4.7)(OPPENHEIM ALAN E SCHAFER, 2012):

$$\mathcal{F}\{\hat{y}(t)\} = \mathcal{F}\{x(t)\}\mathcal{F}\left\{\frac{1}{\pi t}\right\} \quad (4.13)$$

$$\tilde{Y}(f) = -iX(f)\text{sgn}(f) \quad (4.14)$$

em que sgn é a função sinal:

$$\text{sgn}(x) = \begin{cases} -1, & x < 0 \\ 0, & x = 0 \\ 1, & x > 0 \end{cases} \quad (4.15)$$

Substituindo a definição de sgn na equação (4.14):

$$\tilde{Y}(f) = \begin{cases} iX(f), & f < 0 \\ 0, & f = 0 \\ -iX(f), & f > 0 \end{cases} \quad (4.16)$$

Logo, tem-se:

$$\tilde{Y}(f) = -iX(f_+) + iX(f_-) \quad (4.17)$$

Multiplicando ambos os lados por i :

$$i\tilde{Y}(f) = X(f_+) - X(f_-) \quad (4.18)$$

Somando $X(f)$ em ambos os lados, tem-se:

$$X(f) + i\tilde{Y}(f) = X(f) + X(f_+) - X(f_-) \quad (4.19)$$

Substituindo $X(f)$ por $X(f_-) + X(f_0) + X(f_+)$ no lado direito da equação, tem-se:

$$X(f) + i\tilde{Y}(f) = X(f_0) + 2X(f_+) \quad (4.20)$$

Nota-se, pela equação (4.20), que não há componentes negativos de frequência, o que está de acordo com a definição de sinal analítico.

Sendo:

$$Z(f) = \begin{cases} 2X(f), & f > 0 \\ X(f), & f = 0 \\ 0, & f < 0 \end{cases} \quad (4.21)$$

$$z(t) = \mathcal{F}^{-1}[Z(f)] \quad (4.22)$$

Tem-se que:

$$X(f) + i\tilde{Y}(f) = Z(f) \quad (4.23)$$

e, calculando a Transformada Inversa de Fourier:

$$x(t) + i\tilde{y}(t) = z(t) \quad (4.24)$$

Logo:

$$x(t) + i\mathcal{H}[x(t)] = z(t) \quad (4.25)$$

E, com isso, observa-se que o sinal é complexo e que sua parte imaginária corresponde à TH da sua parte real (OPPENHEIM ALAN E SCHAFER, 2012).

Portanto, para sinais de banda estreita, a amplitude instantânea pode ser interpretada como envelope do sinal. Além disso, a Transformada Hilbert não altera o domínio da função ao qual ela é aplicada, não altera a amplitude do sinal, altera apenas a fase. A importância da análise de sinais analíticos se dá, pois, a representação analítica gera um vetor rotativo no plano complexo. A principal consequência disso é que, com isso, pode-se obter valores instantâneos de amplitude e fase, usando apenas uma única amostra de um sinal discreto (OPPENHEIM ALAN E SCHAFER, 2012).

Neste trabalho, a TH foi utilizada com o objetivo de se obter um sinal analítico e, por conseguinte, o envelope dos sinais de vibração, emissão acústica e corrente adquiridos, respectivamente, pelos sensores MEMS, PZT e corrente. A Transformada Hilbert foi utilizada para a obtenção do sinal analítico, e, desta forma, calculou-se a energia do sinal para identificação da fase elétrica afetada pelo ITSC e DT.

4.3 Transformada Wavelet

A Transformada Wavelet é uma ferramenta de processamento digital de sinais que se provou como uma técnica eficaz para sinais estacionários e não-estacionários. Este método é de fácil implementação, preciso e eficiente para sinais no domínio do tempo e para sinais no domínio da frequência, simultaneamente (CHERIF *et al.*, 2020).


A transformada Wavelet pode ser realizada em dois tipos, contínuo e discreto. Em comparação com a transformada Wavelet Discreta, a Transformada Wavelet contínua apresenta uma maior informação do sinal original, entretanto, necessita de um maior esforço computacional do que a TWD. Da mesma forma, para aplicações industriais, necessita-se de processamento digital de sinais com uma velocidade maior e mais robusta, fazendo com que a TWD se torne essencial para este cenário (CHERIF *et al.*, 2020).

A TWD é realizada por meio de uma série de filtros passa-alta para análise de altas frequências do sinal original e uma série de filtros passa-baixa para a análise de baixas frequências do sinal original. Com isso, o sinal é completamente decomposto em coeficientes de detalhe (componentes de alta frequência) e coeficientes de aproximação (componentes de baixa frequência) (CHERIF *et al.*, 2020; KONAR; CHATTOPADHYAY, 2015).

A Figura 13 apresenta a decomposição do sinal original, por meio da Transformada Wavelet, em três níveis. Os coeficientes $h[n]$ e $g[n]$ são, respectivamente, filtros passa-alta e filtros passa-baixa. Os resultados de tais filtros fornecem os coeficientes de aproximação (A) e detalhe (D). Este processo pode se repetir sucessivas vezes até o momento em que não se é mais possível decompor o sinal. Os coeficientes de detalhe têm seu comprimento reduzido pela metade, e apenas os coeficientes de aproximação são decompostos (CHERIF *et al.*, 2020; BOUZIDA *et al.*, 2011).

A TWD é implementada computacionalmente por meio da transformada rápida

Figura 13 – Decomposição do sinal por meio da DWT em três níveis



Fonte: Cherif *et al.* (2020)

de Wavelet. Dessa forma, os coeficientes de detalhes e aproximação são calculados por (ALMOUNAJJED; SAHOO; KUMAR, 2021; HAFIZ *et al.*, 2019):

$$a_{j+1}[p] = \sum_{n=-\infty}^{+\infty} g[n - 2p]a_j[n] \quad (4.26)$$

e

$$d_{j+1}[p] = \sum_{n=-\infty}^{+\infty} h[n - 2p]a_j[n] \quad (4.27)$$

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

A TWD apresenta-se como uma boa técnica para detecção de falhas em MIT e é largamente utilizada na detecção de falhas em máquinas elétricas (CHERIF *et al.*, 2020; ALMOUNAJJED; SAHOO; KUMAR, 2021; LUCAS *et al.*, 2021). Isso se deve pois, possui a capacidade de decomposição de sinais de corrente, vibração e EA em diversas bandas e frequências. É capaz de detectar o instante de ocorrência dessas bandas, ao contrário da Transformada Rápida de Fourier. Além disso, diferentes

métricas estatísticas são utilizadas, em conjunto com os coeficientes fornecidos pela TWD, para realizar o diagnóstico de falhas (ALMOUNAJJED; SAHOO; KUMAR, 2021).

4.4 Energia

A energia de um sinal é usado em diversas pesquisas envolvendo diagnóstico de falhas, uma vez que variações de energia em sinais de vibração, EA e corrente podem indicar a ocorrência de uma falha (LUCAS *et al.*, 2021; TAO *et al.*, 2020; ZHAO; WANG, 2019). Seu valor pode ser obtido por (BOASHASH, 2016):

$$E = \sum_{n=1}^N |x[n]|^2 \quad (4.28)$$

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

Neste trabalho, o valor de energia do envelope da Transformada Hilbert e da Transformada Wavelet Discreta são calculados. Logo, a energia é utilizada para ambas as técnicas propostas e se mostra como uma boa ferramenta, uma vez que falhas ITSC e DT alteram o sinal oriundo de tais transformadas.

4.5 Índice Silhouette e Algoritmo *K-means*

Para se classificar a severidade das faltas observadas, bem como identificar a fase elétrica afetada, utilizou-se o conceito de clusterização. A clusterização de dados é uma técnica que visa realizar agrupamentos automáticos de dados em função do grau de semelhança que estes dados apresentam entre si. A cada conjunto de dados resultante do processo dá-se o nome de grupo (*cluster*). O conceito de clusterização não se trata de um algoritmo específico, e sim de uma técnica de mapeamento de dados. Para que o agrupamento (clusterização) seja realizado da maneira correta, necessita-se da utilização de algoritmos que visam estabelecer critérios para a formação dos grupos (LUCAS *et al.*, 2021; YANG; SINAGA, 2019).

Existem diferentes algoritmos para se obter a clusterização, um dos mais utilizados e conhecidos é o algoritmo *K-means*. Este algoritmo se baseia em aprendizado não supervisionado, que, ao invés de responder a algum treinamento, identifica as semelhanças nos dados e reage com base na presença ou ausência dessas semelhanças

em cada novo dado. Com isso, os dados são separados em k grupos. A centroide pode ser definida como o centro geométrico de cada grupo e é importante pois, o algoritmo *K-means* se baseia na média de um conjunto de pontos de dados e a distância euclidiana entre estes pontos. A primeira etapa deste algoritmo é a determinação aleatória dos centroides iniciais para cada agrupamento. Após isso, cada dado é associado ao centroide mais próximo. O agrupamento inicial é feito atribuindo cada dado ao centroide mais próximo a ele e a primeira iteração é concluída. O algoritmo funciona em iterações até que os dados não mudem seus centros de cluster. Ao fim do processo, o algoritmo *K-means* determina a centroide dos clusters e quais dados pertencem a cada cluster. Por fim, a clusterização de dados permite a detecção e a identificação do tipo de falha em motores elétricos (LUCAS *et al.*, 2021; YANG; SINAGA, 2019).

A qualidade da clusterização é quantificada pela análise Silhouette. Essa técnica estuda o quão próximo o ponto está de seus vizinhos, comparados com o quão distante este mesmo ponto está dos outros clusters. Dessa forma, o índice Silhouette pode variar de -1 a 1, em que 1 é o melhor cenário de clusterização (o ponto está fortemente correlacionado com o cluster) e -1 o pior cenário de clusterização (o ponto está fracamente correlacionado com o cluster) (LUCAS *et al.*, 2021; GUPTA; PANDA, 2019).

O índice Silhouette pode ser calculado por:

$$S(i) = \frac{a(i) - b(i)}{\max \{a(i), b(i)\}} \quad (4.29)$$

em que a é a distância média do ponto i para os demais pontos do mesmo cluster, e b é a mínima distância média do ponto i para os demais pontos de outros clusters.

Capítulo 5

Materiais e Métodos

Neste capítulo, descreve-se a montagem experimental da bancada de ensaios, bem como a metodologia para aquisição de dados.

5.1 Introdução

O objetivo deste projeto de pesquisa é realizar uma comparação de desempenho em relação a três sensores: vibração, emissão acústica e corrente. Diversas técnicas para diagnóstico de faltas em máquinas elétricas foram propostas em literatura utilizando sinais de vibração, emissão acústica e sinais de corrente (ALMOUNAJJED; SAHOO; KUMAR, 2021; ALI *et al.*, 2019; ELBOUCHIKHI *et al.*, 2017; LUCAS *et al.*, 2021; GLOWACZ *et al.*, 2019). Para a aquisição de sinais de vibração, optou-se pelo acelerômetro MEMS baseado em efeito capacitivo. Estes sensores são não invasivos, apresentam pequeno volume, são de baixo custo e baixo consumo de energia (SCHIEWALDT *et al.*, 2019; PEDOTTI; ZAGO; FRUETT, 2017; LIU; MA, 2018). Outro fator determinante para a utilização deste item, é de que, este sensor já possui validação para a detecção e diagnóstico de falhas em rolamentos de motores de indução, entretanto, poucos são os trabalhos que o empregam para o diagnóstico de falhas elétricas que acometem o MIT (MARUTHI; HEGDE, 2016; PEDOTTI; ZAGO; FRUETT, 2017). Para a aquisição de sinais de emissão acústica, optou-se pelo emprego dos sensores piezoelétricos de baixo custo. Estes sensores tem sido empregados em diagnóstico de falhas e monitoramento em diversos trabalhos (LUCAS *et al.*, 2021; VIERA *et al.*, 2019; TÁVORA *et al.*, 2021). Por fim, para a medição da corrente elétrica, optou-se pelo sensor de efeito-Hall. Embora apresentem menor resposta em frequência, estes sensores são mais baratos em comparação aos TCs de alta frequência (CRESCENTINI *et al.*, 2017; CASTRO *et al.*, 2022). Portanto, este trabalho visa contribuir com o fornecimento de uma análise comparativa entre as sensibilidades dos sensores de vibração, emissão

acústica e de efeito-Hall para o diagnóstico de falhas elétricas em motores de indução trifásicos.

Cada um desses sensores monitoram o comportamento de um motor de indução trifásico submetido à dois tipos diferentes de falhas: curto-circuito entre espiras no enrolamento de estator com duração de um segundo e desequilíbrio de tensão. O ITSC com duração de 1 segundo visa simular curtos circuitos que acontecem no estator do MIT por efeito de umidade. Conforme discutido no capítulo 2 desta tese, este tipo de falha não interrompe a operação da máquina elétrica, no entanto, caso não seja imediatamente detectada, poderá evoluir para um curto circuito fase-fase ou fase-terra, tirando o motor de operação (SADEGHI; SAMET; GHANBARI, 2019; COSTA *et al.*, 2018). Cada uma das falhas possuem diferentes severidades. Além disso, o motor apresenta diferentes carregamentos em seu eixo (50% até plena carga). Com isso, outra contribuição desta tese se dá na melhoria do diagnóstico de falhas elétricas no MIT para diferentes graus de severidade, por meio do desenvolvimento de técnicas de processamento digital de sinais. Além disso, a validação das técnicas de monitoramento propostas para diferentes níveis de carregamento se torna interessante, uma vez que diferentes níveis de carregamento no eixo do MIT podem indicar falsos positivos e as condições operacionais da máquina são avaliadas (ALMOUNAJJED; SAHOO; KUMAR, 2021).

Propõe-se, inicialmente, uma técnica baseada na função correlação cruzada visando detectar a ocorrência das falhas elétricas ITSC e DT. Após a detecção, propõe-se uma comparação de desempenho entre as técnicas de processamento digital de sinais propostas e utilizadas para classificar a fase elétrica afetada e identificar o grau de severidade da falta ITSC e DT sobre o MIT.

A primeira técnica utiliza-se da Transformada de Hilbert, a qual calcula o sinal analítico dos sinais de vibração, corrente e emissão acústica. Este sinal analítico é utilizado para extração da energia do envelope dos sinais oriundos dos sensores. A segunda técnica é realizada no domínio tempo-frequência, por meio da Transformada Wavelet Discreta. Após a obtenção dos coeficientes de detalhe e aproximação dos sinais fornecidos pelos sensores, aplica-se a função energia. Para isto, este trabalho se dividiu em três partes principais, estudo teórico acerca das técnicas de diagnóstico de falhas com cada um dos sensores estudados, realização dos ensaios experimentais e, por fim, o desenvolvimento das técnicas de processamento digital de sinais propostas.

Os materiais utilizados durante o desenvolvimento desta pesquisa foram:

- Computador pessoal;
- Software MATLAB®;
- Fonte Programável AC Pacific, Smart Source, 360-AMX;
- Motor de indução trifásico WEG, 2,0 cv, rotor em gaiola de esquilo, 220/380 V, 4 polos, 6,12/3,54 A, 1740 rpm e fp 0,78;
- Oscilógrafo Yokogawa DL850;
- Carga: Máquina de corrente contínua de 1,8kW, tensão de armadura de 250V, tensão de campo de 190 V, 9 A de corrente de armadura, 0,75 A de corrente de campo, 1800 rpm. Variador de tensão trifásico variac, ponte retificadora e banco de resistores contendo 4 resistores de 1,5 kW em 220 V.

As próximas seções irão abordar cada uma dessas etapas.


5.2 Montagem experimental

A bancada experimental, a aquisição de dados, bem como todos os experimentos foram realizados no Laboratório de Pesquisa em Qualidade de Energia Elétrica (LAQEE), da Faculdade de Engenharia de Bauru, Localizado no Departamento de Engenharia Elétrica da Unesp. A seguir, serão descritos os principais componentes e procedimentos adotados para a bancada de teste e aquisição de dados. O diagrama apresentado na Figura 14 detalha melhor a metodologia adotada neste trabalho.

5.2.1 Montagem das máquinas elétricas


Para realização dos experimentos, o motor de indução de 2,0 cv foi acoplado em uma máquina de corrente contínua (CC). O acoplamento entre as máquinas foi alinhado com auxílio de relógios comparadores, e as máquinas elétricas foram ajustadas sobre a bancada de forma a se evitar que elas estivessem soltas, conforme mostrado na Figura 15.

Figura 14 – Diagrama da Metodologia Utilizada



Fonte: autoria própria

Figura 15 – Acoplamento do Motor de Indução à máquina CC




Fonte: autoria própria

O motor de indução foi alimentado em sua tensão nominal utilizando uma fonte trifásica programável, esta fonte permite a criação dos desequilíbrios de tensão. O circuito de campo da máquina CC foi conectado a uma ponte retificadora e o circuito de armadura foi conectado a um banco de cargas resistivas. A tensão de campo da máquina CC foi ajustada até o MIT atingir sua carga nominal. Esta metodologia foi aplicada para simular a condição de operação industrial de um motor de indução. Além

disso, a variação de carregamento do motor de indução foi controlado por meio do ajuste do circuito de campo da máquina CC. O diagrama completo utilizado neste trabalho pode ser visto na Figura 16. A Fonte Trifásica Programável, o banco de resistores e o sistema de medição e aquisição de dados é apresentado na Figura 17. O destaque em vermelho se refere a placa de condicionamento de sinais que pode ser vista em maior detalhe na Figura 18.


Figura 16 – Diagrama representativo da bancada experimental



Fonte: autoria própria


Após a montagem da bancada experimental, as faltas foram aplicadas. Em um primeiro momento, a falha de estudo foi a ITSC. Para isso, o motor de indução utilizado neste trabalho foi especialmente modificado para permitir acesso aos enrolamentos do estator, conforme mostra a Figura 19. Os terminais de conexão são mostrados na Figura 19 (a), representando quatro conexões de enrolamentos para as três fases. Cada enrolamento de fase é composto por seis bobinas e uma dessas bobinas é dividida em duas partes, equivalente a 5,5% e 11% da bobina (Figura 19 (b)). Com o intuito de se reproduzir a falha ITSC causada pelo efeito de umidade presente no estator, aplicou-se curtos para cada fase de 5,5% e 11% com duração de 1 segundo. Além disso, utilizou-se um sistema de controle já consolidado pelo grupo de pesquisa e

Figura 17 – Componentes da bancada experimental



Fonte: autoria própria

Figura 18 – Placa de condicionamento de sinais




Fonte: autoria própria

utilizado em trabalhos anteriores para ativar o curto-circuito, de modo a simular o efeito da umidade, conforme descrito no capítulo 2.

Dessa forma, o curto circuito foi aplicado com uma rampa de subida de 0,5 segundos e, após, uma rampa de descida de 0,5 segundos de duração. O padrão do resultado da corrente de falta é mostrado na Figura 20. A característica dessa falha simula a presença de umidade nas bobinas do estator. No momento em que a falta


Figura 19 – Detalhes experimentais. (a) Terminais de conexão; (b) Seções na bobina



Fonte: autoria própria

ITSC é aplicada, há uma diminuição da força dielétrica entre as bobinas. Portanto, a sobrecorrente aquece a bobina, e a umidade evapora, extinguindo a falta ITSC. Este procedimento foi repetido 50 vezes para cada uma das três fases elétricas, garantindo a repetibilidade da técnica proposta. Além disso, este mesmo procedimento foi realizado para o motor em condições normais de operações.

Figura 20 – Padrão da corrente de falta ITSC



Fonte: autoria própria


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 para 95 e 90% do valor nominal do motor. Estes passos foram repetidos para cada uma das três fases e os sinais foram adquiridos para todas as porcentagens descritas. Na literatura, o diagnóstico de falhas causadas por desequilíbrio de tensão em motores de indução trifásicos já é realizado, no entanto, para desequilíbrios maiores, por exemplo, entre 10% e 90% como exposto em (LUCAS *et al.*, 2021). No trabalho proposto por Lucas *et al.*, 2021, os autores aplicaram desbalanços de tensão individuais a cada uma das fases elétricas com um valor mínimo de DT de 90% da tensão nominal de operação. Dessa forma, este trabalho visa contribuir com uma técnica que seja capaz da realização do diagnóstico de falha DT para desbalanços menores que 10%, que são valores mais próximos aos permitidos por norma. Além disso, esta tese tem por intuito validar a sensibilidade dos sensores de vibração, emissão acústica e corrente para o diagnóstico dos dois tipos de falhas elétricas supracitados (ITSC e DT). Essas falhas foram aplicadas de forma separada ao MIT. Ainda, visando garantir que as técnicas propostas seriam válidas para condições distintas de operação do MIT, cada um dos ensaios descritos foram feitos para diferentes níveis de carregamento (50% a 100% do valor nominal).

5.3 Sistema de aquisição de dados

Para este trabalho, os sinais de EA foram obtidos pelos sensores piezoelétricos. Já os sinais de vibração foram obtidos pelos sensores acelerômetros ADXL335 tridimensionais. Ambos foram fixados ao MIT usando uma cola à base de cianoacrilato, e seus posicionamentos no MIT são mostrados na Figura 21. Em trabalhos prévios realizados pelo Laboratório de Qualidade de Energia (LAQEE), verificou-se que os sensores piezoelétricos se tornariam mais sensíveis a diagnósticos se posicionados conforme indicado pela Figura 21. Este posicionamento tem por objetivo garantir a triangulação de dados, levando em consideração a posição geométrica das fases elétricas do MIT (LUCAS *et al.*, 2020; LUCAS *et al.*, 2021). Além disso, o sensor MEMS foi posicionado de maneira central ao motor de indução com o intuito de se obter um padrão de vibração capaz de fornecer o diagnóstico de falhas. Esta tese não realizou ensaios com o sensor MEMS posicionado em demais localidades. A

medição da corrente de linha de entrada foi realizada por meio de sensores de Efeito Hall. Cada garra de corrente foi conectada a uma fase elétrica de alimentação. O MIT está conectado na ligação triângulo, com tensão nominal de 220 V.

Figura 21 – Posicionamento dos sensores PZT e MEMS no Motor de Indução



Fonte: autoria própria

Os sinais obtidos pelos sensores piezoelétricos e MEMS foram condicionados por uma placa de condicionamento de sinais utilizando o amplificador de instrumentação INA128p, que atua como um filtro *anti-aliasing* passa-baixas de 400 kHz e que foi alimentada por uma fonte CC simétrica Politerm - POL 16B. O amplificador de instrumentação, com ganho de 25, tem a função de amplificar os sinais de baixa tensão dos sensores além de diminuir os problemas relacionados ao casamento de impedância e ao ruído em modo comum. 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®. Com o objetivo de se evitar ruídos indesejados, utilizou-se cabos blindados para conexão dos sensores ao osciloscópio. Além disso, a bancada experimental foi aterrada.

De modo a se mitigar o efeito de variação de temperatura nos sensores MEMS e piezoelétrico, houve o controle de temperatura. Este controle foi efetuado com auxílio de um termopar conectado à carcaça do MIT. Inicialmente, o motor de indução foi colocado em operação, e após atingir temperatura estável (47°C), os ensaios foram

realizados. Se houvesse, durante os ensaios, variação de temperatura de $\pm 2^{\circ}\text{C}$, os ensaios eram interrompidos até que a temperatura se estabilizasse novamente em seu ponto de operação. Além disso, para se aumentar a confiabilidade das técnicas propostas, os ensaios foram repetidos 50 vezes cada um, garantindo a repetibilidade dos resultados.

5.4 Análise de Processamento Digital de Sinais

Para o diagnóstico de falhas elétricas, uma média de 50 ensaios foram realizados para cada uma das falhas elétricas estudadas (DT e ITSC) e para cada um dos sensores. Após a experimentação e aquisição dos sinais oriundo dos sensores, a função correlação cruzada foi aplicada para detectar a ocorrência das falhas ITSC e DT. Para isso, é feita a autocorrelação do sinal de referência (motor em estado saudável) e este resultado é comparado com a correlação cruzada dos sinais do motor em estado saudável e com motor em condição de falha. Após a detecção da falha elétrica, os sinais foram processados por meio de duas técnicas distintas. Uma baseada na Transformada de Hilbert, e a segunda baseada na Transformada Wavelet Discreta. O principal objetivo da aplicação dessas técnicas foi o de validar a efetividade do diagnóstico de falha para a identificação da fase elétrica afetada, classificação de seu grau de severidade e a influência de carregamento. Além disso, a sensibilidade dos sensores para cada uma das técnicas foi analisada e os resultados foram comparados.


A Transformada Hilbert foi empregada para cada um dos sinais oriundos dos sensores de vibração, emissão acústica e corrente. A TH forneceu um sinal analítico, e deste sinal analítico foi extraído a energia de envelope. Após isso, os resultados foram dispostos em gráficos tridimensionais para o agrupamento de dados. Os gráficos tridimensionais foram realizados da seguinte maneira: para sensores de emissão acústica, cada eixo representa a energia de envelope do sinal analítico obtido pela TH do sinal adquirido de cada sensor piezoelétrico; para o sensor MEMS, cada eixo representa a energia de envelope do sinal analítico obtido pela TH de cada sinal oriundo dos eixos X, Y e Z do acelerômetro; e para o sensor de corrente, cada eixo representa a energia de envelope do sinal analítico obtido pela TH dos sinais oriundos dos sensores de corrente elétrica de cada uma das três fases de alimentação do sistema. Por meio do gráfico tridimensional, utilizou-se o algoritmo de *K-means* para a

realização da clusterização e, com isso, a identificação da fase elétrica afetada, bem como a classificação da severidade da falta. Por fim, para determinação da eficácia da técnica, utilizou-se o índice estatístico *Silhouette*, capaz de quantificar a qualidade dos agrupamentos obtidos. Este procedimento foi repetido para diferentes níveis de carregamento (50% a 100%), verificando a influência que esta variação tem sobre a técnica proposta.

A segunda técnica proposta se baseia na Transformada Wavelet Discreta. Do mesmo modo que a TH, a TWD foi empregada para cada um dos sinais oriundos dos sensores de vibração, emissão acústica e corrente. A análise Wavelet foi realizada pela extração da energia dos coeficientes de detalhe e aproximação obtidos pela TWD. Além disso, a Wavelet mãe escolhida foi a Daubechies, uma vez que não apresenta descontinuidade em sua função. Nesta técnica, foram obtidos 9 níveis de aproximação e 9 níveis de detalhe. Com isso, analisou-se os 18 agrupamentos formados, e os resultados foram apresentados apenas para os níveis em que a clusterização teve maiores índices *Silhouette*. Após isso, os resultados foram dispostos em gráficos tridimensionais para o agrupamento de dados. Para composição dos gráficos tridimensionais, foi realizado o seguinte procedimento: para os sensores de emissão acústica, cada eixo do gráfico representa a energia do respectivo nível de detalhe ou aproximação obtido pela TWD; para o sensor de vibração, cada eixo do gráfico representa a energia da TWD para os eixos X, Y e Z fornecidos pelo acelerômetro; para os sensores de corrente, cada eixo do gráfico representa a energia da TWD de cada uma das correntes elétricas de linha do sistema. Com o gráfico tridimensional realizado, aplicou-se o algoritmo *K-means* para a realização da clusterização e, com isso, a identificação da fase elétrica afetada, bem como a classificação da severidade da falta. Por fim, para determinação da eficácia da técnica, utilizou-se o índice estatístico *Silhouette*, capaz de quantificar a qualidade dos agrupamentos obtidos. Este procedimento foi repetido para diferentes níveis de carregamento (50% a 100%), verificando a influência que esta variação tem sobre a técnica proposta. O fluxograma apresentado na Figura 22 resume as análises de processamento digital de sinais utilizadas nesta tese.

Desta forma, os resultados obtidos pela aplicação das duas técnicas para cada um dos sensores foram comparados, demonstrando qual técnica e qual sensor apresentou o melhor desempenho para o diagnóstico de falhas ITSC e DT em MIT.

Figura 22 – Fluxograma da análise de processamento de sinais



Fonte: autoria própria

Capítulo 6

Resultados e Discussão

Neste capítulo serão apresentados os resultados experimentais obtidos, bem como a aplicação das técnicas de processamentos de sinais. Além disso, será efetuada uma análise comparativa entre os sensores e entre as transformadas utilizadas.

6.1 Sensores de corrente aplicado a diagnóstico de falhas ITSC e DT


Neste tópico, serão apresentados os resultados obtidos por meio da aquisição dos sinais de corrente na alimentação do motor de indução trifásico, no momento em que há a ocorrência das falhas elétricas ITSC e DT. A detecção da falha foi obtida por meio da função correlação cruzada. Já a identificação da fase elétrica afetada, bem como a classificação da severidade da falta foram obtidos por meio das técnicas de processamento de sinais baseadas na Transformada Hilbert e Transformada Wavelet. Em um primeiro momento, serão apresentados os resultados obtidos por meio da aplicação da Transformada Hilbert. Após isso, os resultados discutidos serão acerca da utilização da TWD.

6.1.1 Detecção do Desequilíbrio de Tensão utilizando TH

Com o intuito de realizar o diagnóstico de falhas em DT para valores menores que 10% de afundamento, aplicou-se desequilíbrios de 5% e 10% em cada um das fases elétricas. A detecção da falha DT foi realizada por meio da função correlação cruzada dos sinais analíticos obtidos pela aplicação da TH entre o sinal do motor em operação saudável (a *baseline*) e todas as situações de falha proposta neste trabalho. A Figura 23 apresenta os valores médios de autocorrelação da *baseline* em

comparação com a correlação cruzada entre *baseline* e os sinais de falha DT de 5% e 10% em cada uma das fases elétricas.

Figura 23 – Valor limiar da função correlação cruzada normalizada para a detecção de DT



Fonte: autoria própria


Pela análise da Figura 23, nota-se que, ao se comparar os sinais de falha DT com os sinais do motor de indução em operação normal, existe um limiar que indica a ocorrência deste tipo de falha. Após a detecção da falha, é possível identificar a fase afetada, conforme descrito a seguir.

6.1.2 Identificação da fase desequilibrada e classificação de severidade utilizando TH

Três sensores de corrente foram colocados em cada uma das fases elétricas do motor de indução. Após isso, aplicou-se duas falhas DT de 5% e 10% em cada uma das fases elétricas. Além disso, variou-se o carregamento do MIT de 100% até 50%, com passos de 10%. Os sinais medidos foram processados e, pela aplicação da TH, obteve-se um sinal analítico. Deste sinal analítico, calculou-se a energia do envelope. Cada um dos três sensores de corrente foi associado a um eixo de um gráfico tridimensional. Isso foi feito com o intuito de se observar um comportamento de clusterização. Em um primeiro momento, o agrupamento foi realizado para o MIT

operando a plena carga. A Figura 24 apresenta este comportamento para os níveis DTs aplicados com 100% de carregamento.

Figura 24 – Agrupamento das fases afetadas e grau de severidade para 100% de carregamento




Fonte: autoria própria

Pela análise da 24 é possível observar que houve um comportamento de agrupamento para cada uma das 50 amostras de cada fase e severidade para 100% de carregamento no eixo do MIT. Este resultado se torna esperado, uma vez que trata-se de uma falha elétrica que afeta o comportamento da corrente elétrica de alimentação. Além disso, o comportamento de clusterização proporcionou o diagnóstico da falta DT, uma vez que a Transformada Hilbert não altera a amplitude do sinal. Isso faz com que, a TH se torne interessante pois, há alteração de comportamento na amplitude da corrente ocasionada pela falta DT.

Para se estabelecer a eficácia da técnica proposta, foram calculados parâmetros estatísticos para determinação do grau de eficácia do agrupamento proposto. O índice de Silhouette foi calculado para cada um dos seis clusters apresentados, utilizando o algoritmo de *k-means*. Os valores dos índices de Silhouette são apresentados na Figura 25. Este índice revela que a técnica proposta apresentou um agrupamento capaz de realizar a identificação da fase elétrica afetada bem como a classificação de severidade, uma vez que o valor da Silhouette foi próximo a 1 (representando o melhor agrupamento).

Figura 25 – Índice Silhouette para os agrupamentos obtidos




Fonte: autoria própria

Com o objetivo de se averiguar a influência do carregamento aplicado ao eixo do MIT, variou-se a carga de 100% até 50% em passos de 10%. A Figura 26 apresenta o comportamento para este ensaio. Vale ressaltar que a variação de carregamento ocorreu concomitantemente à aplicação da falha DT. É possível observar que o comportamento de clusterização se manteve para as fases afetadas e para os graus de severidade aplicados. Além disso, é possível observar um comportamento proporcional entre a variação de carregamento e o nível de energia do envelope obtidos do sinal analítico fornecido pela Transformada Hilbert.


Desta forma, nota-se que a variação do carregamento do MIT não influenciou em nada o comportamento da clusterização utilizado para o diagnóstico da falha DT. Com isso, é possível determinar qual o carregamento presente no eixo do MIT e, concomitantemente, realizar o diagnóstico da falha DT. Para se determinar o carregamento presente no eixo do motor, aplica-se a regressão nos sinais de correlação cruzada entre a *baseline* e níveis de falha DT. Para a fase elétrica A, a regressão obtém um índice 0,9499, conforme indica a Figura 27. Já para a fase B, o índice R^2 de 0,9453 (Figura 28). E, por fim, a fase C teve um índice de 0,9442, como visto na Figura 29. Todos as fases apresentaram índices R^2 próximos a 1, mostrando a possibilidade de se identificar o nível de carregamento, e após isso, a fase afetada e o grau de severidade da falha DT.

Figura 26 – Agrupamento da falha DT para todos os níveis de carregamento




Fonte: autoria própria

Figura 27 – Regressão linear para Fase A




Fonte: autoria própria

Figura 28 – Regressão linear para Fase B



Fonte: autoria própria

Figura 29 – Regressão linear para Fase C




Fonte: autoria própria

6.1.3 Detecção do ITSC utilizando TH

Aplicou-se ao MIT dois níveis de ITSC, de duração de um segundo, em cada uma das fases elétricas (5,5% e 11%). Com o intuito de se detectar este tipo de falha no estator da máquina elétrica, utilizou-se a função correlação cruzada dos sinais obtidos pela aplicação da TH entre a *baseline* e os sinais oriundos da aplicação da falta. A Figura 30 apresenta os valores médios de autocorrelação da *baseline* em comparação com a correlação cruzada entre *baseline* e os sinais de falha ITSC de 5,5% e 11% em cada uma das fases elétricas.

Figura 30 – Valor limiar da função correlação cruzada normalizada para a detecção de ITSC



Fonte: autoria própria


Pela análise da Figura 30, observa-se um valor Limiar próximo a 0,5. Este limiar indica a ocorrência deste tipo de falta. Além disso, ao se comparar com a Figura 23 nota-se que os valores limiares são distintos entre si, indicando uma diferença de comportamento que essas duas falhas causam ao MIT. Após a detecção da falha, é possível identificar a fase afetada e seu grau de severidade, conforme descrito a seguir.

6.1.4 Identificação da fase afetada pelo curto entre espiras e classificação de severidade utilizando TH

Do mesmo modo que para a falta DT, três sensores de corrente foram colocados em cada uma das fases elétricas do motor de indução. Após isso, aplicou-se as falhas ITSC de 5,5% e 11% devido a alteração do enrolamento do estator do MIT utilizado

no ensaio. Além disso, variou-se o carregamento do MIT de 100% até 50%. Os sinais medidos foram processados por meio do valor do envelope obtido do sinal analítico fornecido pela aplicação da TH. Cada um dos três sensores de corrente foi associado a um eixo de um gráfico tridimensional. A Figura 31 apresenta o comportamento de clusterização para as falhas ITSC aplicadas ao MIT com 100% de carregamento.

Figura 31 – Agrupamento das fases afetadas por ITSC e grau de severidade para 100% de carregamento




Fonte: autoria própria

Utilizando o índice Silhouette e a técnica *k-means* para estabelecer parâmetros estatísticos e quantificar a eficácia do cluster, obteve-se o seguinte comportamento, conforme mostrado na Figura 32. Este índice revela que a técnica proposta também apresentou um comportamento de agrupamento de dados capaz de realizar o diagnóstico para a falha ITSC, uma vez que o valor da Silhouette foi próximo a 1.

No entanto, conforme há a variação de carregamento no eixo do motor, os agrupamentos tendem para um comportamento linear, fazendo com que o índice Silhouette apresente valores mais baixos. Isto pode ser exemplificado para o pior caso, em que o carregamento se encontra em 50% do valor nominal. A Figura 33 apresenta a clusterização, enquanto que a Figura 34 apresenta os valores dos índices Silhouette para cada cluster. É possível observar que houve um certo padrão de agrupamento, no entanto linear, fazendo com que os pontos ficassem distantes do centróide, diminuindo assim o índice Silhouette.


Figura 32 – Índice Silhouette para os agrupamentos obtidos



Fonte: autoria própria


A Figura 35 apresenta a variação de carregamento de 100% a 50% do valor nominal do MIT em conjunto com os níveis de falha ITSC. Do mesmo modo que para a falha DT, é possível observar que há um padrão para a variação de carga. Este padrão permite identificar o nível de carregamento no eixo do motor, e após isso, identificar a

Figura 33 – Agrupamento das fases afetadas por ITSC e grau de severidade para 50% de carregamento



Fonte: autoria própria


Figura 34 – Índice Silhouette para os agrupamentos obtidos com 50% de carregamento



Fonte: autoria própria

fase elétrica afetada, bem como o grau de severidade.

Figura 35 – Agrupamento da falha ITSC para todos os níveis de carregamento




Fonte: autoria própria

O carregamento pode ser identificado por meio da técnica de regressão linear. Para isso, aplica-se a regressão nos sinais de correlação cruzada entre a *baseline* e níveis de falha ITSC. Para a fase elétrica A, o índice R^2 foi de 0,9730, conforme indica a


Figura 36. Já para a fase B, o índice R^2 de 0,9731 (Figura 37). E, por fim, a fase C teve um índice de 0,9751, como visto na Figura 38. Todos as fases apresentaram índices R^2 próximos a 1, mostrando a possibilidade de se identificar o nível de carregamento, e após isso, a fase afetada e o grau de severidade da falha ITSC.

Figura 36 – Regressão linear para Fase A - falta ITSC




Fonte: autoria própria

Figura 37 – Regressão linear para Fase B - falta ITSC



Fonte: autoria própria

Figura 38 – Regressão linear para Fase C - Falta ITSC




Fonte: autoria própria

6.1.5 Detecção do DT utilizando TWD

Do mesmo modo do que a técnica de detecção utilizando a Transformada Hilbert, aplicou-se a função correlação cruzada nos sinais obtidos após aplicação da Transformada Wavelet Discreta. A Figura 39 apresenta os valores médios de autocorrelação da *baseline* em comparação com a correlação cruzada entre *baseline* e os sinais de falha DT de 5% e 10% em cada uma das fases elétricas.

Figura 39 – Valor limiar da função correlação cruzada normalizada para a detecção de DT utilizando a TWD




Fonte: autoria própria

Pela análise da Figura 39, observa-se o comportamento da falta DT apresentou um valor de correlação cruzada normalizada próxima a 0,45.

6.1.6 Identificação da fase afetada por DT e classificação de severidade utilizando TWD

Após a aplicação da falha DT de 5% e 10%, os sinais oriundos dos sensores de corrente foram processados por meio da TWD, e o sinal de energia foi calculado para 9 níveis de detalhe e 9 níveis de aproximação. Com isso, analisou-se os 18 agrupamentos formados, e verificou-se que o nível Wavelet que apresentou maior índice Silhouette foi o nível de detalhe 4. A clusterização relacionada aos sinais Wavelet para este nível é mostrado na Figura 40. É importante ressaltar que cada eixo do gráfico 3D representa o sinal de energia da TWD para um sensor de corrente. Além disso, o motor está com 100% de carregamento neste ensaio.

Figura 40 – Agrupamento das fases afetadas por DT e grau de severidade para 100% de carregamento utilizando TWD




Fonte: autoria própria

O índice Silhouette para cada um dos agrupamentos da Figura 40 é apresentado na Figura 41. Este resultado mostra que a Transformada Wavelet Discreta é uma boa técnica para o diagnóstico de DT utilizando sensores de corrente.

Variando o carregamento do motor de indução de 100% até 50% de seu valor nominal, o agrupamento visto na Figura 40 se mantém para todos os níveis de carga e de falta DT, conforme visto na Figura 42. Além disso, observa-se um certo padrão


Figura 41 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento



Fonte: autoria própria


de comportamento, este padrão permite que o carregamento seja identificado, e após isso, a fase seja identificada, bem como o grau de severidade seja classificado. A identificação do carregamento é feita por meio da regressão linear dos valores de correlação cruzada da TWD, conforme indicam a Figura 43, Figura 44 e Figura 45.

Figura 42 – Agrupamento da falha DT para todos os níveis de carregamento utilizando TWD




Fonte: autoria própria

Figura 43 – Regressão linear para Fase A - falta DT - TWD




Fonte: autoria própria

Figura 44 – Regressão linear para Fase B - falta DT - TWD



Fonte: autoria própria

Figura 45 – Regressão linear para Fase C - Falta DT - TWD




Fonte: autoria própria

6.1.7 Detecção do ITSC utilizando TWD

Do mesmo modo que nos tópicos anteriores, a técnica para a detecção da ocorrência da falha foi o mesmo. A Figura 46 apresenta os valores médios de auto-correlação da *baseline* em comparação com a correlação cruzada entre *baseline* e os sinais de falha ITSC de 5,5% e 11% em cada uma das fases elétricas.

Figura 46 – Valor limiar da função correlação cruzada normalizada para a detecção de ITSC utilizando a TWD



Fonte: autoria própria


Pela análise da Figura 46, observa-se o comportamento da falta ITSC apresentou um valor de correlação cruzada normalizada próxima a 0,55.

6.1.8 Identificação da fase afetada por ITSC e classificação de severidade utilizando TWD

Após a aplicação da falha ITSC de 5,5% e 11%, os sinais oriundos dos sensores de corrente foram processados por meio da TWD, e o sinal de energia foi calculado para 9 níveis de detalhe e 9 níveis de aproximação. Com isso, analisou-se os 18 agrupamentos formados, e verificou-se que o nível Wavelet que apresentou maior índice Silhouette foi o nível de detalhe 2. A clusterização relacionada aos sinais Wavelet para este nível é mostrado na Figura 47. Analisando a Figura, nota-se que o comportamento de agrupamento apresentou pontos distantes do centroide de seu

cluster e próximos a centroides de outros clusters. Nota-se ainda que, durante os 50 ensaios, alguns pontos apresentaram padrão de comportamento distinto, conforme observado na Fase B com 5,5% de ITSC e Fase C com 11% de ITSC. Vale ressaltar que, para todos os ensaios realizados, todas as condições foram mantidas constantes, e que havia apenas a falta ITSC sendo aplicada ao MIT.

Figura 47 – Agrupamento das fases afetadas por ITSC e grau de severidade para 100% de carregamento utilizando TWD



Fonte: autoria própria


Este comportamento supracitado pode ser quantificado por meio do índice Silhouette (Figura 48).

Este resultado mostra que a Transformada Wavelet Discreta aliada ao sinal de Energia é uma boa técnica para a detecção de DT utilizando sensores de corrente, no entanto, apresenta um comportamento pior do que a utilização da TH, em que o menor índice Silhouette foi de 0,94, já neste caso foi de 0,67 para fase A 5,5% de ITSC.

No entanto, ainda comparando com os resultados obtidos para a falta ITSC com a utilização da TH, conforme se diminui a carga até 50% de seu valor nominal, o comportamento do cluster apresenta uma melhora, e, em nenhum momento, apresenta comportamento linear. A Figura 49 apresenta a clusterização para 50% de carregamento. Já a Figura 50 apresenta os respectivos índices Silhouettes.


Com isso, pode-se identificar o nível de carregamento, e, assim, classificar a fase elétrica afetada pelo ITSC e seu grau de severidade. A identificação do carregamento é

Figura 48 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento - falta ITSC



Fonte: autoria própria


Figura 49 – Agrupamento das fases afetadas por ITSC e grau de severidade para 50% de carregamento utilizando TWD



Fonte: autoria própria


feita por meio da regressão linear dos valores de correlação cruzada da TWD, conforme indicam a Figura 51, Figura 52 e Figura 53.

Figura 50 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 50% de carregamento - falta ITSC




Fonte: autoria própria

Figura 51 – Regressão linear para Fase A - falta ITSC - TWD




Fonte: autoria própria

Figura 52 – Regressão linear para Fase B - falta ITSC - TWD



Fonte: autoria própria

Figura 53 – Regressão linear para Fase C - Falta ITSC - TWD



Fonte: autoria própria


6.2 Sensor MEMS aplicado a diagnóstico de falhas ITSC e DT

Neste tópico, serão apresentados os resultados obtidos por meio da aquisição dos sinais de vibração presentes no MIT, no momento em que há a ocorrência das falhas. Em um primeiro momento, serão apresentados os resultados obtidos por meio da aplicação da Transformada Hilbert. Após isso, os resultados discutidos serão acerca da utilização da TWD.

6.2.1 Detecção do Desequilíbrio de Tensão utilizando TH - sensor MEMS

A detecção da falha DT foi obtida por meio da diferença entre a autocorrelação da *baseline* com a correlação cruzada entre a *baseline* e os sinais de falha DT de 5% e 10% obtidos em cada um dos eixos (X, Y e Z) do sensor MEMS. Este resultado pode ser visto na Figura 54. Observa-se um limiar que indica a ocorrência da falha.

Figura 54 – Detecção da ocorrência da falha DT para técnica utilizando TH e aquisição por sensor MEMS




Fonte: autoria própria

6.2.2 Identificação da fase desequilibrada e classificação de severidade utilizando TH e Sensor MEMS

Um sensor MEMS foi anexado à carcaça do MIT, conforme descrito em Material e Métodos. Após isso, aplicou-se os DT de 5% e 10% para cada uma das fases elétricas. Além disso, variou-se o carregamento do motor de 100% até 50% de seu valor nominal. Com a aplicação da falha, o motor de indução altera seu padrão vibratório, e o sensor MEMS mede essa vibração em três eixos (X, Y e Z). Estes sinais medidos, são processados por meio do envelope obtido do sinal analítico fornecido pela Transformada de Hilbert. Cada eixo do sensor de vibração está associado a um eixo de um gráfico 3D. A clusterização para 100% de carregamento é mostrada na Figura 55.

Figura 55 – Agrupamento das fases afetadas e grau de severidade para 100% de carregamento utilizando TH e sensor MEMS




Fonte: autoria própria

É possível observar que a Transformada Hilbert dos sinais medidos por sensor MEMS não é uma boa técnica para clusterização de falhas DT. Isto pode ser quantificado por meio do índice Silhouette (Figura 56). Nota-se que não houve nenhum índice maior que 0,7. Isso se deve ao fato das falhas DT apresentarem um padrão parecido de comportamento vibratório para os três eixos do sensor MEMS. Nota-se ainda que a técnica de processamento proposta fornece a separação entre os níveis de DT aplicados, mas não consegue identificar qual fase elétrica foi afetada pela falta.

Além disso, a medida em que o nível de carregamento diminui, o perfil de


Figura 56 – Índice Silhouette para TH utilizando MEMS - 100% de carregamento



Fonte: autoria própria

agrupamento acaba ficando cada vez pior, conforme indica a Figura 57. Portanto, esta técnica não apresentou a eficácia desejada para o diagnóstico de falhas DT.

Figura 57 – Agrupamento das fases afetadas e grau de severidade para 50% de carregamento utilizando TH e sensor MEMS




Fonte: autoria própria

6.2.3 Detecção do ITSC utilizando TH e sensor MEMS

Do mesmo modo do que para a falha DT, aplicou-se dois níveis de ITSC em cada uma das fases elétricas com duração de 1 segundo (5,5% e 11%). Com o intuito de se detectar este tipo de falha no estator da máquina elétrica, utilizou-se a função correlação cruzada dos sinais obtidos pela aplicação da TH entre a *baseline* e os sinais oriundos da aplicação da falta. A Figura 58 apresenta os valores médios de

autocorrelação da *baseline* em comparação com a diferença entre a autocorrelação e a correlação cruzada entre *baseline* e os sinais de falha ITSC de 5,5% e 11% em cada uma das fases elétricas.

Figura 58 – Valor limiar da função correlação cruzada normalizada para a detecção de ITSC utilizando TH e sensor MEMS



Fonte: autoria própria


6.2.4 Identificação da fase afetada pela falta ITSC e classificação de severidade utilizando TH e sensor MEMS

Para a falta ITSC utilizando a Transformada Hilbert e sensor MEMS, foi possível obter a identificação da fase afetada além da classificação de severidade. Este comportamento de agrupamento é mostrado na Figura 59. Esta análise é para um carregamento nominal.

Pela análise da Figura, nota-se que os agrupamentos da Fase A e Fase B ficaram com seus respectivos dados próximos aos centroides dos outros clusters. Isto pode ser evidenciado pelo índice Silhouette mostrado na Figura 60. Observa-se que a clusterização não foi ótima, uma vez que para Fase A 5,5% de ITSC e para Fase B 5,5% de ITSC os índices foram, respectivamente, 0,4601 e 0,5067.


Por mais que a identificação do grau de severidade da falha não seja viável utilizando esta técnica, a classificação da fase afetada é, conforme indica a Figura 61 e a Figura 62.

Figura 59 – Agrupamento das fases afetadas por ITSC e grau de severidade para 100% de carregamento utilizando TH e sensor MEMS



Fonte: autoria própria


Figura 60 – Índice Silhouette para os agrupamentos obtidos por meio da TH e sensor MEMS



Fonte: autoria própria


Conforme se varia o nível de carregamento, nota-se que o comportamento de clusterização não se mantém, fazendo com que esta técnica não seja viável para identificação do grau de severidade da falha ITSC. O comportamento de agrupamento para 50% é mostrado na Figura 63. Já seu índice Silhouette é mostrado na Figura 64. Além disso, não há qualquer padrão de comportamento, em que seja viável uma regressão, conforme indicam a Figura 65, Figura 66 e Figura 67. Com isso, não se dá para determinar o que é efeito de carregamento e o que é efeito de falha.

Figura 61 – Agrupamento das fases afetadas por 5,5% de ITSC e para 100% de carregamento utilizando TH e sensor MEMS




Fonte: autoria própria

Figura 62 – Índice Silhouette para os agrupamentos obtidos por meio da TH e sensor MEMS - 5,5% de severidade de ITSC




Fonte: autoria própria

Figura 63 – Agrupamento das fases afetadas por 5,5% de ITSC e para 100% de carregamento utilizando TH e sensor MEMS




Fonte: autoria própria

Figura 64 – Índice Silhouette para os agrupamentos obtidos por meio da TH e sensor MEMS - 5,5% de severidade de ITSC




Fonte: autoria própria

Figura 65 – Regressão linear para Fase A - falta ITSC




Fonte: autoria própria

Figura 66 – Regressão linear para Fase B - falta ITSC



Fonte: autoria própria

Figura 67 – Regressão linear para Fase C - Falta ITSC




Fonte: autoria própria

6.2.5 Detecção do DT utilizando TWD e sensor MEMS

Do mesmo modo do que a técnica de detecção utilizando a Transformada Hilbert, aplicou-se a função correlação cruzada nos sinais obtidos após aplicação da Transformada Wavelet Discreta. A Figura 68 apresenta os valores médios de autocorrelação da *baseline* em comparação com a diferença entre a autocorrelação e correlação cruzada entre *baseline* e os sinais de falha DT de 5% e 10% em cada uma das fases elétricas.

Figura 68 – Valor limiar da função correlação cruzada normalizada para a detecção de DT utilizando a TWD




Fonte: autoria própria

6.2.6 Identificação da fase afetada por DT e classificação de severidade utilizando TWD e sensor MEMS

Ao ser aplicado falhas DT de 5% e 10% de intensidade, o padrão vibratório da máquina de indução se altera. O sensor MEMS mede estes sinais em três eixos e aplica-se a TWD. Após isso, calcula-se o sinal de energia para cada um dos 18 níveis Wavelets (9 de aproximação e 9 de detalhe) e analisa qual agrupamento apresenta o melhor índice Silhouette. O nível que apresentou o melhor índice foi o nível 6 de aproximação. A clusterização relacionada aos sinais Wavelet para este nível é mostrado na Figura 69. É importante ressaltar que cada eixo do gráfico 3D representa o sinal de energia da TWD para eixo do sensor MEMS. Além disso, o motor está com 100% de carregamento neste ensaio. O índice Silhouette para cada um dos agrupamentos


da Figura 69 é apresentado na Figura 70. Este resultado mostra que a Transformada Wavelet Discreta é uma boa técnica para a detecção de DT utilizando sensor MEMS. No entanto, as faltas DT aplicadas a Fase B e C, respectivamente, apresentam um comportamento vibratório similar, fazendo com que o índice Silhouette ficasse em, aproximadamente, 0,65.

Figura 69 – Agrupamento das fases afetadas por DT e grau de severidade para 100% de carregamento utilizando TWD e sensor MEMS



Fonte: autoria própria


Figura 70 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento



Fonte: autoria própria

No entanto, esta técnica não é capaz de diferenciar a variação de carregamento da falha. Isto pode ser visto na Figura 71, em que o carregamento é de 50%.

Figura 71 – Agrupamento das fases afetadas por DT e grau de severidade para 50% de carregamento utilizando TWD e sensor MEMS




Fonte: autoria própria

6.2.7 Detecção do ITSC utilizando TWD e sensor MEMS

Do mesmo modo que nos tópicos anteriores, a técnica para a detecção da ocorrência da falha foi a mesma. A Figura 72 apresenta os valores médios de auto-correlação da *baseline* em comparação com a correlação cruzada entre *baseline* e os sinais de falha ITSC de 5,5% e 11% em cada uma das fases elétricas.

Figura 72 – Valor limiar da função correlação cruzada normalizada para a detecção de ITSC utilizando a TWD e sensor MEMS




Fonte: autoria própria

6.2.8 Identificação da fase afetada por ITSC e classificação de severidade utilizando TWD e sensor MEMS

Após a aplicação da falha ITSC de 5,5% e 11%, os sinais oriundos do sensor MEMS foram processados por meio da TWD, e o sinal de energia foi calculado para 9 níveis de detalhe e 9 níveis de aproximação. Com isso, analisou-se os 18 agrupamentos formados, e verificou-se que o nível Wavelet que apresentou maior índice Silhouette foi o nível de detalhe 4. A clusterização relacionada aos sinais Wavelet para este nível é mostrado na Figura 73.

Figura 73 – Agrupamento das fases afetadas por ITSC e grau de severidade para 100% de carregamento utilizando TWD e sensor MEMS




Fonte: autoria própria

O agrupamento é quantificado por meio do índice Silhouette (Figura 74). Este resultado mostra que a Transformada Wavelet Discreta aliada é uma boa técnica para a diagnóstico de ITSC utilizando sensor MEMS. Apresentando um melhor comportamento do que com a técnica utilizando a TH, uma vez que o menor índice foi de 0,8170 para a Fase C, com 11% de nível ITSC, já para a TH, o menor índice foi de aproximadamente 0,6.

Analisando o comportamento de apenas um grau de severidade (5,5%), fica mais evidente a classificação da fase afetada, conforme mostra a Figura 75. Seu índice Silhouette é mostrado na Figura 76.


Ao se variar o carregamento de 100% até 50%. O comportamento de clusterização se mantém, conforme indica a Figura 77. O índice Silhouette para o cluster é apresentado na Figura 78.

Figura 74 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento - falta ITSC - uso de sensor MEMS



Fonte: autoria própria


Figura 75 – Agrupamento das fases afetadas por ITSC de 5,5% e 100% de carregamento utilizando TWD e sensor MEMS



Fonte: autoria própria


No entanto, quando se aplica mais de um grau de severidade, a técnica proposta não apresenta um bom comportamento.

Figura 76 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 100% de carregamento - falta ITSC de 5,5% - uso de sensor MEMS




Fonte: autoria própria

Figura 77 – Agrupamento das fases afetadas por ITSC de 5,5% e 50% de carregamento utilizando TWD e sensor MEMS



Fonte: autoria própria

Figura 78 – Índice Silhouette para os agrupamentos obtidos na aplicação da TWD para 50% de carregamento - falta ITSC de 5,5% - uso de sensor MEMS



Fonte: autoria própria

6.3 Sensores PZT aplicados a diagnóstico de falhas ITSC e DT

Nesta seção, serão apresentados os resultados obtidos por meio da aquisição de sinais de emissão acústica presentes no MIT, no momento da ocorrência de falhas elétricas no estator (DT e ITSC). Foi utilizado quatro sensores piezoelétricos anexados a carcaça do motor de indução, conforme a Figura 21. Primeiramente, serão apresentados os resultados obtidos pela aplicação da Transformada Hilbert para diagnóstico das falhas estudadas. Após, serão apresentados os resultados obtidos pela aplicação da Transformada Wavelet.


6.3.1 Diagnóstico de falhas DT e ITSC utilizando Transformada Hilbert e sensores PZT

A aplicação da transformada Hilbert para a detecção da falha, bem como identificação das fases afetadas e classificação de severidade não apresentou resultados promissores. No entanto, a clusterização para os níveis de falha DT de 5% e 10% com 100% de carregamento no eixo do motor permitiu o diagnóstico da falha, conforme será explicado a seguir. No entanto, a medida em que variou-se 10% de carregamento, o sistema se perdeu. Para exemplificar isso, a Figura 79 apresenta a Identificação da fase elétrica afetada para 100% de carregamento, bem como a classificação de sua severidade. A Figura 80 apresenta o índice Silhouette para este agrupamento. Nota-se que os agrupamentos referentes as fases elétricas e aos níveis de falha DT tiveram índices Silhouette relativamente altos (todos maiores que 0,8), garantindo que a fase elétrica submetida a falta DT fosse identificada e o grau de severidade fosse classificado.

Já a Figura 81 apresenta a piora de agrupamento quando se reduz o carregamento para 90%. Para quantificar esta piora, utilizou-se a métrica estatística Silhouette (Figura 82).


Como este trabalho buscou estudar, além do diagnóstico de falhas, a influência de carregamento neste diagnóstico, a Figura 83 apresenta a clusterização para o pior caso (50% de carregamento). Com isso, observa-se que, com a variação de carregamento, o padrão de clusterização sofre alteração, fazendo com que o resultado

Figura 79 – Agrupamento das fases afetadas por DT de 5% e 10% para 100% de carregamento utilizando TH e sensores PZT



Fonte: autoria própria

Figura 80 – Índice Silhouette para os agrupamentos obtidos na aplicação da TH para 100% de carregamento - falta DT de 5,5% e 10% - uso de sensores PZT




Fonte: autoria própria

não seja alcançado, em comparação ao sensor de corrente.


Para as falhas ITSC, a técnica não foi capaz de realizar qualquer tipo de diagnóstico, independente do carregamento no eixo do motor de indução.

Figura 81 – Agrupamento das fases afetadas por DT de 5% e 10% para 90% de carregamento utilizando TH e sensores PZT




Fonte: autoria própria

Figura 82 – Índice Silhouette para os agrupamentos obtidos na aplicação da TH para 100% de carregamento - falta DT de 5,5% e 10% - uso de sensores PZT



Fonte: autoria própria

Figura 83 – Agrupamento das fases afetadas por DT de 5% e 10% para 50% de carregamento utilizando TH e sensores PZT




Fonte: autoria própria

6.3.2 Diagnóstico de falhas DT utilizando Transformada Wavelet Discreta e sensores PZT

A detecção do desequilíbrio de tensão é realizada por meio da diferença entre a autocorrelação da *baseline* com a comparação dos sinais de falha com o sinal sem falha. A Figura 84 apresenta um limiar de DT para a detecção da ocorrência de falha.

Figura 84 – Detecção da ocorrência da Falha DT




Fonte: autoria própria

Após a falha ser detectada, é possível identificar a fase elétrica afetada, além de classificar a magnitude da falha. Com isso, aplicou-se falhas DTs de 5% e 10% na alimentação do MIT. Os sinais medidos pelos quatro sensores PZT foram processados por meio da TWD. Obtiveram-se 18 níveis Wavelet, sendo 9 de aproximação e 9 de detalhe. Ao se analisar o agrupamento a respeito da fase elétrica afetada e da magnitude da falha, observou-se que o nível de detalhe 6 foi o que apresentou a melhor clusterização. Com isso, a Figura 85 apresenta a identificação da fase elétrica afetada e a classificação da severidade da falha para faltas DT aplicadas ao MIT a plena carga. Pela análise da Figura, nota-se que a técnica permitiu a identificação da fase afetada bem como a classificação do grau de severidade. Aplicou-se o índice Silhouette com o intuito de se evidenciar a eficácia do método proposto (Figura 86). Para 100%, houve um excelente diagnóstico, em que o índice mais baixo foi de 0,9509 para a fase A com 5% de DT.


Ao se variar a carga aplicada no eixo do motor, o comportamento de clusteriza-

Figura 85 – Agrupamento para identificação da fase afetada e classificação de severidade para falta DT utilizando TWD e sensores PZT - plena carga



Fonte: autoria própria

Figura 86 – Índice Silhouette para identificação da fase afetada e classificação de severidade para falta DT utilizando TWD e sensores PZT - plena carga




Fonte: autoria própria

ção se mantém, conforme indicam a Figura 87 e a Figura 88. Analisando os resultados, nota-se que quando se altera o carregamento de 100% para 50%, o comportamento de classificação se mantém eficaz, possibilitando, ainda, a identificação da fase afetada e a classificação de severidade.


Desta forma, é necessário identificar o carregamento presente na máquina

Figura 87 – Agrupamento para identificação da fase afetada e classificação de severidade para falta DT utilizando TWD e sensores PZT - 50% de carregamento



Fonte: autoria própria

Figura 88 – Índice Silhouette para identificação da fase afetada e classificação de severidade para falta DT utilizando TWD e sensores PZT - 50% de carregamento




Fonte: autoria própria

elétrica, para poder realizar o diagnóstico de falha. Para isso, utilizou-se a função correlação cruzada entre a *baseline* e os sinais de falha. com os valores médios oriundos deste cálculo, realizou-se uma regressão linear e obteve-se altos índices de R^2 (0,8449; 0,8742 e 0,8846), indicando a possibilidade de se conhecer o carregamento presente no MIT. Os valores da regressão linear para as fases A, B e C, são mostradas,


respectivamente, na Figura 89, Figura 90 e Figura 91.

Figura 89 – R^2 para a fase A sob falha DT



Fonte: autoria própria


Figura 90 – R^2 para a fase B sob falha DT



Fonte: autoria própria

6.3.3 Diagnóstico de falhas ITSC utilizando Transformada Wavelet Discreta e sensores PZT


A falta ITSC pode ser detectada por meio da diferença entre a autocorrelação da *baseline* com a correlação cruzada dos sinais de falha e sem falha. A Figura

Figura 91 – R^2 para a fase C sob falha DT

Fonte: autoria própria

92 apresenta a ocorrência desta falha. É possível observar que há um limitar para detecção, pois há uma diferença de comportamento entre sinais de falha com sinais do motor em operação normal.

Figura 92 – Detecção da ocorrência da Falha ITSC utilizando sensores PZT e TWD




Fonte: autoria própria

Uma vez que a falha ITSC foi detectada, é possível identificar a fase elétrica afetada, bem como classificar a severidade da falta. Para isso, aplicou-se falhas ITSC com duração de 1 segundo com 5,5% e 11% de magnitude. Os sinais medidos pelos quatro sensores PZT foram processados por meio da Transformada Wavelet Discreta. 18 níveis Wavelet foram obtidos, sendo 9 coeficientes de aproximação e 9 de detalhe.

Ao se analisar o comportamento dos 18 níveis em relação ao diagnóstico de falha, obteve-se o nível 1 de detalhe como o melhor desempenho de clusterização. Com isso, a Figura 93 apresenta o diagnóstico de falhas ITSC em relação a identificação da fase elétrica afetada e classificação de severidade. A técnica proposta realizou este diagnóstico, permitindo a identificação da fase elétrica afetada e classificação de severidade da falta. Com o intuito de se evidenciar a eficácia do método proposto, utilizou-se o índice Silhouette (Figura 94). Com o MIT a plena carga, houve um bom diagnóstico, em que o índice mais baixo foi 0,67 para a Fase B com 5,5% de ITSC.

Figura 93 – Agrupamento para identificação da fase afetada e classificação de severidade para falta ITSC utilizando TWD e sensores PZT - plena carga




Fonte: autoria própria

Ao se variar a carga aplicada no eixo do motor, o comportamento de clusterização se mantém, conforme indicam a Figura 95 e a Figura 96. Analisando os resultados, nota-se que o carregamento não influencia na técnica de diagnóstico, possibilitando, ainda, a identificação da fase afetada e a classificação de severidade.


Desta forma, é necessário identificar o carregamento presente na máquina elétrica, para poder realizar o diagnóstico de falha. Para isso, utilizou-se a função correlação cruzada entre a *baseline* e os sinais de falha. com os valores médios oriundos deste cálculo, realizou-se uma regressão linear e obteve-se altos índices de R^2 (0,9490; 0,9099 e 0,8943), indicando a possibilidade de se conhecer o carregamento presente no MIT. Os valores da regressão linear para as fases A, B e C, são mostradas, respectivamente, na Figura 97, Figura 98 e Figura 99.

Figura 94 – índice Silhouette para identificação da fase afetada e classificação de severidade para falta ITSC utilizando TWD e sensores PZT - plena carga




Fonte: autoria própria

Figura 95 – Agrupamento para identificação da fase afetada e classificação de severidade para falta ITSC utilizando TWD e sensores PZT - 50% de carregamento




Fonte: autoria própria

Figura 96 – índice Silhouette para identificação da fase afetada e classificação de severidade para falta ITSC utilizando TWD e sensores PZT - 50% de carregamento




Fonte: autoria própria


Figura 97 – R^2 para a fase A sob falha ITSC



Fonte: autoria própria

Figura 98 – R^2 para a fase B sob falha ITSC

Fonte: autoria própria

Figura 99 – R^2 para a fase C sob falha ITSC

Fonte: autoria própria

6.4 Análise comparativa

Com o intuito de se realizar uma análise comparativa entre os sensores e as técnicas de processamento digital de sinais, os valores de limiares de detecção, índice *Silhouette* e de regressão são apresentados na Tabela 1. Os valores de limiar de detecção foram obtidos por meio da média da correlação cruzada entre o sinal de referência e o sinal oriundo da condição de falta no MIT. Desta forma, quando mais baixo for o valor do limiar de tensão em relação a unidade, maior eficácia a detecção terá.

Para comparação da identificação da fase elétrica afetada pela falha bem como a classificação do grau de severidade da falha, utilizou-se a média dos índices *Silhouette* para cada um dos seis agrupamentos obtidos com o motor operando a plena carga e sob condição de falha DT e ITSC. Os seis agrupamentos são respectivos aos dois níveis de falta e as três fases elétricas de alimentação do sistema. Por fim, para determinação do nível de carregamento aplicado ao eixo do MIT, utilizou-se a média dos valores obtidos da regressão linear para as três fases de alimentação do motor de indução.

Para o diagnóstico da falha de desbalanço de tensão, o sensor de corrente foi o que apresentou a maior sensibilidade tanto com a técnica baseada na TH quanto com a técnica baseada na TWD. Com o motor operando a plena carga, foi possível realizar a detecção da falta DT, com limiares de 0,3881 para TH e 0,4558 para a TWD. Além disso, a identificação da fase elétrica afetada e a classificação da severidade foi obtida, uma vez que os índices *Silhouette* foram de 0,9996 e 0,9865, respectivamente. Por fim, este sensor proporcionou a identificação do nível de carregamento aplicado ao eixo do MIT, uma vez que os valores de regressão foram de 0,9465 para técnica baseada na Transformada Hilbert e 0,9184 para técnica baseada na Transformada Wavelet Discreta. Para os mesmos níveis de falta DT aplicados a máquina elétrica, os sinais aquisitados pelo sensor piezoelétrico e processados por meio da utilização da TH tiveram resultados inconclusivos para a detecção da falta, bem como para a determinação do nível de carregamento. Desta forma, este ensaio permitiu apenas a identificação da fase elétrica afetada e a classificação do grau de severidade para o motor operando a plena carga (índice de 0,9601). No entanto, quando estes mesmos sinais são processados com auxílio da Transformada Wavelet Discreta, a falta é detectada (limiar de tensão de

0,5871), a clusterização é realizada (índice de 0,9760) e o nível de carregamento é identificado (regressão linear de 0,8679). Por mais que o sensor PZT proporcionou o correto diagnóstico da falta DT, os índices foram piores se comparados com os índices obtidos pela utilização dos sinais de corrente. Isso pode ser explicado pois, por se tratar de uma falha elétrica, a variação da corrente é mais perceptível que a variação da emissão acústica do sistema. Ainda neste tópico, a TH teve um melhor desempenho com sinais de corrente, pois esta não altera a amplitude do sinal, sendo o principal ponto de variação ocasionado pela falta. O sensor MEMS apresentou desempenho pior do que os sensores de corrente e PZT. Por mais que a falta tenha sido detectada, com limiares de tensão de 0,6057 para TH e 0,7728 para TWD, seus valores são maiores do que os obtidos pelo sensor de corrente. Além disso, este sensor permitiu o diagnóstico da falta DT apenas à plena carga, apresentando variações no padrão de agrupamento com a variação de carregamento.

Para a falha ITSC, os sinais oriundos dos sensores de corrente e PZT processados pela TWD tiveram desempenho parecido. Ambos permitiram o diagnóstico completo da falta ITSC com índices próximos, conforme apresentado na Tabela 1. No entanto, o sensor de corrente foi sensível a falta ITSC quando os sinais foram processados pela TH, permitindo o diagnóstico completo, com índice *Silhouette* de 0,9738 e regressão de 0,9737. Já, o mesmo não ocorreu para o sensor PZT. Este sensor não apresentou sensibilidade alguma e o diagnóstico não foi alcançado. Da mesma forma que ocorreu com a falta DT, o sensor MEMS proporcionou apenas o diagnóstico da falta ITSC com o motor a plena carga. Conforme há variação de carregamento, a clusterização passa a ser ineficaz e os resultados passam a ser não alcançados. Por fim, o resultado de maior destaque foi a sensibilidade do sensor PZT em conjunto com a TWD para o diagnóstico de falhas elétricas, dado o seu baixo custo em relação aos demais sensores, além de medir indiretamente a variável afetada pela falha.

Tabela 1 – Análise comparativa entre os sensores e técnicas de processamento de sinais.

Sensor	Falta	Técnica	Limiar de Detecção	Índice Silhouette a plena carga	Determinação de Carregamento
PZT	DT	Hilbert	Não Alcançado	0,9601	Não Alcançado
		Wavelet	0,5871	0,9760	0,8679
	ITSC	Hilbert	Não Alcançado	Não Alcançado	Não Alcançado
		Wavelet	0,3984	0,8014	0,9177
MEMS	DT	Hilbert	0,6057	0,5829	Não Alcançado
		Wavelet	0,7728	0,7134	Não Alcançado
	ITSC	Hilbert	0,3872	0,6071	0,5402
		Wavelet	0,1724	0,8661	Não Alcançado
Corrente	DT	Hilbert	0,3881	0,9996	0,9465
		Wavelet	0,4558	0,9865	0,9184
	ITSC	Hilbert	0,5237	0,9738	0,9737
		Wavelet	0,5058	0,8140	0,9205

Capítulo 7

Conclusão

Motores de Indução Trifásicos desempenham um importante papel nos dias atuais, especialmente em processos industriais. Isso se deve, principalmente, por suas características construtivas, como robustez, baixa necessidade de manutenção e alta eficiência. Dessa forma, qualquer parada inesperada neste componente pode gerar consequências econômicas, de produtividade e segurança. Portanto, técnicas de diagnóstico de falhas para detecção de falta em estágio inicial é fundamental para evitar danos severos. As principais estratégias para realização de diagnóstico são técnicas de monitoramento não invasivas, que apresentam como vantagens a possibilidade de detecção da falta, identificação e classificação de condições não ideais de operação. Para isso, sensores são empregados para obtenção de informações físicas (vibração, corrente, emissão acústica, entre outros) em relação a operação do motor.

Dessa forma, técnicas não invasivas de análise do sinal de corrente, análise de vibração e emissão acústica mostram-se como soluções adequadas para o estudo de diagnóstico de falha DT e ITSC em máquinas elétricas. Com isto, esta tese tem como objetivo o estudo de técnicas de monitoramento utilizando sensores de corrente de feito Hall e sensores MEMS e piezoelétricos de baixo custo. O sensor de corrente, na maioria da vezes, é utilizado em instalações industriais para monitoramento de condições da planta industrial, se mostrando como uma opção adequada para este tipo de diagnóstico, uma vez que já estarão sendo empregados. Além disso, o sensor MEMS de baixo custo se mostra como uma alternativa aos sensores de vibração convencionais para viabilizar o diagnóstico de falhas elétricas no estator. Do mesmo modo, os sensores PZT de baixo custo também se mostram como uma alternativa aos sensores de emissão acústica convencionais.

Neste contexto, propõe-se duas técnicas de processamento digital de sinais para o diagnóstico de falhas DT e ITSC no motor de indução utilizando três tipos diferentes de sensores (corrente, vibração e emissão acústica). A primeira falta analisada foi DT

de pequena intensidade (5% e 10%), no qual os dispositivos de proteção podem ser insensíveis, utilizando sensores de corrente de efeito Hall, sensor MEMS e sensores PZT. Para o diagnóstico deste tipo de falha, propôs-se duas técnicas distintas, uma baseada no envelope fornecido pelo sinal analítico da Transformada Hilbert e a segunda baseada na energia dos coeficientes de aproximação e detalhe da Transformada Wavelet Discreta. Além disso, analisou-se faltas ITSC de 5,5% e 11% de intensidade, com curta duração, em cada uma das fases elétricas do estator. Foram analisados os mesmos sensores para o diagnóstico dos dois tipos de falta, bem como as mesmas técnicas de processamento.

A aplicação da Transformada Hilbert aliado a sensores de corrente obteve um excelente desempenho para detecção de falhas ITSC e DT, apresentando identificação da fase elétrica afetada e classificação da severidade das faltas. Isso é garantido pelo alto índice Silhouette (acima de 0,8 para todos os casos) apresentado. Além disso, esta técnica permite o conhecimento do carregamento do motor, garantindo que não haja qualquer falso positivo a medida em que a carga mecânica varie. O bom desempenho da TH para o sensor de corrente se dá pois, está transformada não altera a amplitude do sinal de corrente original, sendo mais perceptível a falhas elétricas. A aplicação da energia dos coeficientes de aproximação e detalhe da TWD aliado a sensores de corrente também permitiu a detecção de falhas ITSC e DT, com identificação da fase elétrica afetada e classificação da severidade das faltas para qualquer nível de carregamento. No entanto, os agrupamentos apresentaram piores desempenhos, com índices Silhouette abaixo de 0,7 em alguns dos casos analisados.

A aplicação da Transformada Hilbert aliado ao sensor MEMS obteve um desempenho não tão promissor quanto os demais sensores estudados para o diagnóstico de falhas ITSC e DT. Foi possível a detecção e identificação da fase elétrica afetada para 100% de carregamento, no entanto, não foi possível realizar a classificação da severidade das faltas, com índices Silhouette abaixo de 0,6. Além disso, não foi possível diferenciar o comportamento de falha com o comportamento de variação de carregamento. Já a aplicação da energia dos coeficientes da TWD obteve bom desempenho a plena carga. Foi realizada a detecção das falhas, a identificação das fases elétricas afetadas além da classificação da severidade da falha, com índices Silhouette acima de 0,8 para a maioria dos casos estudados. No entanto, quando há a variação de carregamento, o sistema é sensível a isto, fazendo com que o diagnóstico se torne

impreciso.

Para os sensores piezoelétricos, quando utiliza-se a técnica baseada na Transformada Hilbert, o método de monitoramento permite apenas a detecção, identificação da fase elétrica afetada e classificação de severidade para falta DT e 100% de carregamento. A medida em que se varia a carga mecânica aplicada ao eixo do MIT, a técnica apresenta resultados inconclusivos. Já para a falta ITSC, este método não teve eficácia alguma.

Quando utiliza-se a energia dos coeficientes da Transformada Wavelet discreta aliado aos sensores piezoelétricos, o resultado é bem diferente daquele visto na utilização da TH. Isso pois, esta técnica permite, com um excelente desempenho (índices Silhouette acima de 0,8 para a maioria dos casos), a detecção dos dois tipos de falta estudados, a identificação da fase elétrica afetada e a classificação da magnitude para qualquer nível de carga mecânica no eixo do MIT. Logo, uma vez que o carregamento é conhecido, o diagnóstico de falha é efetuado.

Dessa forma, a análise comparativa demonstra que os sensores de corrente e PZT tiveram sensibilidade para o diagnóstico de falhas elétricas em motores de indução, já os sensores MEMS não apresentaram resultados promissores para ambas as técnicas. Por fim, o resultado de maior destaque foi a sensibilidade do sensor PZT em conjunto com a TWD devido ao seu baixo custo em relação aos demais sensores, além de medir indiretamente a variável afetada.

REFERÊNCIAS

AL-MUSAWI, A. K.; ANAYI, F.; PACKIANATHER, M. Three-phase induction motor fault detection based on thermal image segmentation. **Infrared Physics & Technology**, Elsevier BV, v. 104, p. 103140, jan. 2020. Disponível em: <<https://doi.org/10.1016/j.infrared.2019.103140>>.

ALEXANDRE, F. A. **Monitoramento do fenômeno de queima no processo de retificação de aços por meio de sinais de vibração e análise de tempo e frequência**. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), Bauru, SP, 2018.

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>>.

ALMOUNAJJED, A.; SAHOO, A. K.; KUMAR, M. K. Diagnosis of stator fault severity in induction motor based on discrete wavelet analysis. **Measurement**, Elsevier BV, v. 182, p. 109780, set. 2021. Disponível em: <<https://doi.org/10.1016/j.measurement.2021.109780>>.

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

BESSAM, B. *et al.* Wavelet transform and neural network techniques for inter-turn short circuit diagnosis and location in induction motor. **International Journal of System Assurance Engineering and Management**, Springer Science and Business Media LLC, v. 8, n. S1, p. 478–488, dez. 2015. Disponível em: <<https://doi.org/10.1007/s13198-015-0400-4>>.

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

BOUZIDA, A. *et al.* Fault diagnosis in industrial induction machines through discrete wavelet transform. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 58, n. 9, p. 4385–4395, set. 2011. Disponível em: <<https://doi.org/10.1109/tie.2010.2095391>>.

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. *et al.* Partial discharge monitoring in power transformers using low-cost piezoelectric sensors. **Sensors**, MDPI AG, v. 16, n. 8, p. 1266, ago. 2016. Disponível em: <<https://doi.org/10.3390/s16081266>>.

CASTRO, B. A. d. **Uma contribuição aos sistemas de monitoramento de integridade estrutural baseados na impedância eletromecânica sob aplicações de baixa relação sinal-ruído**. Tese (Doutorado) — Universidade Estadual Paulista (UNESP), Bauru, SP, 2019.

CASTRO, B. A. de *et al.* A comparative analysis applied to the partial discharges identification in dry-type transformers by hall and acoustic emission sensors. **Sensors**, MDPI AG, v. 22, n. 5, p. 1716, fev. 2022. Disponível em: <<https://doi.org/10.3390/s22051716>>.

CHERIF, H. *et al.* Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor. **Energy**, Elsevier BV, v. 212, p. 118684, dez. 2020. Disponível em: <<https://doi.org/10.1016/j.energy.2020.118684>>.

CHUDASAMA, K.; SHAH, V.; SHAH, S. Induction motor relaying scheme for external faults detection and classification using subtractive clustering based sugeno fuzzy inference system. **Electric Power Components and Systems**, Informa UK Limited, v. 44, n. 10, p. 1149–1162, maio 2016. Disponível em: <<https://doi.org/10.1080/15325008.2016.1149255>>.

COSTA, C. F. da *et al.* Implementation of an induction motor mathematical model for stator winding fault analysis. In: **2018 13th IEEE International Conference on Industry Applications (INDUSCON)**. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/induscon.2018.8627194>>.

CRESCENTINI, M. *et al.* Bandwidth limits in hall effect-based current sensors. **ACTA IMEKO**, IMEKO International Measurement Confederation, v. 6, n. 4, p. 17, dez. 2017. Disponível em: <https://doi.org/10.21014/acta_imeko.v6i4.478>.

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>>.

DEVI, N. R.; SARMA, D. V. S. S. S.; RAO, P. V. R. Diagnosis and classification of stator winding insulation faults on a three-phase induction motor using wavelet and MNN. **IEEE Transactions on Dielectrics and Electrical Insulation**, Institute of Electrical and Electronics Engineers (IEEE), v. 23, n. 5, p. 2543–2555, out. 2016. Disponível em: <<https://doi.org/10.1109/tdei.2016.7736811>>.

ELBOUCHIKHI, E. *et al.* Motor current signal analysis based on a matched subspace detector. **IEEE Transactions on Instrumentation and Measurement**, Institute of Electrical and Electronics Engineers (IEEE), v. 66, n. 12, p. 3260–3270, dez. 2017. Disponível em: <<https://doi.org/10.1109/tim.2017.2749858>>.

FAIZ, J.; EBRAHIMPOUR, H. Precise derating of three-phase induction motors with unbalanced voltages. In: **Fourtieth IAS Annual Meeting. Conference Record of**

the **2005 Industry Applications Conference, 2005**. IEEE, 2005. Disponível em: <<https://doi.org/10.1109/ias.2005.1518352>>.

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>>.

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>. [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>. [Online; Acessado em 04/05/2020].

GARCIA, M. *et al.* Efficiency assessment of induction motors operating under different faulty conditions. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 66, n. 10, p. 8072–8081, out. 2019. Disponível em: <<https://doi.org/10.1109/tie.2018.2885719>>.

GLOWACZ, A. *et al.* Detection of deterioration of three-phase induction motor using vibration signals. **Measurement Science Review**, Walter de Gruyter GmbH, v. 19, n. 6, p. 241–249, dez. 2019.

GONZALEZ-CORDOBA, J. L. *et al.* Thermal-impact-based protection of induction motors under voltage unbalance conditions. **IEEE Transactions on Energy Conversion**, Institute of Electrical and Electronics Engineers (IEEE), v. 33, n. 4, p. 1748–1756, dez. 2018.

GUEDES, J. J. **Identificação de falhas em motores de indução trifásicos utilizando algoritmos de otimização e sistemas inteligentes**. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR, 2019.

GUPTA, T.; PANDA, S. P. Clustering validation of CLARA and k-means using silhouette & DUNN measures on iris dataset. In: **2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)**. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/comitcon.2019.8862199>>.

GUREVICH, A. Y. *et al.* Synthetic turbulence modeling for evaluation of ultrasonic cross-correlation flow measurement. **Flow Measurement and Instrumentation**, Elsevier BV, v. 60, p. 134–143, abr. 2018. Disponível em: <<https://doi.org/10.1016/j.flowmeasinst.2017.12.013>>.

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>>.

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>>.

JUNG, J.-H.; LEE, J.-J.; KWON, B.-H. Online diagnosis of induction motors using MCSA. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 53, n. 6, p. 1842–1852, dez. 2006. Disponível em: <<https://doi.org/10.1109/tie.2006.885131>>.

JUNIOR, P.; D'ADDONA, D. M.; AGUIAR, P. R. Dressing tool condition monitoring through impedance-based sensors: Part 1—PZT diaphragm transducer response and EMI sensing technique. **Sensors**, MDPI AG, v. 18, n. 12, p. 4455, dez. 2018. Disponível em: <<https://doi.org/10.3390/s18124455>>.

KEESMAN, K. J. **System Identification**. London, England: Springer, 2011. (Advanced Textbooks in Control and Signal Processing).

KHANJANI, M.; EZOJI, M. Electrical fault detection in three-phase induction motor using deep network-based features of thermograms. **Measurement**, Elsevier BV, v. 173, p. 108622, mar. 2021. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.108622>>.

KHECHEKHOUACHE, A. *et al.* Experimental diagnosis of inter-turns stator fault and unbalanced voltage supply in induction motor using mcsa and dwer. **Periodicals of Engineering and Natural Sciences**, v. 8, n. 3, p. 1202–1216, 2020.

KONAR, P.; CHATTOPADHYAY, P. Multi-class fault diagnosis of induction motor using hilbert and wavelet transform. **Applied Soft Computing**, Elsevier BV, v. 30, p. 341–352, maio 2015.

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>>.

LIANG, X.; ALI, M. Z.; ZHANG, H. Induction motors fault diagnosis using finite element method: A review. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 56, n. 2, p. 1205–1217, mar. 2020. Disponível em: <<https://doi.org/10.1109/tia.2019.2958908>>.

LIU, Y.; MA, T. Parasitic resistance-based high precision capacitive MEMS accelerometer phase shift and its usage for temperature compensation. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 18, n. 2, p. 629–634, jan. 2018.

LUCAS, G. B. **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 (Mestrado) — Universidade Estadual Paulista (UNESP), Bauru, SP, 2020.

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>>.

LUCAS, G. B. *et al.* A new acoustic emission-based approach for supply disturbances evaluation in three-phase induction motors. **IEEE Transactions on Instrumentation and Measurement**, Institute of Electrical and Electronics Engineers (IEEE), v. 70, p. 1–10, 2021. Disponível em: <<https://doi.org/10.1109/tim.2020.3047492>>.

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](https://doi.org/10.1109/jsen.2015.2476561)>.

MOOSAVI, S. *et al.* ANN based fault diagnosis of permanent magnet synchronous motor under stator winding shorted turn. **Electric Power Systems Research**, Elsevier BV, v. 125, p. 67–82, ago. 2015. Disponível em: <[https://doi.org/10.1016/j.epsr.2015-03.024](https://doi.org/10.1016/j.epsr.2015.03.024)>.

OJAGHI, M.; SABOURI, M.; FAIZ, J. Performance analysis of squirrel-cage induction motors under broken rotor bar and stator inter-turn fault conditions using analytical modeling. **IEEE Transactions on Magnetics**, Institute of Electrical and Electronics Engineers (IEEE), v. 54, n. 11, p. 1–5, nov. 2018. Disponível em: <<https://doi.org/10.1109/tmag.2018.2842240>>.

OPPENHEIM, A. **Signals, systems & inference**. Boston: Pearson, 2016. ISBN 978-0133943283.

OPPENHEIM ALAN E SCHAFER, R. W. **Processamento em tempo discreto de sinais**. São Paulo: Pearson Education do Brasil, 2012. ISBN 978-8581431024.

PEDOTTI, L. A. D. S.; ZAGO, R. M.; FRUETT, F. Fault diagnostics in rotary machines through spectral vibration analysis using low-cost MEMS devices. **IEEE Instrumentation & Measurement Magazine**, Institute of Electrical and Electronics Engineers (IEEE), v. 20, n. 6, p. 39–44, dez. 2017.

PUCHE-PANADERO, R. *et al.* Improved resolution of the MCSA method via hilbert transform, enabling the diagnosis of rotor asymmetries at very low slip. **IEEE Transactions on Energy Conversion**, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 1, p. 52–59, mar. 2009. Disponível em: <<https://doi.org/10.1109/tec.2008.2003207>>.

RAMSDEN, E. **Hall-effect sensors : theory and applications**. Amsterdam Boston: Elsevier/Newnes, 2006. ISBN 0-7506-7934-4.

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.

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>>.

SADEGHI, R.; SAMET, H.; GHANBARI, T. Detection of stator short-circuit faults in induction motors using the concept of instantaneous frequency. **IEEE Transactions on Industrial Informatics**, Institute of Electrical and Electronics Engineers (IEEE),

v. 15, n. 8, p. 4506–4515, ago. 2019. Disponível em: <<https://doi.org/10.1109/tii.2018.2881921>>.

SANTOS, V. dos *et al.* An application of wavelet analysis to assess discharge evolution by acoustic emission sensor. In: **Proceedings of 7th International Electronic Conference on Sensors and Applications**. [S.l.]: MDPI, 2020.

SAPENA-BANO, A. *et al.* The harmonic order tracking analysis method for the fault diagnosis in induction motors under time-varying conditions. **IEEE Transactions on Energy Conversion**, Institute of Electrical and Electronics Engineers (IEEE), v. 32, n. 1, p. 244–256, mar. 2017.

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.

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>>.

STIEF, A. *et al.* A PCA and two-stage bayesian sensor fusion approach for diagnosing electrical and mechanical faults in induction motors. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 66, n. 12, p. 9510–9520, dez. 2019. Disponível em: <<https://doi.org/10.1109/tie.2019.2891453>>.

TAO, X. *et al.* Bearings fault detection using wavelet transform and generalized gaussian density modeling. **Measurement**, Elsevier BV, v. 155, p. 107557, abr. 2020.

TÁVORA, C. G. *et al.* Hinkley criterion applied to detection and location of burn in grinding process. **The International Journal of Advanced Manufacturing Technology**, Springer Science and Business Media LLC, v. 113, n. 11-12, p. 3177–3188, fev. 2021. Disponível em: <<https://doi.org/10.1007/s00170-021-06828-7>>.

VIERA, M. A. A. *et al.* Low-cost piezoelectric transducer for ceramic grinding monitoring. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 19, n. 17, p. 7605–7612, set. 2019. Disponível em: <<https://doi.org/10.1109/jsen.2019.2917119>>.

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, 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>>.

YAMAN, O. An automated faults classification method based on binary pattern and neighborhood component analysis using induction motor. **Measurement**, Elsevier BV, v. 168, p. 108323, jan. 2021. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.108323>>.

YANG, M.-S.; SINAGA, K. P. A feature-reduction multi-view k-means clustering algorithm. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 114472–114486, 2019. Disponível em: <[https://doi.org/10.1109/access.2019-2934179](https://doi.org/10.1109/access.2019.2934179)>.

YETGIN, A. G. Effects of induction motor end ring faults on motor performance. experimental results. **Engineering Failure Analysis**, Elsevier BV, v. 96, p. 374–383, fev. 2019. Disponível em: <<https://doi.org/10.1016/j.engfailanal.2018.10.019>>.

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](https://doi.org/10.1109/access.2019.2924056)>.

ZIEGLER, S. *et al.* Current sensing techniques: A review. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 9, n. 4, p. 354–376, abr. 2009. Disponível em: <<https://doi.org/10.1109/jsen.2009.2013914>>.

APÊNDICE A

Lista de publicações realizadas durante o período de doutorado

- 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

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

SOUZA, W. S.; CASTRO, B. A.; LUCAS, G. B.; ROCHA, M. A.; ANDREOLI, A. L. Identificação de Falhas em Rolamentos Aplicados em Motores de Indução por meio de Sensores de Corrente. In. **2021 14th IEEE International Conference on Industry Applications (INDUSCON)**

LUCAS, G. B., ROCHA, M. A, CASTRO, B. A., ANDREOLI, A. L. Stator Winding Fault Phase Identification Using Piezoelectric Sensors in Three-Phase Induction Motors. In: **Engineering Proceedings**, MDPI AG, v. 2, n. 1, p. 32, fev. 2020. doi:10.3390/ecsa-7-08183

AKIYOSHI, D. F.; CASTRO, B. A.; LEÃO, J. V.; ROCHA, M. A.; REY, J. A.; RIEHL, R. R.; ANDREOLI, A. L. Evaluation of low cost piezoelectric sensors for the identification of partial discharges evolution. In **Multidisciplinary Digital Publishing Institute Proceeding**, MDPI, v. 4, n. 1, p. 36. doi: 10.3390/ecsa-5-05722

OLIVEIRA, J. R.; SOUZA, W. G.; ROCHA, M. A.; COSTA, C. F.; LEÃO, J. V.; ANDREOLI, A. L. Wind Turbine Emulator Using Induction Motor Driven by Frequency Inverter and

Hardware-in-the-loop Control. In **2018 13th IEEE International Conference on Industry Applications (INDUSCON)**. IEEE, 2018. doi: 10.1109/INDUSCON.2018.8627167
2018 13th IEEE International Conference on Industry Applications (INDUSCON) (pp. 381-385). Ieee.

LUCAS, G. B., CASTRO, B. A., ROCHA, M. A., ANDREOLI, A. L. 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

COSTA, C. F.; ROCHA, M. A.; SOUZA, W. G.; JUSTINO, P. T.; ANDREOLI, A. L. Implementation of an induction motor mathematical model for stator winding fault analysis. In **2018 13th IEEE International Conference on Industry Applications (INDUSCON)**. IEEE, 2018. doi: 10.1109/INDUSCON.2018.8627194
2018 13th IEEE International Conference on Industry Applications (INDUSCON) (pp. 381-385). Ieee.

LUCAS, G. B., CASTRO, B. A., ROCHA, M. A., ANDREOLI, A. L. 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