

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO ASSOCIADO EM ENGENHARIA ELÉTRICA**

**GUSTAVO HENRIQUE BAZAN**

**IDENTIFICAÇÃO INTELIGENTE DE FALHAS EM MÁQUINAS  
ELÉTRICAS UTILIZANDO INFORMAÇÃO MÚTUA**

**TESE**

**CORNÉLIO PROCÓPIO**

**2020**

**GUSTAVO HENRIQUE BAZAN**

**IDENTIFICAÇÃO INTELIGENTE DE FALHAS EM MÁQUINAS  
ELÉTRICAS UTILIZANDO INFORMAÇÃO MÚTUA**

**Intelligent Identification of Electrical Machine Faults  
Using Mutual Information**

Tese apresentada como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica, do Programa de Pós-Graduação Associado em Engenharia Elétrica, da Universidade Tecnológica Federal do Paraná (UTFPR).  
Orientador: Prof. Dr. Alessandro Goedtel.

**CORNÉLIO PROCÓPIO**

**2020**



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite o download e o compartilhamento da obra desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-la ou utilizá-la para fins comerciais.



GUSTAVO HENRIQUE BAZAN

**IDENTIFICAÇÃO INTELIGENTE DE FALHAS EM MÁQUINAS ELÉTRICAS UTILIZANDO INFORMAÇÃO MÚTUA**

Trabalho de pesquisa de doutorado apresentado como requisito para obtenção do título de Doutor Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Sistemas Eletrônicos.

Data de aprovação: 16 de Dezembro de 2020

Prof Alessandro Goedel, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Andre Luiz Andreoli, Doutorado - Universidade Estadual Paulista Júlio de Mesquita Filho (Unesp)

Prof Carlos Eduardo Pereira, Doutorado - Universidade Federal do Rio Grande do Sul (Ufrgs)

Prof Marcelo Suetake, Doutorado - Universidade Federal de São Carlos (Ufscar)

Prof Sebastiao Lauro Nau, Doutorado - Weg Equipamentos Elétricos S. A.

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 16/12/2020.

## **AGRADECIMENTOS**

À Deus por estar sempre ao meu lado.

À minha esposa Paula, por seu amor, por seu apoio, incentivo e, principalmente, pelo seu companheirismo. À minha família, pelo apoio, dedicação, esforço e a oportunidade dada para realização deste sonho.

Ao meu orientador Prof. Dr. Alessandro Goedtel, pelas valiosas contribuições e pelos inúmeros e inestimáveis conselhos sobre a condução deste trabalho.

Aos colegas do Laboratório de Sistemas Inteligentes (LSI) pelo convívio, pelo apoio, pela compreensão, pela amizade e auxílio no desenvolvimento deste projeto.

À Universidade Tecnológica Federal do Paraná, por disponibilizar a estrutura necessária para a realização deste trabalho de doutorado.

Ao Instituto Federal do Paraná, em especial aos colegas do eixo de Controle e Processos Industriais e à Direção do Campus que colaboraram de alguma forma com este importante passo na minha carreira profissional.

À Universidade de Valladolid, na figura do Prof. Dr. Óscar Duque-Perez e do Prof. Dr. Daniel Moríñigo-Sotelo, meus eternos agradecimentos pela oportunidade em realizar o doutorado sanduíche de curta duração. Embora o período de tempo tenha se encerrado antecipadamente, em razão da pandemia Covid-19, a experiência internacional colaborou com meu crescimento acadêmico e profissional.

Ao suporte financeiro da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná (Processos N° 338/2012) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Processos N° 474290/2008-5, 473576/2011-2, 552269/2011-5, 201902/2015-0).

"E ainda que tivesse o dom de profecia, e conhecesse todos os mistérios e toda a ciência, e ainda que tivesse toda a fé, de maneira tal que transportasse os montes, e não tivesse amor, nada seria."

(1 Coríntios 13:2)

## RESUMO

BAZAN, Gustavo Henrique. **Identificação Inteligente de Falhas em Máquinas Elétricas Utilizando Informação Mútua**. 2020. 155 f. Tese (Doutorado em Engenharia Elétrica) – Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2020.

Os motores de indução trifásicos são amplamente empregados em processos de produção industrial, devido ao seu baixo custo de aquisição e manutenção, bem como sua adaptação diante de diferentes condições de cargas mecânicas e robustez para uso em ambientes agressivos. O diagnóstico de uma falha incipiente quando esses motores estão em operação, mesmo antes que falhas significativas possam ocorrer, devem receber uma especial atenção da indústria. Assim, um diagnóstico adequado pode levar à redução das perdas nos processos, tempo fora de serviço e a quebra do equipamento, além de garantir operação consistente e confiável dos sistemas industriais. Neste contexto, este trabalho apresenta uma proposta sobre o uso de ferramentas de processamento de sinais e sistemas inteligentes no diagnóstico de falhas de rolamentos, rotor e estator em motores de indução, mesmo quando sujeitos a diversas condições de operação, como variações no torque de carga independente da alimentação da máquina. Este trabalho propõe a extração das características de falha baseadas em medidas de informação mútua atrasada entre os sinais das correntes de linha do estator,  $i_a$  e  $i_b$ , no domínio do tempo. Para avaliar a acurácia da classificação sob vários níveis de severidade de falhas, comparou-se o desempenho de três diferentes técnicas de reconhecimento de padrões: rede neural artificial do tipo perceptron multicamadas,  $k$ -vizinhos mais próximos e máquinas de vetores de suporte. Os resultados experimentais off-line e on-line apresentados neste trabalho validam a robustez e a eficácia da abordagem proposta.

**Palavras-chave:** Informação Mútua. Sistemas Inteligentes. Motor de Indução Trifásico. Identificação de Falhas.

## ABSTRACT

BAZAN, Gustavo Henrique. **Intelligent Identification of Electrical Machine Faults Using Mutual Information**. 2020. 155 p. Thesis (PhD in Electrical Engineering) – Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2020.

Three-phase induction motors are widely employed in industrial production processes due to their low acquisition cost and maintenance and adaptation in front of different conditions of mechanical loads and robustness for use in harsh environments. Diagnosing an incipient fault when these motors are in operation, even before significant faults may occur, should receive special attention from the industry. Thus, a proper diagnosis can reduce losses in the processes, time out of service, and the equipment breaks down and ensures consistent and reliable industrial systems operation. In this context, this paper presents an approach concerning the use of intelligent systems and signal processing tools in the classification of bearing, rotor, and stator fault diagnosis in induction motors, even when they are subject to various operating conditions such as variations in load torque independent of machine power supply. This work proposes the extraction of the fault characteristics based on delayed mutual information measurements between the stator line current signals,  $i_a$ , and  $i_b$ , in the time domain. To evaluate the classification accuracy under various fault severity levels, the performance of three different pattern recognition techniques were compared: artificial neural network type multilayer perceptron,  $k$ -nearest neighbors and support vector machine. The offline and online experimental results presented in this work validate the proposed approach's robustness and effectiveness.

**Keywords:** Mutual Information. Intelligent Systems. Three-Phase Induction Motors. Fault Identification.

## LISTA DE ALGORITMOS

Algoritmo 1 – Informação Mútua Deslocada . . . . .	125
--	-----



## LISTA DE FIGURAS

Figura 1 – Classificação dos principais tipos de falhas presentes nos MITs . . .	28
Figura 2 – Exemplo de uma rede neural artificial MLP com duas camadas es- condidas . . . . .	57
Figura 3 – Organização geral de desenvolvimento e implementação da metodo- logia proposta neste trabalho . . . . .	63
Figura 4 – Bancada Experimental de Ensaio Experimentais do LSI - UTFPR .	65
Figura 5 – Diagrama de Blocos do Sistema Proposto para a Identificação de Defeitos em Motores de Indução Trifásicos . . . . .	70
Figura 6 – Sinais de Correntes das Fases A e B - Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas . . . . .	71
Figura 7 – Curva da Informação Mútua - Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas . . . . .	71
Figura 8 – Exemplo da PDF marginal da corrente $i_a$ para o Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas	72
Figura 9 – Exemplo da PDF marginal da corrente $i_b$ para o Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas	73
Figura 10 – Exemplo da PDF conjunta das correntes, $i_a$ e $i_b$ , para o Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas . . . . .	73
Figura 11 – Variação no conjugado de carga - Motor 1 operando sem defeitos e com as tensões equilibradas . . . . .	74
Figura 12 – Variação no nível de desequilíbrio de tensão - Motor 1 operando sem defeitos e com carga nominal . . . . .	75
Figura 13 – Variação no nível de desequilíbrio de tensão - Motor 1 operando sem defeitos e com carga nominal . . . . .	76
Figura 14 – Variação no conjugado de carga - Motor 1 operando com defeitos de rolamentos e tensões equilibradas . . . . .	76
Figura 15 – Variação no nível de desequilíbrio de tensão - Motor 1 operando com defeitos de rolamentos e carga nominal . . . . .	77
Figura 16 – Variação no conjugado de carga - Motor 1 operando com uma barra quebrada de rotor e tensões equilibradas . . . . .	78
Figura 17 – Variação no nível de desequilíbrio de tensão - Motor 1 operando com uma barra quebrada de rotor e carga nominal . . . . .	78
Figura 18 – Variação no conjugado de carga - Motor 1 operando com 3% de curto-circuito de estator e tensões equilibradas . . . . .	79
Figura 19 – Variação no nível de desequilíbrio de tensão - Motor 1 operando com 3% de curto-circuito de estator e carga nominal . . . . .	79
Figura 20 – Variação no nível de frequência de alimentação - Motor 1 operando sem defeitos e com carga nominal . . . . .	80
Figura 21 – Metodologia embarcada em hardware DSP para o diagnóstico de curto-circuito entre espiras de estator de MITs. . . . .	123
Figura 22 – Kit de desenvolvimento LAUNCHXL-F28379D empregado no sistema proposto de diagnóstico de falhas de estator. . . . .	124

Figura 23 – Análise da Informação Mútua Calculada pelo Sistema Proposto Implementado em DSP Comparado com as Estimadas pelo Matlab® . 127

## LISTA DE TABELAS

Tabela 1 – Especificações dos Motores de Indução Trifásicos Utilizados no Trabalho . . . . .	66
Tabela 2 – Número de amostras por classe de defeitos . . . . .	67
Tabela 3 – Categorias do coeficiente Kappa conforme Landis e Koch (1977) . .	82
Tabela 4 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador MLP . . . . .	85
Tabela 5 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador $k$ -NN . . . . .	85
Tabela 6 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador SVM . . . . .	86
Tabela 7 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador MLP . . . . .	87
Tabela 8 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador $k$ -NN . . . . .	88
Tabela 9 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador SVM . . . . .	88
Tabela 10 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 operando diretamente pela rede elétrica - Defeitos de rolamentos . . . . .	89
Tabela 11 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 operando diretamente pela rede elétrica - Defeitos de rolamentos . . . . .	89
Tabela 12 – Classificação dos defeitos de rolamentos considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 1 . .	90
Tabela 13 – Classificação dos defeitos de rolamentos considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 2 . .	91
Tabela 14 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 alimentado por inversores de frequência - Defeitos de rolamentos . . . . .	92
Tabela 15 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 alimentado por inversores de frequência - Defeitos de rolamentos . . . . .	93
Tabela 16 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador MLP . . . . .	94
Tabela 17 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador $k$ -NN . . . . .	95

Tabela 18 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador SVM . . . . .	95
Tabela 19 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador MLP . . . . .	96
Tabela 20 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador <i>k</i> -NN . . . . .	96
Tabela 21 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador SVM . . . . .	97
Tabela 22 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 operando diretamente pela rede elétrica - Barras quebradas de rotor . . . . .	98
Tabela 23 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 operando diretamente pela rede elétrica - Barras quebradas de rotor . . . . .	99
Tabela 24 – Classificação de barras quebradas de rotor considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 1	100
Tabela 25 – Classificação de barras quebradas de rotor considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 2	100
Tabela 26 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 alimentado por inversores de frequência - Barras quebradas de rotor . . . . .	102
Tabela 27 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 alimentado por inversores de frequência - Barras quebradas de rotor . . . . .	102
Tabela 28 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador MLP . . . . .	104
Tabela 29 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador <i>k</i> -NN . . . . .	104
Tabela 30 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador SVM . . . . .	104
Tabela 31 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador MLP . . . . .	106
Tabela 32 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador <i>k</i> -NN . . . . .	106
Tabela 33 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador SVM . . . . .	106

Tabela 34 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 operando diretamente pela rede elétrica - Curto-circuito de estator . . . . .	107
Tabela 35 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 operando diretamente pela rede elétrica - Curto-circuito de estator . . . . .	108
Tabela 36 – Classificação de curto-circuito de estator considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 1 . . . . .	109
Tabela 37 – Classificação de curto-circuito de estator considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 2 . . . . .	109
Tabela 38 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 alimentado por inversores de frequência - Curto-circuito de estator . . . . .	111
Tabela 39 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 alimentado por inversores de frequência - Curto-circuito de estator . . . . .	111
Tabela 40 – Quadro Resumo dos Resultados Experimentais . . . . .	112
Tabela 41 – Resumo de alguns trabalhos relacionados ao diagnóstico de falhas de rolamentos . . . . .	114
Tabela 42 – Resumo de alguns trabalhos relacionados ao diagnóstico de barras quebradas de rotor . . . . .	115
Tabela 43 – Resumo de alguns trabalhos relacionados ao diagnóstico de falhas de estator . . . . .	117
Tabela 44 – Quantidade Necessária de Pontos das Correntes para a Estimção das PDFs em Comparação entre o DSP e o Matlab® . . . . .	126
Tabela 45 – Desempenho do Sistema Proposto Implementado em DSP Comparado ao Matlab® . . . . .	126
Tabela 46 – Resultados da viabilidade computacional de diversas topologias de RNA - Motor 1 . . . . .	128
Tabela 47 – Resultados da viabilidade computacional de diversas topologias de RNA - Motor 2 . . . . .	129
Tabela 48 – Validação da metodologia proposta em hardware dedicado para o diagnóstico de curto-circuito entre as espiras de estator em MITs - Motores 1 e 2 . . . . .	130

## LISTA DE SIGLAS

AD	Árvores de Decisão
AE	<i>Auto-Encoder</i>
LBFO	<i>Bacterial Foraging Optimization with Levy Flight</i>
CEEMD	<i>Complete Ensemble Empirical Mode Decomposition</i>
CNNF	<i>Convolutional Neural Networks</i>
CCB	<i>Counter-Current Braking</i>
DCNN	<i>Deep Convolutional Neural Network</i>
DL	<i>Deep Learning</i>
DMI	<i>Delayed Mutual Information</i>
DE	<i>Differential Evolution</i>
DSP	<i>Digital Signal Processor</i>
DFT	<i>Discrete Fourier Transform</i>
EMD	<i>Empirical Mode Decomposition</i>
H	Entropia
ESPRIT	<i>Estimation of Signal Parameters via Rotational Invariance Techniques</i>
FIBL	<i>Feature Incremental Broad Learning</i>
GCC	Gerador de Corrente Contínua
IT	<i>Information Theory</i>
IRP	<i>Insulation Resistance Profile</i>
IMF	<i>Intrinsic Mode Functions</i>
k-NN	<i>k-Nearest Neighbors</i>
LSI	Laboratório de Sistemas Inteligentes
LDA	<i>Linear Discriminant Analysis</i>
MEMS	<i>Microelectromechanical Systems</i>
MCSA	<i>Motor Current Signal Analysis</i>
MIT	Motor de Indução Trifásico
MLP	<i>Multilayer Perceptron</i>
MCCM	<i>Multiple Coupled Circuit Modeling</i>
MUSIC	<i>Multiple Signal Classification</i>
MRSFN	<i>Multi-Resolution e Multi-Sensor Fusion Network</i>
MRVM	<i>Multivariate Relevance Vector Machine</i>
MI	<i>Mutual Information</i>
OCD	<i>Orthogonal Component Decomposition</i>
OMP	<i>Orthogonal Matching Pursuit</i>

PSO	<i>Particle Swarm Optimization</i>
POP	<i>Pendulous Oscillation Phenomenons</i>
PCA	<i>Principal Component Analysis</i>
PDF	<i>Probability Density Function</i>
QSA	<i>Quaternion Signal Analysis</i>
RNA	Redes Neurais Artificiais
SOM	<i>Self-Organized Maps</i>
SMO	<i>Sequential Minimal Optimization</i>
STFT	<i>Short Time Fourier Transform</i>
SVD	<i>Singular Value Decomposition</i>
SI	Sistemas Inteligentes
SM	Sistemas Multiagentes
SAFC	<i>Stacked Auto-Encoders Sparse Filter Rotating Component Comprehensive Diagnosis</i>
SVM	<i>Support Vector Machines</i>
TR-LDA	<i>Trace Ratio-Linear Discriminant Analysis</i>
TF	Transformada de Fourier
TH	Transformada Hilbert
TW	Transformada Wavelet
TWC	Transformada Wavelet Contínua
TWD	Transformada Wavelet Discreta
WEKA	<i>Waikato Environment for Knowledge Analysis</i>
ZSC	<i>Zero-Sequence Current</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>17</b>
1.1	JUSTIFICATIVA	23
1.2	OBJETIVOS	24
1.3	CONTRIBUIÇÕES	26
1.4	ORGANIZAÇÃO DO TRABALHO	27
<b>2</b>	<b>FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS</b>	<b>28</b>
2.1	FALHAS DE ROLAMENTOS EM MITS	29
2.2	FALHAS DE BARRAS QUEBRADAS DE ROTOR EM MITS	36
2.3	FALHAS DE ESTATOR EM MITS	44
2.4	CONCLUSÃO DO CAPÍTULO	51
<b>3</b>	<b>ESTRATÉGIAS PARA O MONITORAMENTO E DIAGNÓSTICO DE FALHAS</b>	<b>52</b>
3.1	INTRODUÇÃO	52
3.2	TEORIA DA INFORMAÇÃO EMPREGADA NA EXTRAÇÃO DE CARACTERÍSTICAS DOS SINAIS DE CORRENTES DOS MITS	53
3.3	REDES NEURAIS ARTIFICIAIS APLICADAS NA CLASSIFICAÇÃO DE PADRÕES	57
3.4	K-VIZINHOS MAIS PRÓXIMOS APLICADOS NA CLASSIFICAÇÃO DE PADRÕES	59
3.5	MÁQUINA DE VETORES DE SUPORTE APLICADA NA CLASSIFICAÇÃO DE PADRÕES	60
3.6	CONCLUSÃO DO CAPÍTULO	62
<b>4</b>	<b>METODOLOGIA</b>	<b>63</b>
4.1	ASPECTOS GERAIS RELACIONADOS AO CONJUNTO DE DADOS	64
4.2	EXTRAÇÃO DE CARACTERÍSTICAS USANDO MEDIDAS DA INFORMAÇÃO MÚTUA	69
4.3	IDENTIFICAÇÃO DE FALHAS USANDO SISTEMAS INTELIGENTES	81
4.4	CONCLUSÃO DO CAPÍTULO	83
<b>5</b>	<b>RESULTADOS EXPERIMENTAIS</b>	<b>84</b>
5.1	RESULTADOS EXPERIMENTAIS - DEFEITOS DE ROLAMENTOS	84
5.1.1	Defeitos de Rolamentos - Motores Conectados Diretamente à Rede	85
5.1.2	Defeitos de Rolamentos - Motores Alimentados por meio de Inversores de Frequência	90
5.2	RESULTADOS EXPERIMENTAIS - BARRAS QUEBRADAS DE ROTOR	93
5.2.1	Barras Quebradas de Rotor - Motores Conectados Diretamente à Rede	94
5.2.2	Barras Quebradas de Rotor - Motores Alimentados por meio de Inversores de Frequência	99



5.3	RESULTADOS EXPERIMENTAIS - CURTO-CIRCUITO DE ESTATOR . . . . .	103
5.3.1	Curto-circuito de Estator - Motores Conectados Diretamente à Rede	104
5.3.2	Curto-circuito de Estator - Motores Alimentados por meio de Inversores de Frequência . . . . .	108
5.4	QUADRO RESUMO DOS RESULTADOS EXPERIMENTAIS . . . . .	112
5.5	COMPARATIVO COM OUTROS TRABALHOS ENCONTRADOS NA LITERATURA . . . . .	112
5.6	CONCLUSÃO DO CAPÍTULO . . . . .	117
<b>6</b>	<b>SISTEMA EMBARCADO PARA O DIAGNÓSTICO DE CURTO-CIRCUITO DE ESTATOR EM MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO TEORIA DA INFORMAÇÃO E REDES NEURAIIS ARTIFICIAIS . . . . .</b>	<b>119</b>
6.1	IMPLEMENTAÇÃO DA METODOLOGIA EMBARCADA EM HARDWARE . . . . .	121
6.1.1	Resultados Experimentais Embarcados Off-line . . . . .	125
6.1.2	Resultados Experimentais Embarcados On-line . . . . .	129
6.2	CONCLUSÃO DO CAPÍTULO . . . . .	131
<b>7</b>	<b>CONCLUSÕES . . . . .</b>	<b>132</b>
7.1	TRABALHOS FUTUROS . . . . .	133
7.2	PRODUÇÕES CIENTÍFICAS . . . . .	134
7.2.1	Artigos Apresentados em Conferências Nacionais e/ou Internacionais	134
7.2.2	Artigos Publicados em Periódicos . . . . .	135
7.2.3	Artigos Aceitos para Publicação em Periódicos . . . . .	136
7.2.4	Artigos Submetidos a Periódicos . . . . .	136
7.2.5	Artigo em Elaboração para Periódico . . . . .	136
7.2.6	Certificados de Registro de Programa de Computador . . . . .	136
	<b>REFERÊNCIAS . . . . .</b>	<b>138</b>

## 1 INTRODUÇÃO

Os motores de indução trifásicos (MIT) são as máquinas elétricas mais comuns empregadas em aplicações industriais, devido ao baixo custo de aquisição e manutenção. Ainda, tais máquinas possuem bom desempenho frente a diversas condições de cargas mecânicas, além de serem robustas até mesmo em ambientes desfavoráveis de operação (FROSINI *et al.*, 2015; TRACHI *et al.*, 2016; BOUDINAR *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; GARCIA-CALVA *et al.*, 2017; MORALES-PEREZ *et al.*, 2018; GUVEN; ATIS, 2018; LIBONI *et al.*, 2019; GANGSAR; TIWARI, 2020). Mais recentemente, com o advento da Eletrônica de Potência e com o emprego de inversores de frequência que permitiram o controle eficiente por meio de diferentes estratégias, essas máquinas tornaram-se ainda mais presentes nas mais diversas aplicações industriais (BELLINI *et al.*, 2008; GODOY *et al.*, 2015; GODOY *et al.*, 2016).

Contudo, essas máquinas estão suscetíveis a vários tipos de falhas, que podem ser generalizadas em falhas elétricas e mecânicas (TRACHI *et al.*, 2016; GARCIA-CALVA *et al.*, 2017; DEGHAN *et al.*, 2018; GANGSAR; TIWARI, 2020). Dentre as falhas elétricas mais frequentes, podem ser citadas as de circuito aberto ou curto-circuito nos enrolamentos do estator do motor, especialmente pelos problemas de isolamento dos enrolamentos; conexão incorreta dos enrolamentos; alta resistência de contato ao condutor; e condutor terra conectado de forma incorreta ou operando de forma instável (TRAN *et al.*, 2013; EFTEKHARI *et al.*, 2014; SURYA *et al.*, 2017; IRHOUMAH *et al.*, 2018; BERZOY *et al.*, 2018; DEGHAN *et al.*, 2018; GANGSAR; TIWARI, 2020). Ainda, no contexto das falhas elétricas, tem-se as barras de rotor quebradas e anéis rompidos. Já em relação as falhas mecânicas, podem ser incluídas as de desalinhamento do eixo, afrouxamento dos parafusos, falhas de rolamentos, falhas no redutor de velocidade e irregularidades do entreferro (BELLINI *et al.*, 2008; TRACHI *et al.*, 2016; MIRZAEVA *et al.*, 2017; GANGSAR; TIWARI, 2020).

Diversos pesquisadores, em recentes trabalhos, destacam que as falhas de rolamentos são as maiores responsáveis por paradas inesperadas nos processos industriais, representando entre 40% e 70% das causas associadas a estas paradas (THORSEN; DALVA, 1995; BONNETT; YUNG, 2008; BELLINI *et al.*, 2008; FROSINI *et al.*, 2015; LEITE *et al.*, 2015; BOUDINAR *et al.*, 2016; SINGH; KUMAR, 2017;

GANGSAR; TIWARI, 2020). Geralmente, os defeitos nos rolamentos estão associados a contaminação, corrosão, lubrificação inadequada e problemas de instalação, como desalinhamento e sobrecarga (LEITE *et al.*, 2015; GANGSAR; TIWARI, 2020).

Estima-se que entre 20% e 40% das falhas são ocasionadas no enrolamento do estator das máquinas elétricas (THORSEN; DALVA, 1995; BONNETT; YUNG, 2008; BELLINI *et al.*, 2008; BARZEGARAN *et al.*, 2013; ZAREI *et al.*, 2014; DRIF; CARDOSO, 2014; SURYA *et al.*, 2017; IRHOUMAH *et al.*, 2018; BERZOY *et al.*, 2018; DEGHAN *et al.*, 2018; GANGSAR; TIWARI, 2020). Normalmente, uma avaria no enrolamento do estator é provocada pela ruptura do isolamento de algumas espiras, a qual evolui rapidamente, podendo comprometer o adequado funcionamento do MIT (BELLINI *et al.*, 2008; GANDHI *et al.*, 2011; DRIF; CARDOSO, 2014; GODOY *et al.*, 2015; BERZOY *et al.*, 2018; ELBOUCHIKHI *et al.*, 2019; GANGSAR; TIWARI, 2020).

Já os defeitos de barras quebradas de rotor correspondem entre 5% e 10% das ocorrências de falhas dos MITs (THORSEN; DALVA, 1995; BONNETT; YUNG, 2008; BELLINI *et al.*, 2008; GYFTAKIS *et al.*, 2016; SAMANTA *et al.*, 2018; MALEK *et al.*, 2017; DIAS; PEREIRA, 2018; TRUJILLO-GUAJARDO *et al.*, 2018; LIBONI *et al.*, 2019; GANGSAR; TIWARI, 2020). A forma de fabricação, as condições de trabalho as quais estão sujeitas, bem como as fissuras mecânicas, estão relacionados a presença desse tipo de defeito nessas máquinas (HOU *et al.*, 2016; GYFTAKIS *et al.*, 2016; GANGSAR; TIWARI, 2020).

Essas falhas podem causar a parada inesperada do processo produtivo industrial, a degradação dos componentes presentes nas máquinas, as vibrações e o alto custo de manutenção. Assim, o desenvolvimento de uma estratégia capaz de realizar a detecção rápida dos defeitos relativos a essas máquinas tem sido alvo de grande interesse da comunidade acadêmica, pois o correto acompanhamento das condições pode trazer benefícios importantes aos processos industriais como a prevenção de paradas desnecessárias e dispendiosas. Neste caso, os operadores têm tempo suficiente para o desligamento controlado do processo, com redução dos custos de manutenção e operação mais segura das máquinas. Ainda neste contexto, pode-se identificar as reais necessidades de manutenção, possibilitando programar a manutenção preventiva futura (TRACHI *et al.*, 2016; GARCÍA-ESCUADERO *et al.*, 2017; SINGH; KUMAR, 2017; DELGADO-ARREDONDO *et al.*, 2017; APPANA *et al.*, 2018; DENG *et al.*, 2019).

Um considerável número de pesquisadores está interessado no monitoramento e identificação das falhas presentes nos motores de indução trifásicos (FROSINI *et al.*, 2015; TRACHI *et al.*, 2016; BOUDINAR *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; LEITE *et al.*, 2015; ELBOUCHIKHI *et al.*, 2016; PRUDHOM *et al.*, 2017; DELGADO-ARREDONDO *et al.*, 2017; SURYA *et al.*, 2017; ABDALLAH; BENATMAN, 2017; GUEDES *et al.*, 2016; BESSAM *et al.*, 2016; GYFTAKIS *et al.*, 2016; HOU *et al.*, 2016; GODOY *et al.*, 2016; MOUSSA *et al.*, 2017; GARCÍA-ESCUADERO *et al.*, 2017; GARCIA-CALVA *et al.*, 2017; MARTINEZ *et al.*, 2017; SOUSA *et al.*, 2017; SAMANTA *et al.*, 2018; ROMERO-TRONCOSO *et al.*, 2016; MALEK *et al.*, 2017; PALÁCIOS *et al.*, 2016; NAYANA; GEETHANJALI, 2017; JERKAN *et al.*, 2017; IRHOUMAH *et al.*, 2018; BERZOY *et al.*, 2018; DEGHAN *et al.*, 2018; DIAS; PEREIRA, 2018; TRUJILLO-GUAJARDO *et al.*, 2018; APPANA *et al.*, 2018; ALI *et al.*, 2019; CONTRERAS-HERNANDEZ *et al.*, 2019; DENG *et al.*, 2019; JIANG *et al.*, 2019; LIBONI *et al.*, 2019; STIEF *et al.*, 2019; WANG *et al.*, 2019b; ALI *et al.*, 2020; GANGSAR; TIWARI, 2020; NAYANA; GEETHANJALI, 2020; SABOURI *et al.*, 2020; SHAO *et al.*, 2020; VINAYAK *et al.*, 2020; XUE *et al.*, 2020; ZHAO; WANG, 2019).

Os métodos apresentados para o diagnóstico de falhas em máquinas de indução trifásicos distinguem-se um dos outros por meio da variável utilizada no monitoramento, como por exemplo, os sinais de vibração (ESFAHANI *et al.*, 2014; MARTINEZ *et al.*, 2017; DELGADO-ARREDONDO *et al.*, 2017; MORALES-PEREZ *et al.*, 2018; ZHAO *et al.*, 2019), temperatura (PICAZO-RÓDENAS *et al.*, 2015), emissões acústicas (ESFAHANI *et al.*, 2014; DELGADO-ARREDONDO *et al.*, 2017), corrente (ESFAHANI *et al.*, 2014; TRACHI *et al.*, 2016; GYFTAKIS *et al.*, 2016; HOU *et al.*, 2016; GODOY *et al.*, 2016; MOUSSA *et al.*, 2017; GARCÍA-ESCUADERO *et al.*, 2017; GARCIA-CALVA *et al.*, 2017; JERKAN *et al.*, 2017; SAMANTA *et al.*, 2018; BESSAM *et al.*, 2016; ROMERO-TRONCOSO *et al.*, 2016; MALEK *et al.*, 2017; PALÁCIOS *et al.*, 2016; TRUJILLO-GUAJARDO *et al.*, 2018; LIBONI *et al.*, 2019; ZHAO; WANG, 2019), tensão (HOU *et al.*, 2016; GARCIA-CALVA *et al.*, 2017; LIBONI *et al.*, 2019), potências ativa e reativa (DRIF *et al.*, 2017; DRIF; CARDOSO, 2014), sinais magnéticos (FROSINI *et al.*, 2015; SOUSA *et al.*, 2017; DIAS; PEREIRA, 2018; PANAGIOTOU *et al.*, 2019), dentre outras variáveis.

No entanto, algumas dessas metodologias são invasivas, isto é, deve-se aces-

sar o interior das máquinas para a realização das medições, que faz com que o monitoramento seja prejudicial ao processo produtivo industrial, tendo em vista que haverá a necessidade de parada para a realização da medição. Ainda, em alguns casos, há a exigência de sensores e ferramentas de aquisição de sinais específicas, tornando o sistema caro e assim, dificultando a implementação do mesmo. A medida de corrente do estator apresenta muitas vantagens, tais como a possibilidade da medição de forma não-invasiva, acessibilidade para a medição, flexibilidade na implementação, capacidade de identificar tanto falhas mecânicas quanto elétricas e o não requerimento de sensores adicionais (TRACHI *et al.*, 2016; LEITE *et al.*, 2015; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; PICAZO-RÓDENAS *et al.*, 2015; TRUJILLO-GUAJARDO *et al.*, 2018; LIBONI *et al.*, 2019; ZHAO; WANG, 2019).

Além da atenção especial com o tipo de variável, a escolha da ferramenta que irá processar os sinais é de extrema importância nos sistemas de diagnóstico de falhas em motores de indução, pois possibilita a extração e seleção das características mais relevantes. O processamento desses sinais pode ser realizado utilizando tanto o domínio da frequência quanto o domínio do tempo. No domínio da frequência, destacam-se as ferramentas tradicionais que trabalham com a decomposição espectral dos sinais, tais como a Transformada de *Fourier* (TF) (GYFTAKIS *et al.*, 2016; HOU *et al.*, 2016; MOUSSA *et al.*, 2017; MARTINEZ *et al.*, 2017; SOUSA *et al.*, 2017; JERKAN *et al.*, 2017; PANAGIOTOU *et al.*, 2019; SOHAIB; KIM, 2020; DING *et al.*, 2020; KUMAR *et al.*, 2021), a Transformada *Wavelet* (TW) (GARCÍA-ESCUADERO *et al.*, 2017; TRACHI *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; ABID *et al.*, 2018; ZHANG *et al.*, 2018; ALI *et al.*, 2019; ALI *et al.*, 2020) e a Transformada *Hilbert* (TH) (BESSAM *et al.*, 2016; MALEK *et al.*, 2017; XUE *et al.*, 2020).

A TF é a técnica mais usual na análise de sinais estacionários, entretanto, possui algumas desvantagens como resolução de frequência limitada, vazamento espectral e baixa tolerância ao ruído (DELGADO-ARREDONDO *et al.*, 2017). Assim, com o intuito de solucionar algumas dessas desvantagens das metodologias tradicionais, recentemente alguns pesquisadores estão utilizando ferramentas alternativas como por exemplo o algoritmo de classificação de sinais múltiplos, do inglês *Multiple Signal Classification* (MUSIC) (GARCIA-CALVA *et al.*, 2017; NAHA *et al.*, 2016; GARCIA-PEREZ *et al.*, 2011; ROMERO-TRONCOSO *et al.*, 2016; BOUDINAR *et al.*, 2016),

as técnicas de invariância rotacional, do inglês *Estimation of Signal Parameters via Rotational Invariance Techniques* (ESPRIT) (KIM *et al.*, 2013; XU *et al.*, 2012), a análise das componentes principais, do inglês *Principal Component Analysis* (PCA) (CHEN; LIU, 2018; STIEF *et al.*, 2019; ZHAO *et al.*, 2019; XUE *et al.*, 2020; ZHAO; WANG, 2019). O algoritmo MUSIC tem como característica exigir uma menor quantidade de amostras de dados para alcançar a resolução de frequência apropriada, em comparação com os métodos tradicionais. No entanto, ainda é considerado uma ferramenta muito complexa para a implementação em tempo real. Já o algoritmo ESPRIT tem como particularidade determinar diretamente as componentes de corrente de falhas em uma faixa de frequência pré-definida, porém, também tem um alto custo computacional (JERKAN *et al.*, 2017).

As técnicas que trabalham no domínio do tempo, geralmente, apresentam vantagens de cálculo e implementação simples (LIU; BAZZI, 2017). Tendo isso em vista, alguns pesquisadores estão desenvolvendo abordagens alternativas às que utilizam o domínio da frequência, buscando reduzir os custos dos sistemas de identificação de falhas, como pode ser encontrado nos trabalhos de Duan e Živanović (2015), Godoy *et al.* (2015), Palácios *et al.* (2015), Godoy *et al.* (2016), Palácios *et al.* (2016), Nayana e Geethanjali (2017) e Nayana e Geethanjali (2020).

Além dos tipos de sinais, do meio que os mesmos são coletados e do tipo de domínio onde é realizada a análise, as técnicas para redução da dimensão dos dados são consideradas extremamente importantes no campo da aprendizagem de máquinas, na mineração de dados e no reconhecimento de padrões. O pré-processamento de dados de alta dimensão por uma ferramenta adequada pode levar a um custo computacional menor em processamentos posteriores e melhor interpretação das características, resultando assim na melhoria no desempenho (JUKIC; FILIPOVIC, 2013; ZHAO *et al.*, 2014).

Os métodos de extração de características buscam extrair os padrões do conjunto de dados por meio de transformações ou combinações desse mesmo conjunto (ESTÉVEZ *et al.*, 2009). Por outro lado, a seleção das características compreende a seleção de um subconjunto de características que contenha as informações relevantes do conjunto de dados original, possibilitando assim diferenciar uma classe das outras, e conseqüentemente, aumentar a qualidade dos dados e o desempenho dos

classificadores (ESTÉVEZ *et al.*, 2009; HERMAN *et al.*, 2013).

Os fundamentos da Teoria da Informação, do inglês *Information Theory* (IT), têm se tornado cada vez mais útil na área de diagnóstico de falhas e reconhecimento de padrões, pois oferece um conjunto de ferramentas que mensuram estaticamente a associação entre as variáveis envolvidas no problema (FAIZ *et al.*, 2010; ROMERO-TRONCOSO *et al.*, 2011; LI *et al.*, 2011; LEIVA-MURILLO; ARTÉS-RODRÍGUEZ, 2012; KUMAR *et al.*, 2021). De acordo com Melia *et al.* (2015), a Informação Mútua, do termo inglês *Mutual Information* (MI), é uma medida de associação entre os sinais, além de ser apta na identificação das dependências lineares e não-lineares entre as séries temporais. Visto que o MIT é um sistema não-linear e variante no tempo complexo, neste trabalho utiliza-se a MI como medida de associação entre as correntes, objetivando extrair informações significativas que permitam o eficiente diagnóstico de múltiplas falhas (rolamentos, barras quebradas de rotor e curto-circuito do estator) em motores de indução trifásicos.

Além das ferramentas de processamento de sinais que auxiliam na extração das informações mais relevantes dos dados, os Sistemas Inteligentes (SI) têm demonstrado sua importância na detecção de falhas em MITs, pois possibilitam a classificação e identificação dos padrões de defeitos presentes nas máquinas sem a necessidade de modelos matemáticos complexos. Estes classificadores são capazes de apontar o princípio dos defeitos precocemente e assim auxiliam na operação mais segura dos motores, inviabilizando a parada desnecessária do processo produtivo e reduzindo os prejuízos com o tempo de interrupção.

As Árvores de Decisão (AD), as Redes Neurais Artificiais (RNA), as Máquinas de Vetores de Suporte, do termo inglês *Support Vector Machines* (SVM), o algoritmo dos *k*-vizinhos mais próximos, do termo inglês *k-Nearest Neighbors* (*k*-NN), a Lógica Fuzzy e os Sistemas Híbridos tem apresentando promissores desempenhos nos sistemas de monitoramento de falhas (PALÁCIOS *et al.*, 2016; SAUCEDO-DORANTES *et al.*, 2017; NAYANA; GEETHANJALI, 2017; ABID *et al.*, 2018; ALI *et al.*, 2019; ABID *et al.*, 2020; ALI *et al.*, 2020; GANGSAR; TIWARI, 2020; SOHAIB; KIM, 2020; XUE *et al.*, 2020; WANG *et al.*, 2020).

Assim, a contribuição deste trabalho consiste em apresentar uma metodologia alternativa para o diagnóstico de múltiplas falhas (rolamentos, rotor e estator) em

motores de indução trifásicos independentemente da alimentação das máquinas, seja diretamente da rede de alimentação ou por meio de inversores de frequência. Essa metodologia é baseada em medidas da informação mútua entre os sinais de correntes obtidos no domínio do tempo, para classificar a severidade de desgaste de rolamentos, barras quebradas de rotor e curto-circuito entre as espiras de estator. Ainda, no trabalho, é realizada uma avaliação de três técnicas de aprendizado supervisionado de máquina, a *Perceptron* de Múltiplas Camadas, do termo inglês *Multilayer Perceptron* (MLP), o algoritmo *k*-NN e o SVM, com o intuito de verificar o classificador de padrões mais adequado com a estratégia de extração de características adotada. A fim de avaliar a metodologia proposta, foram coletados dados experimentais de motores de potências distintas, operando em regime permanente, a partir de fontes de alimentação senoidal diretamente da rede elétrica e também por meio de inversores de frequência, incluindo ensaios com variações no desequilíbrio de tensão, na frequência de alimentação e no conjugado de carga.

## 1.1 JUSTIFICATIVA

Segundo o Balanço Energético Nacional apresentado no ano de 2020, verificou-se que em 2019, aproximadamente, 30,4% de toda energia elétrica produzida no Brasil é consumida pelo setor industrial brasileiro, onde os MITs são os maiores responsáveis por esse consumo (EPE, 2020). Ainda, é importante destacar que no mundo 80% da conversão de energia nos setores industriais e comerciais são realizados por esses equipamentos, evidenciando a sua importância nessas aplicações (GARCÍA-ESCUADERO *et al.*, 2017). A sua grande utilização deve-se às suas características como ter uma estrutura mais simples do que as demais máquinas, por apresentar uma satisfatória adaptação frente a diversas condições de cargas mecânicas e robustez para a utilização em ambientes hostis (FROSINI *et al.*, 2015; TRACHI *et al.*, 2016; BOUDINAR *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; GARCIA-CALVA *et al.*, 2017; MORALES-PEREZ *et al.*, 2018; GUVEN; ATIS, 2018; LIBONI *et al.*, 2019). No entanto, esses motores estão sujeitos a ocorrência de falhas inesperadas que podem alterar o seu adequado funcionamento (TRACHI *et al.*, 2016; GARCIA-CALVA *et al.*, 2017; DEHGHAN *et al.*, 2018).

Diante desse fato, muitos estudos estão sendo desenvolvidos com o intuito de



detectar os defeitos em estágios incipientes, que pode colaborar com os programas de manutenção desses equipamentos. O adequado monitoramento das condições dessas máquinas traz vantagens importantes aos processos produtivos industriais, como a diminuição de paradas indesejadas, redução nos custos com manutenção e fornecimento de uma operação mais confiável dos motores (GARCÍA-ESCUADERO *et al.*, 2017; APPANA *et al.*, 2018; DENG *et al.*, 2019).

Uma forma de minimizar os problemas relacionados a essas máquinas elétricas consiste na utilização de sistemas eficazes que incorporam técnicas adequadas de processamento de sinais para a extração e seleção de características específicas das assinaturas de falhas, associadas a metodologias de classificadores de padrões, que possibilitam a classificação da falha existente no motor em operação. Assim, a busca por metodologias capazes de identificar os defeitos em estágio precoce é de grande interesse para a comunidade acadêmica e vem despertando a atenção de diversos pesquisadores nos últimos anos (BELLINI *et al.*, 2008; AYDIN *et al.*, 2012; HENAO *et al.*, 2014; FROSINI *et al.*, 2015; TRACHI *et al.*, 2016; BOUDINAR *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; LEITE *et al.*, 2015; ELBOUCHIKHI *et al.*, 2016; PRUDHOM *et al.*, 2017; DELGADO-ARREDONDO *et al.*, 2017; SURYA *et al.*, 2017; ABDALLAH; BENATMAN, 2017; GUEDES *et al.*, 2016; BESSAM *et al.*, 2016; GYFTAKIS *et al.*, 2016; HOU *et al.*, 2016; GODOY *et al.*, 2016; MOUSSA *et al.*, 2017; GARCÍA-ESCUADERO *et al.*, 2017; GARCIA-CALVA *et al.*, 2017; MARTINEZ *et al.*, 2017; SOUSA *et al.*, 2017; SAMANTA *et al.*, 2018; ROMERO-TRONCOSO *et al.*, 2016; MALEK *et al.*, 2017; PALÁCIOS *et al.*, 2016; NAYANA; GEETHANJALI, 2017; JERKAN *et al.*, 2017; IRHOUMAH *et al.*, 2018; BERZOY *et al.*, 2018; DEHGHAN *et al.*, 2018; DIAS; PEREIRA, 2018; TRUJILLO-GUAJARDO *et al.*, 2018; APPANA *et al.*, 2018; ALI *et al.*, 2019; CONTRERAS-HERNANDEZ *et al.*, 2019; DENG *et al.*, 2019; JIANG *et al.*, 2019; LIBONI *et al.*, 2019; STIEF *et al.*, 2019; WANG *et al.*, 2019b; ALI *et al.*, 2020; GANGSAR; TIWARI, 2020; NAYANA; GEETHANJALI, 2020; SABOURI *et al.*, 2020; SHAO *et al.*, 2020; VINAYAK *et al.*, 2020; XUE *et al.*, 2020; ZHAO; WANG, 2019).

## 1.2 OBJETIVOS

Os objetivos gerais deste trabalho consistem na investigação, desenvolvimento, implementação e validação de uma abordagem alternativa para o diagnóstico e iden-

tificação de falhas em motores de indução trifásicos independente do seu tipo de alimentação (diretamente da rede elétrica ou inversor de frequência) baseadas em medidas de informação e sistemas inteligentes.

Assim, os objetivos específicos do trabalho são apresentados a seguir:

- Estudar o estado da arte relacionado às metodologias empregadas no diagnóstico de falhas em motores de indução trifásicos alimentados diretamente pela rede elétrica ou por meio de inversores de frequência;
- Utilizar os bancos de dados criados pelos pesquisadores do Laboratório de Sistemas Inteligentes (LSI) do Centro Integrado de Pesquisa em Controle e Automação (CIPECA) da Universidade Tecnológica Federal do Paraná (UTFPR), Campus Cornélio Procópio, os quais consistem de uma grande variedade de ensaios experimentais para os motores de indução trifásicos sujeitos a diversas condições de operação como variação no conjugado de carga, no desequilíbrio da tensão de alimentação e na faixa de frequência de alimentação, bem como falhas de rolamentos, rotor e estator;
- Analisar os sinais das correntes de linha das máquinas elétricas operando sem falhas e com falhas de rolamentos, rotor e estator;
- Utilizar o algoritmo da informação mútua atrasada conforme Nichols (2006), Alonso *et al.* (2007) e Melia *et al.* (2015), a fim de obter as medidas de associação entre os sinais de correntes dos MITs;
- Realizar a avaliação entre diferentes técnicas inteligentes, tais como a RNA MLP, o algoritmo  $k$ -NN e a SVM, com o intuito de verificar qual classificador é mais adequado com a técnica de extração de características;
- Avaliar a otimização da técnica de processamento de sinais devido ao complexo processamento estatístico das ferramentas, com o intuito de embarcar a metodologia proposta em hardware<sup>1</sup> e assim ter um sistema de diagnóstico on-line;
- Embarcar a metodologia proposta para o diagnóstico de curto-circuito de estator em MITs acionados diretamente pela rede elétrica em um hardware dedicado;

---

<sup>1</sup>De acordo com o Manual de Comunicação do Senado Federal. Disponível em: <<https://www12.senado.leg.br/manualdecomunicacao/redacao-e-estilo/estilo/estrangeirismos-grafados-sem-italico>>. Acesso em: 21/10/2020 às 14h.

- Validar a metodologia em testes on-line.

Neste contexto, esse trabalho visa apresentar uma metodologia alternativa e generalista para o diagnóstico de falhas nos rolamentos, barras quebradas do rotor e enrolamento do estator em MIT acionados diretamente pela rede de alimentação ou por modelos distintos de inversores de frequência, monitorando a associação entre os sinais de correntes das fases A e B do motor, utilizando a informação mútua e classificadores de padrões para identificar as falhas.

### 1.3 CONTRIBUIÇÕES

A proposta deste trabalho busca contribuir com as pesquisas na área de monitoramento e diagnóstico de falhas em MITs acionados independentemente da fonte de alimentação. Assim, por meio da identificação de falhas incipientes em uma máquina, objetiva-se minimizar os custos de manutenção e paradas não-programadas de um processo produtivo industrial, justificando a necessidade de um monitoramento on-line, e abrangendo os seguintes pontos:

- Apresentar uma contribuição ao estudo de monitoramento e diagnóstico de falhas de rolamentos, barras quebradas de rotor e enrolamento do estator em MIT alimentados tanto diretamente da rede quanto por inversores de frequência utilizando uma metodologia alternativa baseada em medidas de informação e sistemas inteligentes validados a partir de sinais de correntes obtidos diretamente da máquina;
- Investigar a robustez da metodologia proposta para o monitoramento e diagnóstico de falhas em MIT de diferentes potências operando tanto em regime senoidal em níveis de desequilíbrios de tensão de alimentação de até 10% de seu valor nominal quanto em regime não-senoidal numa ampla faixa de operação compreendida entre 12-60 Hz, sob diferentes níveis de conjugado de carga, em regime permanente, por meio de dados extraídos da corrente de estator no domínio do tempo;
- Identificar o classificador de padrões mais adequado à técnica utilizada para a extração de características das assinaturas de falhas dos MITs;

- Implementar em hardware DSP o sistema para o monitoramento e diagnóstico de curto-circuito de estator em MITs alimentados diretamente pela rede a fim de colaborar nas tomadas de decisão em tempo real para o operador, possibilitando assim aumentar a disponibilidade e a confiabilidade de operação dessas máquinas.

#### 1.4 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado conforme descrito a seguir: no Capítulo 2, apresenta-se um estudo sobre as principais falhas em MITs, destacando as falhas de rolamentos, barras quebradas de rotor e estator, bem como trabalhos relacionados ao monitoramento e diagnóstico dessas falhas em MITs acionados diretamente da rede ou por meio de inversores de frequência.

No Capítulo 3, resumem-se os conceitos fundamentais da metodologia para a extração de características das assinaturas de falhas baseada na informação mútua e classificadores de padrões baseados em redes neurais artificiais, máquinas vetores de suporte e algoritmo dos  $k$ -vizinhos próximos. O Capítulo 4 apresenta os aspectos metodológicos relacionados à abordagem empregada para a identificação de falhas de rolamentos, barras quebradas de rotor e curto-circuito entre as espiras do estator em MITs independente do seu tipo de alimentação. Ainda, nos Capítulos 5 e 6, apresentam-se e discutem-se os resultados experimentais off-line<sup>1</sup> e on-line<sup>1</sup> obtidos a partir dos ensaios realizados, com o intuito de validar a proposta. Finalmente, no Capítulo 7, as conclusões finais do trabalho e as perspectivas futuras são descritas.

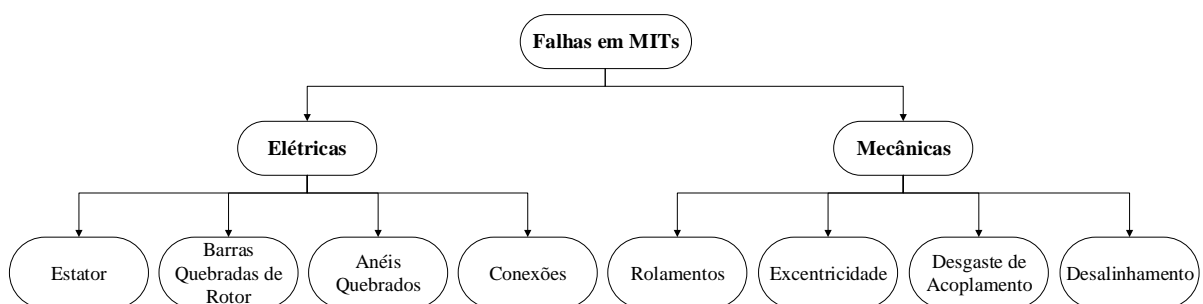
---

<sup>1</sup>De acordo com o Manual de Comunicação do Senado Federal. Disponível em: <<https://www12.senado.leg.br/manualdecomunicacao/redacao-e-estilo/estilo/estrangeirismos-grafados-sem-italico>>. Acesso em: 21/10/2020 às 14h.

## 2 FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

Neste capítulo são apresentadas as pesquisas relacionadas ao monitoramento e diagnóstico de falhas em máquinas elétricas, relatando as recentes pesquisas da comunidade científica para a solução dessas situações adversas. A motivação das referidas pesquisas consiste em evitar as paradas indesejadas e redução de gastos com manutenção em diversos processos produtivos industriais.

Os motores de indução trifásicos estão presentes em grande parte dos equipamentos empregados em aplicações industriais, devido as suas características como baixo custo de aquisição e manutenção, aliado com a sua adaptabilidade a diversas condições de operação. Entretanto, estas máquinas podem apresentar algum tipo de falha com o passar do tempo que pode prejudicar a sua operação de forma adequada. Dentre as falhas em MITs, encontram-se as falhas elétricas, associadas geralmente aos enrolamentos de estator e de rotor, às barras quebradas e anéis quebrados do rotor e conexões bem como as falhas mecânicas, resultado de defeitos de rolamentos, excentricidade, desgaste de acoplamento e desalinhamento (BELLINI *et al.*, 2008; TRACHI *et al.*, 2016; MIRZAEVA *et al.*, 2017; DEGHAN *et al.*, 2018; GANGSAR; TIWARI, 2020). A Figura 1 apresenta a classificação dos principais tipos de falhas em MITs.



**Figura 1 – Classificação dos principais tipos de falhas presentes nos MITs**

**Fonte: Autoria própria**

Devido à presença dessas falhas nos MITs, vários autores estão apresentando metodologias para o monitoramento e diagnóstico das condições dessas máquinas visando identificar os defeitos incipientes relativos as mesmas, objetivando a prevenção de desligamentos dispendiosos, a redução dos custos com manutenção e a operação mais confiável das máquinas (FROSINI *et al.*, 2015; TRACHI *et al.*, 2016; BOUDINAR

*et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; LEITE *et al.*, 2015; ELBOU-CHIKHI *et al.*, 2016; PRUDHOM *et al.*, 2017; DELGADO-ARREDONDO *et al.*, 2017; SURYA *et al.*, 2017; ABDALLAH; BENATMAN, 2017; GUEDES *et al.*, 2016; BESSAM *et al.*, 2016; GYFTAKIS *et al.*, 2016; HOU *et al.*, 2016; GODOY *et al.*, 2016; MOUSSA *et al.*, 2017; GARCÍA-ESCUDERO *et al.*, 2017; GARCIA-CALVA *et al.*, 2017; MARTINEZ *et al.*, 2017; SOUSA *et al.*, 2017; SAMANTA *et al.*, 2018; ROMERO-TRONCOSO *et al.*, 2016; MALEK *et al.*, 2017; PALÁCIOS *et al.*, 2016; NAYANA; GEETHANJALI, 2017; JERKAN *et al.*, 2017; IRHOUMAH *et al.*, 2018; BERZOY *et al.*, 2018; DEHGHAN *et al.*, 2018; DIAS; PEREIRA, 2018; TRUJILLO-GUAJARDO *et al.*, 2018; APPANA *et al.*, 2018; ALI *et al.*, 2019; CONTRERAS-HERNANDEZ *et al.*, 2019; DENG *et al.*, 2019; JIANG *et al.*, 2019; LIBONI *et al.*, 2019; STIEF *et al.*, 2019; WANG *et al.*, 2019b; ALI *et al.*, 2020; GANGSAR; TIWARI, 2020; NAYANA; GEETHANJALI, 2020; SABOURI *et al.*, 2020; SHAO *et al.*, 2020; VINAYAK *et al.*, 2020; XUE *et al.*, 2020; ZHAO; WANG, 2019). Geralmente, essas metodologias empregam ferramentas para a extração e seleção de características dos sinais coletados, além de SIs para a classificação desses padrões extraídos.

Nas próximas seções são apresentados recentes trabalhos relativos as diversas metodologias propostas para o diagnóstico das principais falhas encontradas nos MITs.

## 2.1 FALHAS DE ROLAMENTOS EM MITS

As falhas de rolamentos são as falhas mais comuns em MITs. As maiores causas dessas falhas são: i) defeitos de pista interna e externa devido a estresse térmico ou mecânico, ii) defeitos na caixa dos rolamentos ocasionado pelo desalinhamento ou montagem incorreta dos rolamentos, iii) falta de lubrificação nos rolamentos (ESFAHANI *et al.*, 2014; GANGSAR; TIWARI, 2020).

Para o diagnóstico dessas falhas, os autores propõem metodologias que geralmente dependem de um único tipo de sinal das máquinas. Neste contexto, os sinais das correntes, de vibrações, dos fluxos de dispersão, das tensões e das potências ativa e reativa foram empregadas como bases das metodologias para o diagnóstico das falhas de rolamentos. Apesar de algumas dessas abordagens demonstrarem ser confiáveis apenas para a detecção de um tipo de falhas, boa parte delas provaram ser suficientemente confiáveis para diagnosticar uma ampla gama de falhas (PICAZO-RÓDENAS *et*

*al.*, 2015).

Tendo isso em vista, os métodos que empregam os sinais da grandeza corrente das máquinas têm ganhado destaque. Isso deve-se ao fato de que a forma de onda da corrente do estator pode ser coletada de maneira não-invasiva, utilizando sensores de efeito Hall, amperímetros, transformadores de corrente e osciloscópios. Uma vez que não são realizadas medições invasivas, não implicam a instalação de sensores ou equipamentos auxiliares que exigem a parada da máquina, o que muitas vezes é inviável nas aplicações industriais (PICAZO-RÓDENAS *et al.*, 2015). Além das correntes, os sinais de vibração são amplamente utilizados no diagnóstico de falhas de rolamentos. Esses sinais também são geralmente coletados por sensores não-invasivos, tais como acelerômetros baseados em Sistemas Microeletromecânicos, do inglês *Microelectromechanical Systems* (MEMS), acelerômetros piezoelétricos, dentre outros (S.; HEGDE, 2016).

Normalmente, os sinais coletados não são adequados para a detecção da existência de uma falha. Assim, várias metodologias utilizam técnicas que extraem e selecionam as características mais relevantes dos sinais (TIAN *et al.*, 2016). Alguns autores trabalham com métodos no domínio da frequência, utilizando técnicas de processamento que realizam a decomposição espectral dos sinais, tais como a TF (ELBOUCHIKHI *et al.*, 2016; PRUDHOM *et al.*, 2017; DELGADO-ARREDONDO *et al.*, 2017; LEITE *et al.*, 2015; FROSINI *et al.*, 2015; PICAZO-RÓDENAS *et al.*, 2015; S.; HEGDE, 2016; TRACHI *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; BOUDINAR *et al.*, 2016; SOHAIB; KIM, 2020; DING *et al.*, 2020; KUMAR *et al.*, 2021), a TW (TRACHI *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; ABID *et al.*, 2018; ZHANG *et al.*, 2018; ALI *et al.*, 2019; ALI *et al.*, 2020) e a TH (ESFAHANI *et al.*, 2014; KONAR; CHATTOPADHYAY, 2015; XUE *et al.*, 2020).

Algumas técnicas que utilizam o domínio da frequência estão sendo associadas com outras metodologias para contribuir no diagnóstico mais preciso dos motores. Em Trachi *et al.* (2016) e Trachi *et al.* (2017), são utilizados parâmetros estatísticos extraídos a partir de estimadores de mínimos quadrados para favorecer na identificação de falhas de rolamentos e de rotor em motores de indução. Outros autores como Boudinar *et al.* (2016) utilizam o *Root-Multiple Signal Classification Method* para auxiliar na detecção de defeitos nos rolamentos de motores de indução trifásicos.

Em Singh e Kumar (2017), uma nova abordagem para a detecção de falhas de rolamentos foi proposta. Tal abordagem utiliza a Transformada *Wavelet* Contínua (TWC) combinados com critérios baseado em energia para a extração e identificação dos componentes de falhas.

Recentemente, nos trabalhos de Ali *et al.* (2019) e Ali *et al.* (2020), foram avaliados a técnica de busca de correspondência ortogonal, do inglês *Orthogonal Matching Pursuit* (OMP), e a TW discreta para a extração de características dos sinais de corrente e de vibração para a identificação de múltiplas falhas em MITs acionados diretamente pela rede e por meio de inversores de frequência. Os padrões extraídos no processamento desses sinais foram analisados em diversos classificadores disponíveis na *toolbox* Matlab® *Classification Learner*. Os autores do referido trabalho utilizaram diversas condições de operação como variação no conjugado de carga e variações nos níveis de tensão de alimentação, tendo alcançado taxas de acerto na classificação dos padrões superior a 90%.

No trabalho de Picazo-Ródenas *et al.* (2015), os autores apresentaram uma metodologia combinando o uso de dados de correntes e de temperatura para o monitoramento de defeitos de rolamentos, de barras quebradas de rotor e do sistema de ventilação de MITs alimentados diretamente da rede. Esta metodologia é dividida em dois estágios, onde o primeiro, baseia-se na coleta dos sinais de correntes por um amperímetro e posterior análise desses sinais pelo domínio da frequência, com o intuito de diagnosticar a situação das máquinas. Caso no primeiro estágio não seja possível obter um diagnóstico conclusivo, na segunda etapa, a análise das imagens termográficas obtidas por meio da câmera infravermelha é usada para descartar ou confirmar a presença do defeito. Embora a metodologia utiliza sensores com um preço mais elevado, essa abordagem é útil independente da potência do motor, visto que o adequado diagnóstico pode levar à redução de perdas econômicas e paradas na produção. Ainda, não há relatos no trabalho se os autores utilizaram nos ensaios experimentais variações no desequilíbrio de alimentação das máquinas.

Observa-se na literatura que, geralmente, boa parte das metodologias são baseadas em análises dos sinais de vibração, tendo em vista a sua eficácia e confiabilidade na detecção desse tipo de falha (JIN *et al.*, 2014; ESFAHANI *et al.*, 2014; TIAN *et al.*, 2016; PANDARAKONE *et al.*, 2017). No trabalho de Jin *et al.* (2014),



uma metodologia alternativa para a extração de características dos sinais de vibração baseada na *Trace Ratio-Linear Discriminant Analysis* (TR-LDA) foi proposta para o diagnóstico de falhas de rolamentos de ponto único e de desgastes abrasivos. Os resultados experimentais demonstram que a abordagem proposta alcança promissor desempenho quando comparado com outras metodologias convencionais utilizadas na redução da matriz de dados.

Em Amar *et al.* (2015), as falhas de rolamentos são monitoradas por meio de imagens espectrais dos sinais de vibração. Os autores utilizam um filtro de média 2-D para aumentar a qualidade das características das imagens combinado com as redes neurais artificiais para a classificação dos padrões. No artigo de Harmouche *et al.* (2015), verificou-se que as assinaturas produzidas pelos defeitos de rolamentos nos sinais de vibração eram muito fracas e difíceis de serem detectadas e identificadas, tendo isso em vista, os autores empregaram a análise discriminante linear para melhorar a identificação entre as diferentes condições de falhas em rolamentos em MITs.

Já o artigo de Tian *et al.* (2016) apresentou uma metodologia que identifica e monitora a degradação em rolamentos de máquinas elétricas. Baseado na análise espectral de *kurtosis* e na correlação cruzada, o método extrai as características das falhas de rolamentos presentes nos sinais de vibração. Os resultados experimentais demonstraram principalmente a capacidade da abordagem para a identificação de falhas ainda em estágios incipientes.

Em S. e Hegde (2016), apresentou-se uma abordagem alternativa para a detecção de defeitos em rolamentos e sua influência na excentricidade das máquinas. Para a aquisição dos sinais de vibração são empregados os acelerômetros MEMS. Nesse artigo, os autores utilizaram desequilíbrios de tensão na alimentação do motor, situação comum às aplicações industriais. Entretanto, foram realizados ensaios experimentais apenas com o MIT operando a vazio. Não há evidências se houve avaliação da metodologia em situações sob variação de carga.

Já em Saucedo-Dorantes *et al.* (2017), os autores empregaram a análise discriminante linear, do inglês *Linear Discriminant Analysis* (LDA) e RNAs para o monitoramento de múltiplas falhas em MITs. O principal objetivo foi apresentar uma metodologia para reduzir a dimensão dos dados e conseqüentemente aumentar a performance do sistema de diagnóstico. Assim, aliado à LDA, os pesquisadores utilizaram outras ferra-

mentas de otimização como o algoritmo genético, a PCA e a técnica Fisher *score* para selecionar os atributos mais significativos resultantes do processo de decomposição dos sinais de vibração. Essa gama de ferramentas possibilitou o uso de uma simples RNA para a identificação das múltiplas falhas.

Recentemente em Stief *et al.* (2019), foi desenvolvido uma metodologia bayesiana combinada ao PCA para diagnosticar defeitos no estator, no rotor e nos rolamentos de MITs acionados diretamente pela rede elétrica. O PCA é empregado para remover as correlações presentes nas características extraídas dos sinais de vibração e de outras variáveis da máquina, além de reduzir a influência das diversas condições de carga em que a máquina atua. Os resultados experimentais com acurácias acima de 94% demonstram a satisfatória capacidade da metodologia no diagnóstico desses defeitos.

Nos trabalhos de Nayana e Geethanjali (2017) e Nayana e Geethanjali (2020), são empregadas características no domínio do tempo dos sinais de vibração, tais como o valor absoluto médio, integral simples do sinal, comprimento da forma de onda, amplitude de Wilson, passagem por zero e mudanças da inclinação do sinal para o diagnóstico de defeitos de rolamentos em MITs. Após, a seleção de características são realizadas por um filtro baseado em um *score* Laplaciano e por uma abordagem de *wrapper*. Assim, os atributos selecionados foram avaliados por diversos classificadores de padrões, tais como a LDA, o Naive Bayes e os SVMs.

Contudo, as análises dos sinais de vibração apresentam algumas desvantagens, principalmente na escolha e no posicionamento do sensor, pois os mesmos variam de acordo com a localização do equipamento. Tais desvantagens podem ser superadas por meio de metodologias baseadas em análises da corrente do estator, pois são capazes de detectarem os defeitos de rolamentos indiferentemente da escolha e do posicionamento do sensor adotado (PANDARAKONE *et al.*, 2017).

Em Leite *et al.* (2015), foram utilizados os algoritmos baseados em *kurtosis* espectrais como a kurtograma rápida e a kurtograma *Wavelet* dos sinais de corrente, buscando detectar a severidade de falhas nos rolamentos de pista externa em motores de indução trifásicos.

O artigo de Pandarakone *et al.* (2017) apresenta uma metodologia para a identificação de defeitos de pista externa por meio da seleção de frequência de falhas

no espectro de corrente do estator. Os autores utilizaram essas frequências como matriz de entrada das máquinas de vetores de suporte para a classificação das falhas.

Recentemente no trabalho de Contreras-Hernandez *et al.* (2019), os autores empregaram o método de análise de sinal de quaternário, do inglês *Quaternion Signal Analysis* (QSA), para obter os modelos de comportamentos dos sinais de corrente e de vibração dos MITs. Este método permite a extração de características para a detecção de falhas de rolamentos e desbalanceamento no rotor em MITs por meio da análise estatística de *quaternion*. Nos testes experimentais, foram obtidos acurácias de 99%, no entanto, os pesquisadores não evidenciaram no manuscrito se as máquinas estiveram sujeitas a alterações em suas condições de operação.

Nos últimos anos, a aprendizagem profunda, do inglês *Deep Learning* (DL), têm atraído a atenção de pesquisadores de diversas áreas, como processamento de imagens, visão computacional e reconhecimento de padrões, devido à sua melhor compreensão das informações intrínsecas provenientes dos dados analisados (SOHAIB; KIM, 2020). Além disso, recentemente, os algoritmos de aprendizado profundo estão sendo empregados em metodologias de diagnóstico de falhas em máquinas rotativas, devido a sua capacidade de classificação dos dados sem a necessidade de ferramentas específicas para a extração de características dos sinais (SOHAIB; KIM, 2020; DING *et al.*, 2020).

No trabalho de Sohaib e Kim (2020), as redes neurais convolutivas, do inglês *Convolutional Neural Networks* (CNN), são empregadas no diagnóstico de defeitos de rolamentos em MITs. Essas redes aprendem as informações contidas nos espectros dos sinais de vibração, compactando assim os dados necessários para o processo de classificação. Por outro lado, Ding *et al.* (2020) apresentou um modelo alternativo denominado de *stacked auto-encoders sparse filter rotating component comprehensive diagnosis* (SAFC) para identificar defeitos nos rolamentos de máquinas elétricas rotativas. Essa metodologia proposta tem a capacidade de realizar a *clusterização* e a redução da dimensão dos espectros obtidos por meio dos sinais de vibração das máquinas.

A partir da literatura, torna-se evidente que os sinais de vibração e de corrente são considerados como as duas maiores escolhas para a questão do diagnóstico de falhas de rolamentos em MITs (DALVAND *et al.*, 2016). Por outro lado, alguns

pesquisadores estão observando que outros sinais como os fluxos de dispersão, as tensões e as emissões acústicas podem ser úteis no diagnóstico. Frosini *et al.* (2015) analisaram que o fluxo de dispersão de uma máquina elétrica pode ser afetado pela presença de falhas nas mesmas, pois esse fluxo está relacionado ao estado magnético da máquina. Assim, os autores do referido artigo utilizaram os sinais de fluxo de dispersão para a identificação de falhas de rolamentos em MITs.

Já Dalvand *et al.* (2016) empregaram as *kurtosis* espectrais da frequência instantânea da tensão para a detecção de defeitos em rolamentos. Os resultados experimentais indicam a capacidade da metodologia proposta em revelar a existência de falhas de rolamentos. Em Delgado-Arredondo *et al.* (2017), os pesquisadores utilizaram os sinais acústicos para a detecção de falhas de rolamentos e barras quebradas do rotor dos MITs. As análises realizadas nos sinais acústicos demonstraram a capacidade na identificação das frequências associadas às falhas, de forma equivalente às análises realizadas por meio de sinais de vibração.

No trabalho de Esfahani *et al.* (2014) foi apresentado um método computacional capaz de identificar a presença e os tipos de defeitos de rolamentos e excentricidade em MITs acionados por inversores de frequência. Os autores analisaram os sinais de vibração, acústicos e de corrente coletados pela plataforma proposta para a caracterização das falhas. Embora, os autores desse referido trabalho terem apresentados resultados promissores, não ficou evidenciado no texto se os MITs foram submetidos a outras condições de operação comuns ao ambiente industrial, tais como variação no conjugado de carga e na frequência de alimentação das máquinas.

Alternativamente, o artigo de Jiang *et al.* (2019) propôs uma abordagem para o diagnóstico de defeitos em rolamentos, estator e rotor de MITs conectados diretamente à rede elétrica. A metodologia obtém os padrões dos sinais de corrente e acústicos empregando as técnicas de decomposição de valor singular, do inglês *Singular Value Decomposition* (SVD), e a aprendizagem ampla incremental de características, do inglês *Feature Incremental Broad Learning* (FIBL). Mesmo diante a variações no conjugado de carga e no desequilíbrio de tensão de alimentação, a metodologia proposta obteve taxas de classificação superiores a 92%, demonstrando que é promissora no diagnóstico desses defeitos em máquinas elétricas.

As pesquisas apresentadas nessa seção demonstram a importância dos tipos

de sinais, do meio que os mesmos são coletados, bem como das técnicas para extração de características em um eficiente diagnóstico de defeitos de rolamentos em MITs. Ainda, na sequência, são abordados os trabalhos relacionados ao diagnóstico de barras quebradas de rotor.

## 2.2 FALHAS DE BARRAS QUEBRADAS DE ROTOR EM MITS

As falhas de barras quebradas de rotor correspondem, em torno de 5 a 10% dos casos de falhas do motor de indução trifásico (THORSEN; DALVA, 1995; BONNETT; YUNG, 2008; BELLINI *et al.*, 2008; GYFTAKIS *et al.*, 2016; MALEK *et al.*, 2017; SAMANTA *et al.*, 2018; DIAS; PEREIRA, 2018; TRUJILLO-GUAJARDO *et al.*, 2018; LIBONI *et al.*, 2019; GANGSAR; TIWARI, 2020).

A metodologia para a fabricação do motor e as condições de trabalho estão profundamente relacionados a presença desse tipo de defeito nessas máquinas. Ao utilizar o alumínio na fundição da gaiola de esquilo do motor, as falhas de barras quebradas de rotor podem vir a ocorrer devido a presença de bolhas de ar dentro das barras, formadas durante o processo de fundição, tais quais provocam pontos quentes no enrolamento e, ocasionalmente, rachaduras locais da gaiola. Já as falhas de barras quebradas de rotor de um motor de indução que utilizou o cobre na fundição de sua gaiola, geralmente, estão associadas à expansão térmica das barras ao longo do eixo, vibrações e corrosão do material (GYFTAKIS *et al.*, 2016).

Além da possibilidade das barras quebradas serem produzidas por defeitos em sua fabricação, a sobrecarga das condições de operação e as fissuras mecânicas também estão relacionadas ao surgimento de barras quebradas de rotor. Barras quebradas de rotor levam ao aumento das correntes e tensões nas barras do rotor próximas às que estão danificadas, resultando na possibilidade de quebras em outras barras, ou até mesmo na ocorrência de falhas no enrolamento do estator. Assim, a detecção da barra quebrada de rotor em um estágio incipiente é muito importante (HOU *et al.*, 2016).

Tendo isso em vista, a comunidade científica está em busca de metodologias para o diagnóstico desse tipo de defeito em MITs, as quais geralmente diferenciam-se uma das outras pelo tipo de variável e ferramenta de processamento de sinais empregados, bem como o modo de classificação das amostras. Recentemente, os pesquisadores basearam as suas abordagens nos sinais de vibração (MARTINEZ

*et al.*, 2017; DELGADO-ARREDONDO *et al.*, 2017; MORALES-PEREZ *et al.*, 2018; ZHAO *et al.*, 2019; WANG *et al.*, 2019b; XUE *et al.*, 2020), sons acústicos (DELGADO-ARREDONDO *et al.*, 2017), corrente do estator (TRACHI *et al.*, 2016; GYFTAKIS *et al.*, 2016; HOU *et al.*, 2016; GODOY *et al.*, 2016; MOUSSA *et al.*, 2017; GARCÍA-ESCUADERO *et al.*, 2017; GARCIA-CALVA *et al.*, 2017; JERKAN *et al.*, 2017; SAMANTA *et al.*, 2018; BESSAM *et al.*, 2016; ROMERO-TRONCOSO *et al.*, 2016; MALEK *et al.*, 2017; PALÁCIOS *et al.*, 2016; TRUJILLO-GUAJARDO *et al.*, 2018; LIBONI *et al.*, 2019; WANG *et al.*, 2019b; ABID *et al.*, 2020; ZHAO; WANG, 2019), tensão (HOU *et al.*, 2016; GARCIA-CALVA *et al.*, 2017; LIBONI *et al.*, 2019), potências ativa e reativa (DRIF *et al.*, 2017) e sinais magnéticos (TRACHI *et al.*, 2016; SOUSA *et al.*, 2017; DIAS; PEREIRA, 2018; PANAGIOTOU *et al.*, 2019).

Em Malek *et al.* (2017) foi apresentado uma técnica para a identificação da severidade dos defeitos de barras quebradas de rotor em MITs baseada na análise estatística do envelope da corrente do estator. A fim de avaliar a metodologia proposta, os autores realizaram simulações para situações onde as máquinas são alimentadas diretamente da rede ou por inversores de frequência. Em ambos testes, foram investigados o comportamento da metodologia sem carga e com carga nominal. Entretanto, os autores deveriam ter realizado ensaios experimentais reais com o objetivo de validar a abordagem proposta nesse trabalho.

Já em Jerkan *et al.* (2017), ao empregar a técnica de frenagem por contracorrente, do inglês *Counter-Current Braking Method* (CCB), os autores propuseram uma metodologia alternativa para o diagnóstico de barras quebradas de rotor aplicável a MITs de diversas potências. Nos ensaios experimentais observou-se que o acoplamento magnético entre os enrolamentos do estator e do rotor produzem assinaturas características de falhas que possibilitam o diagnóstico das condições dos MITs.

No artigo de Sousa *et al.* (2017), os autores propõem uma abordagem que emprega os sinais da deformação dinâmica do estator para a detecção das barras quebradas do rotor. A coleta dos sinais são realizadas de forma invasiva por sensores de deformação de fibra óptica FBG (*Fiber Bragg Grating*) instalados na superfície do estator. Utilizando as componentes espectrais dos sinais de deformação do estator, as barras quebradas de rotor podem ser identificadas em motores operando em diversas condições de carga, bem como independente da sua fonte de alimentação.

Entretanto, não ficou evidenciado no texto se nos ensaios experimentais as máquinas estiveram sujeitas a variações no desequilíbrio de tensão e na variação da frequência de alimentação.

O trabalho de Drif *et al.* (2017) propôs o monitoramento on-line de barras quebradas de rotor em motores alimentados diretamente pela rede e sujeitos a variações no conjugado de carga. Os autores propõem a comparação da análise de assinatura das potências instantâneas ativa e reativa por intermédio de corrente e tensão, no domínio da frequência. No entanto, não há citações se nos ensaios experimentais os autores verificaram o comportamento da estratégia quando as máquinas estão sujeitas a variações nos níveis de desequilíbrio das tensões de alimentação.

Recentemente, no trabalho de Panagiotou *et al.* (2019), uma nova abordagem é apresentada para a detecção de barras quebradas de rotor em MITs acionados diretamente pela rede elétrica. Esse método proposto analisa as componentes provenientes da extração de frequência dos sinais de fluxo de dispersão por meio do uso da Transformada de Fourier de Tempo Curto, do inglês *Short Time Fourier Transform* (STFT). Os resultados experimentais demonstraram que a seleção dos subcomponentes dos harmônicos relacionados às falhas oferecem uma promissora capacidade de diagnóstico da real situação das máquinas.

Já em Morales-Perez *et al.* (2018), uma metodologia é proposta para o diagnóstico de barras quebradas de rotor em MITs acionados diretamente pela rede elétrica, analisando os espectros de frequência dos sinais de vibração em um algoritmo OMP. Esses espectros, obtidos por meio da TF, são introduzidos no algoritmo OMP, a fim de selecionar as informações necessárias para a realização do diagnóstico. A partir dos resultados experimentais, observou-se que a abordagem proposta é capaz de identificar os defeitos de barras quebradas de rotor ainda em estágios iniciais.

Além do tipo de sinal empregado, os autores trabalham com diferentes técnicas de processamento desses referidos sinais, as quais são capazes de extrair e selecionar as características mais significativas, colaborando assim na identificação das assinaturas de falhas. Neste contexto, destacam-se as ferramentas que trabalham com a decomposição espectral dos sinais, como a TF (GYFTAKIS *et al.*, 2016; HOU *et al.*, 2016; MOUSSA *et al.*, 2017; MARTINEZ *et al.*, 2017; SOUSA *et al.*, 2017; JERKAN *et al.*, 2017; PANAGIOTOU *et al.*, 2019), a TW (GARCÍA-ESCUADERO *et al.*, 2017;

TRACHI *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017), a TH (BESSAM *et al.*, 2016; MALEK *et al.*, 2017; XUE *et al.*, 2020), a MUSIC (GARCIA-CALVA *et al.*, 2017; NAHA *et al.*, 2016; ROMERO-TRONCOSO *et al.*, 2016), a ESPRIT (KIM *et al.*, 2013; XU *et al.*, 2012) e a corrente de sequência zero, do inglês *Zero-Sequence Current* (ZSC) (GYFTAKIS *et al.*, 2016).

Em Hou *et al.* (2016) foi apresentada uma metodologia on-line para o diagnóstico de barras quebradas de rotor embarcado em um *Digital Signal Processor* (DSP). Essa abordagem baseia-se em um fator de severidade de falhas, o qual é obtido por meio das componentes fundamentais e de banda laterais dos sinais de correntes e tensões das máquinas. No artigo de Martinez *et al.* (2017) foi desenvolvido uma técnica que relaciona o número de barras quebradas de rotor com a amplitude e fase dos componentes de baixa frequência dos sinais de vibração das máquinas. Realizando os ensaios experimentais, os pesquisadores verificaram que as amplitudes de vibração das componentes relacionadas às falhas aumentam quadraticamente com o número de barras de rotor quebradas. Embora utiliza-se um elevado número de acelerômetros, os resultados demonstram que o espectro dos sinais de vibrações possibilitam encontrar uma maior quantidade de assinaturas associadas às falhas quando comparado ao espectro dos sinais de corrente em torno da frequência fundamental.

No trabalho de Gyftakis *et al.* (2016) é apresentado uma nova abordagem para o diagnóstico de barras quebradas de rotor de MITs utilizando a decomposição espectral da ZSC. Nos ensaios experimentais, o motor esteve sujeito a variações no nível de torque de carga e nas tensões de alimentação e foram analisados dois níveis de severidade; a saber: uma e duas barras quebradas de rotor. Os resultados experimentais revelaram que a metodologia proposta é promissora na detecção de barras quebradas de rotor mesmos em situações comuns aos ambientes industriais, tais como variações nos níveis de conjugado de carga e de tensão de alimentação, pois verificaram-se que os espectros da ZSC contém assinaturas mais expressivas do que os espectros de corrente de linha dos motores.

Em Moussa *et al.* (2017), calculando a Transformada Discreta de *Fourier*, do termo inglês *Discrete Fourier Transform* (DFT), da corrente do estator, os pesquisadores analisaram a oscilação da magnitude da frequência fundamental gerada pelas suas frequências de bandas laterais vizinhas com o intuito de identificar as falhas de barras



quebradas de rotor. Essa metodologia mostrou satisfatório desempenho no diagnóstico de barras quebradas e superioridade na situação em que o motor está operando com baixo nível de conjugado de carga em relação às metodologias convencionais. Entretanto, não há evidências no trabalho se os autores empregaram desequilíbrios das tensões de alimentação das máquinas para a realização dos ensaios experimentais.

Por outro lado, uma abordagem alternativa baseada na combinação da *Complete Ensemble Empirical Mode Decomposition* (CEEMD) e do MUSIC foi apresentada no trabalho de Romero-Troncoso *et al.* (2016) para a detecção de barras quebradas de rotor e excentricidade em MITs acionados por fontes não-senoidais. A ferramenta proposta permitiu a identificação da evolução temporal das frequências de falhas no regime transitório e permanente dos sinais de correntes das máquinas. Os resultados experimentais demonstraram a capacidade da metodologia na detecção desses defeitos, mesmo em situações onde as máquinas estiveram sujeitas às variações de carga. Contudo, não ficou claro nos ensaios experimentais se houve variação da frequência de alimentação das máquinas.

Diferentemente dos autores que empregaram as metodologias MUSIC e ESPRIT, no artigo de Samanta *et al.* (2018), utilizaram-se os espectros dos sinais de correntes para obter o escorregamento dos MITs. Após, esse valor do escorregamento foi empregado na estimação e identificação das frequências dos defeitos de barras quebradas de rotor.

No trabalho de Zhao *et al.* (2019), é apresentada uma nova metodologia para a detecção de falhas no rotor. A técnica PCA é empregada em um amplo sistema de aprendizagem, sendo assim uma rede plana alternativa para estruturas de aprendizagem profunda (CHEN; LIU, 2018). Utilizando a PCA foi possível remover a correlação peculiar dos sinais de vibração, que geralmente é considerada um problema dos métodos tradicionais de extração de características. Além disso, esta ferramenta permitiu a redução dos vetores de entrada para o sistema de aprendizagem. As acurácias de classificação obtidas para os testes experimentais validaram o método de detecção de falha do rotor.

Dias e Pereira (2018) apresentaram uma metodologia inteligente para a detecção de barras quebradas de rotor em MITs operando diretamente pela rede elétrica e em diversas condições de carga. Nessa abordagem, algumas frequências característi-

cas dos sinais foram empregadas como entradas para três classificadores inteligentes, SVMs,  $k$ -NNs e RNAs MLP. Ainda, essa metodologia utilizou o PCA para a redução da dimensão da matriz de entrada de dados desses classificadores. Nos ensaios experimentais, a combinação da ferramenta PCA com o classificador RNA MLP demonstrou ser capaz de detectar barras quebradas de rotor, mesmo em condições de operação com baixo torque de carga ou a vazio, atingindo acurácias de classificação superiores a 90%.

Zhao e Wang (2019) desenvolveram uma nova estratégia híbrida de diagnóstico inteligente de barras quebradas de rotor em MITs baseada em PCA, no algoritmo de otimização de forrageamento bacteriano com voos Levy, do inglês *bacterial foraging optimization with Levy flight* (LBFO), e no classificador de máquina de vetor de relevância multivariada, do inglês *multivariate relevance vector machine* (MRVM). No algoritmo desenvolvido, o PCA é empregado para reduzir a dimensionalidade dos conjuntos de amostras e selecionar os seus atributos mais relevantes dos sinais de corrente da máquina, o LBFO é aplicado para obter os parâmetros *kernel* do classificador MRVM. A metodologia demonstrou ser eficiente no diagnóstico de diversos níveis de severidade de barras quebradas de rotor em MITs acionados diretamente pela rede elétrica sob várias condições de torque de carga. Não ficou evidenciado no trabalho, os resultados advindos da aplicação do método proposto para situações em que as tensões de alimentação da máquina estão desequilibradas, uma situação usual ao ambiente industrial.

Ainda, os trabalhos de Palácios *et al.* (2016), Godoy *et al.* (2016) e Garcia-Calva *et al.* (2017) abordaram as ferramentas de processamento de sinais que trabalham no domínio do tempo, devido as suas vantagens de cálculo e implementação quando comparados com os métodos que utilizam o domínio da frequência. Em Palácios *et al.* (2016), foi proposto uma ferramenta para o diagnóstico de múltiplas falhas (rotor, rolamento e estator) utilizando um Sistema Multiagentes (SM) combinado com SIs distintos, tais como: RNA, SVM e  $k$ -NN. Realizou-se o processamento dos dados de entrada do Sistema Multiagentes por meio da discretização dos sinais das correntes dos MITs.

Quando as máquinas elétricas são alimentadas por inversores de frequência, o monitoramento das falhas tem um aumento de complexidade em virtude da mudança

da frequência de alimentação, do aumento do ruído e em razão da amplitude dos harmônicos de campo, a qual é influenciada pela tensão de alimentação e dependente da escolha da técnica de controle do inversor e das frequências de chaveamento. Tendo em vista que atualmente, boa parte dos motores são alimentados por inversores de frequência, um método de monitoramento que tenha capacidade de identificar uma condição inadequada de operação independente da fonte de alimentação tem despertado o interesse da comunidade acadêmica (GARCÍA-ESCUDERO *et al.*, 2017).

García-Escudero *et al.* (2017) propôs um novo método baseado em medidas estatísticas como o teste T-Quadrado de *Hotelling* empregado em aplicações de controle de qualidade com o intuito de identificar a progressão das falhas de barras quebradas em MITs. A fim de atenuar os possíveis ruídos do espectro, os autores utilizaram as funções *Wavelet*, melhorando assim a identificação das assinaturas das falhas.

Outros pesquisadores estão utilizando os sinais no domínio do tempo para o monitoramento de barras quebradas de rotor. No trabalho de Garcia-Calva *et al.* (2017), emprega-se a ferramenta MUSIC como um método de estimação espectral da decomposição frequência-espacial dos sinais de tensão e corrente amostrados no domínio do tempo com o intuito de identificar as assinaturas de falhas de barras quebradas de rotor. A metodologia fundamenta-se na separação dos harmônicos relativos às falhas das componentes de frequência mediante a reamostragem em um tempo não-uniforme, evitando a sobreposição espectral. A utilização dessa abordagem proporcionou uma satisfatória separação das componentes das barras quebradas de rotor, produzindo assim um padrão nítido das assinaturas de falhas. Godoy *et al.* (2016) apresentaram uma nova abordagem que emprega as amplitudes dos sinais de corrente combinadas com sistemas inteligentes, com o objetivo de detectar vários níveis de severidades de barras quebradas de rotor em motores alimentados com diferentes inversores de frequência. Os ensaios experimentais, onde os motores estiverem sujeitos a diversas condições de operação como variação da frequência de alimentação e conjugado de carga, confirmaram a viabilidade da metodologia proposta.

No trabalho Liboni *et al.* (2019) é apresentada uma metodologia alternativa para o diagnóstico de barras quebradas de rotor em MITs independente do seu tipo de alimentação. A metodologia emprega uma técnica matemática no domínio do tempo para decompor sinais de tensão e corrente da máquina, denominada de decomposição

de componente ortogonal, do inglês *Orthogonal Component Decomposition* (OCD). Diferentemente de outras transformações e decomposições de sinais mais tradicionais, como a TF, na qual os sinais são decompostos em alguma base ortogonal pré-estabelecida, a técnica do OCD não decompõe sinais nessas bases, mas utiliza os sinais que estão sendo analisados como base para a decomposição. A eficiência dessa ferramenta de extração de características é avaliada por meio de análises de variância de Kruskal-Wallis e SVMs. Os resultados experimentais acima de 98% obtidos em diversas condições de operação como diferentes níveis de conjugado de carga, variações no desequilíbrio de tensão, diversificados níveis de frequência de alimentação e vários níveis de severidade de barras quebradas de rotor, demonstraram a eficiência da metodologia apresentada nesse trabalho.

A utilização de ferramentas que empregam SIs como classificadores de padrões são utilizados por Palácios *et al.* (2016), Godoy *et al.* (2016), Dias e Pereira (2018), Stief *et al.* (2019) e Liboni *et al.* (2019) já citados anteriormente. Outros pesquisadores como Bessam *et al.* (2016) utilizaram essas ferramentas para analisar os envelopes das correntes obtidos por meio da TH a fim de monitorar e detectar a presença de barras quebradas de rotor em motores de indução de trifásicos. Além disso, nos dias atuais, as arquiteturas DL tem atraído a atenção de diversos pesquisadores, principalmente as baseadas em CNNs, pois além de eliminar a necessidade do conhecimento a priori<sup>1</sup>, esses algoritmos são capazes de extrair de forma independente as características de falhas dos sinais, permitindo o eficiente diagnóstico de defeitos nas máquinas elétricas (ABID *et al.*, 2020; WANG *et al.*, 2019b; XUE *et al.*, 2020; SHAO *et al.*, 2020).

No trabalho de Wang *et al.* (2019b), foi empregada uma CNN de uma dimensão para analisar as características mais adequadas dos sinais de vibração e corrente para investigar problemas relacionados a diversos defeitos, incluindo as de rotor, em MITs alimentados por inversores de frequência. Tendo em vista que os padrões característicos de falhas distintas, geralmente exigem janelas de tempo diferentes para o correto diagnóstico, foi projetado um modelo de fusão de informações em vários níveis, denominado *Multi-Resolution e Multi-Sensor Fusion Network* (MRSFN), que permite uma boa representação de diversas resoluções, auxiliando no processo de detecção

---

<sup>1</sup>De acordo com o Manual de Comunicação do Senado Federal. Disponível em: <<https://www12.senado.leg.br/manualdecomunicacao/redacao-e-estilo/estilo/estrangeirismos-grafados-sem-italico>>. Acesso em: 21/10/2020 às 14h.

de falhas.

Recentemente em Xue *et al.* (2020), utilizou-se um modelo de aprendizado profundo, conhecido como rede neural convolucional profunda, do inglês *Deep Convolutional Neural Network* (DCNN), para extrair automaticamente as características de falha dos espectros de envelope dos sinais de vibração obtidos pela TH. Os padrões extraídos pela DCNN foram utilizados como entrada do classificador SVM para a detecção de defeitos no rolamento e no rotor da máquina. Nos resultados experimentais, observaram-se taxas de classificação acima de 98,0%. Entretanto, não ficou claro no estudo se o desempenho do sistema foi testado a diversas condições operacionais da máquina.

Alternativamente em Abid *et al.* (2020), foi apresentada uma abordagem de diagnóstico de defeitos nas barras quebradas de rotor e nos rolamentos de MITs conectados diretamente a rede, que emprega uma arquitetura profunda SincNet. Essa metodologia tem a capacidade de aprender de forma automática os padrões característicos dos defeitos diretamente dos sinais de corrente da máquina. Acurácias de classificação acima de 99,0% demonstraram a capacidade de diagnóstico de defeitos, mesmo quando as máquinas estão sujeitas a variações no conjugado de carga. No entanto, não ficou evidenciado no manuscrito, se os autores testaram a robustez do sistema quando as máquinas estão sujeitas a variações no desequilíbrio de tensão.

Observando o panorama descrito nessa seção, revelado pelo elevado número de trabalhos encontrados na literatura, evidencia-se a importância do tema e a preocupação na busca de metodologias eficientes para o diagnóstico de barras quebradas em MITs. Ainda, no contexto das falhas elétricas do MIT, na próxima seção são apresentados os estudos referentes a falhas de estator.

### 2.3 FALHAS DE ESTATOR EM MITS

Como apresentado no Capítulo 1, o enrolamento do estator é um dos componentes das máquinas elétricas mais propensos a falhas, sendo a causa de 20% a 40% das paradas indesejadas em máquinas elétricas (THORSEN; DALVA, 1995; BONNETT; YUNG, 2008; BELLINI *et al.*, 2008; BARZEGARAN *et al.*, 2013; ZAREI *et al.*, 2014; DRIF; CARDOSO, 2014; RIERA-GUASP *et al.*, 2015; BERZOY *et al.*, 2017; SURYA *et al.*, 2017; IRHOUMAH *et al.*, 2018; BERZOY *et al.*, 2018; DEGHAN *et al.*,

2018; GANGSAR; TIWARI, 2020). Essas falhas são causadas pela combinação de várias tensões internas e externas atuando no enrolamento do estator. As tensões internas são térmicas, elétricas e mecânicas. Já as externas estão relacionadas com as condições ambientais, como altas temperaturas, umidade, ambientes corrosivos e poeira (BERZOY *et al.*, 2017; BERZOY *et al.*, 2018; ELBOUCHIKHI *et al.*, 2019).

Ainda, tais falhas geralmente resultam do lento e contínuo desgaste do isolamento do enrolamento do estator. O enrolamento desgastado pode causar um defeito incipiente, devido a pequenos esforços como o sobreaquecimento, a vibração ou a sobretensão transitória, gerando assim uma falha de curto-circuito entre as espiras do enrolamento do estator. Em consequência disso, uma corrente mais alta circulará pelas espiras danificadas, aumentando a temperatura do enrolamento. O efeito térmico dessa corrente deteriora gradativamente o isolamento das espiras danificadas e vizinhas, propagando progressivamente a falha e aumentando o valor da corrente. Tendo em vista a rápida evolução desse processo, se em pouco tempo medidas apropriadas não forem tomadas, pode-se afetar o isolamento da ranhura do núcleo ou de outra fase, levando a falhas catastróficas do estator como fase-terra ou fase-fase (RIERA-GUASP *et al.*, 2015; PATEL; CHANDORKAR, 2014; BERZOY *et al.*, 2018; ELBOUCHIKHI *et al.*, 2019).

Diante desse cenário, pesquisas estão sendo realizadas a fim de detectar a presença dessas falhas ainda em estágios iniciais, possibilitando que o operador tome ações adequadas, evitando a ocorrência de paradas não-programadas e falhas mais prejudiciais às máquinas. Como para as outras falhas presentes em MITs, as metodologias para o diagnóstico de falhas do estator baseiam-se em sinais provenientes de diferentes tipos de sensores, nas técnicas para a extração de características dos sinais provenientes dos referidos sensores, bem como em sistemas inteligentes para a classificação dos padrões.

As falhas de curto-circuito entre as espiras do estator geram componentes harmônicas nas correntes do estator. Assim, as frequências características dessa falha têm sido analisadas pela comunidade científica (RIERA-GUASP *et al.*, 2015). Técnicas baseadas em análises dos sinais de correntes do motor, do termo em inglês *Motor Current Signal Analysis* (MCSA), têm sido utilizadas para a detecção de curto-circuito entre as espiras do estator. As metodologias propostas são baseadas na comparação

do espectro do sinal defeituoso com o espectro do sinal saudável da mesma máquina e geralmente utilizam-se a TF, a TW, a TH, dentre outras ferramentas de processamentos de sinais para a realização dessas análises (DEHGHAN *et al.*, 2018; ELBOUCHIKHI *et al.*, 2019; SADEGHI *et al.*, 2019).

Em Das *et al.* (2010), os autores apresentaram uma metodologia baseada na TWC combinada com a Transformada de *Park* para a realização das análises das correntes do motor. Para a classificação dos padrões obtidos na etapa de extração de características, os pesquisadores empregaram os classificadores SVM. Os resultados confirmam a satisfatória capacidade da metodologia no diagnóstico de curto-circuito entre as espiras do estator.

No trabalho de Asfani *et al.* (2012), os níveis de energia dos coeficientes *Wavelets* de alta frequência dos sinais dos motores obtidos pela Transformada *Wavelet* Discreta (TWD) são utilizados como matriz de entrada da RNA para o monitoramento e diagnóstico de falhas de estator. Seshadrinath *et al.* (2014b) utilizaram a variação da TW, conhecida como *Dual Tree Complex Wavelet Transform*, para a investigação de falhas do estator. Os autores extraíram as características das correntes do motor utilizando a referida ferramenta e empregaram o classificador SVM na etapa de classificação dos padrões. Por meio dos resultados experimentais, observou-se que apenas um dos sinais de corrente é suficiente para a detecção precisa da presença de falha, reduzindo assim o custo com sensores.

Em Abdallah e Benatman (2017), foi apresentada uma abordagem alternativa para o monitoramento e diagnóstico de curto-circuito de estator utilizando a identificação dos parâmetros dos MITs. Os autores estimaram os parâmetros das falhas de estator por meio dos sinais de tensões, de correntes e da velocidade mecânica das máquinas. Nos ensaios experimentais, as máquinas foram alimentadas diretamente pela rede e foram sujeitas a vários níveis de conjugado de carga. Todavia, não há evidências se os autores avaliaram a metodologia sob diferentes níveis de tensões de alimentação das máquinas.

No artigo de Sadeghi *et al.* (2019), foi apresentada uma nova abordagem para detecção de curto-circuito de estator de MITs baseada em variações da frequência instantânea dos sinais de corrente. Essa metodologia emprega a decomposição de modo empírico, do inglês *empirical mode decomposition* (EMD), aos sinais da máquina, o que

permite o cálculo das funções do modo intrínseco, do inglês *intrinsic mode functions* (IMF), desses sinais. Assim, as assinaturas características das falhas são destacadas, possibilitando a detecção da condição real da máquina. Nos ensaios experimentais, os autores avaliaram diversos níveis de curto-circuito, bem como diferentes níveis de carga. No entanto, não ficou evidenciado no manuscrito se o motor esteve sujeito a desequilíbrios de tensão.

Recentemente, o trabalho de Vinayak *et al.* (2020) propôs uma metodologia alternativa para o monitoramento em tempo real de curto-circuito entre espiras do estator em MITs alimentados por inversores de frequência. A abordagem emprega a análise de multi-resolução baseada na TWD nos sinais de correntes do estator do motor, com o intuito de selecionar os parâmetros estatísticos necessários para a detecção de falhas. Tais parâmetros são utilizados como dados de entrada para o classificador SVM identificar a real condição da máquina. Nos ensaios experimentais foram simuladas diversas condições de operação, como variações no conjugado de carga e nos níveis de frequência de alimentação.

As abordagens baseadas no modelo buscam prever os comportamentos das condições de defeitos por meio da modelagem matemática dos sinais da máquina. A principal desvantagem desta metodologia pode estar relacionada ao desgaste natural da máquina, pois a degradação dos componentes da máquina acarreta na ampliação da diferença entre a máquina e seu modelo matemático. Além disso, é indispensável que os parâmetros da máquina estejam disponíveis, o que nem sempre ocorre, tornando o diagnóstico mais difícil, pois há a necessidade de estimá-los para a correta modelagem da máquina (ALI *et al.*, 2019; SABOURI *et al.*, 2020). Recentemente, alguns pesquisadores estão adotando essas abordagens para o diagnóstico de defeitos em MITs.

Em Sabouri *et al.* (2020), foi utilizado um modelo analítico flexível do MIT, que possibilitou a inclusão de defeitos nas barras quebradas de rotor e no curto-circuito de estator. Além do uso do modelo do MIT, a técnica não-invasiva proposta é baseada no algoritmo de otimização por enxame de partículas, do inglês *Particle Swarm Optimization* (PSO), e nos fenômenos de oscilação pendulares, do inglês *Pendulous Oscillation Phenomenons* (POP), do campo magnético rotativo produzido pelas falhas. Embora apresente uma diferença entre os resultados de simulação e experimentais,



a metodologia demonstrou desempenho adequado frente às diversas condições de operação do ambiente industrial.

Já em Guedes *et al.* (2019), os autores apresentaram uma metodologia baseada no algoritmo de Evolução Diferencial, do termo inglês *Differential Evolution* (DE), para a identificação de falhas de curto-circuito de estator em MITs conectados diretamente à rede elétrica, por meio dos sinais de tensão e corrente no domínio do tempo. O algoritmo DE é utilizado na estimação dos parâmetros elétricos do motor de indução, a partir do modelo do circuito elétrico equivalente. A identificação da falha ocorre por meio do cálculo da variação da indutância de magnetização estimada com o motor sem falhas. Nos ensaios experimentais, foram obtidas acurácias de classificação acima de 90% mesmo com as máquinas operando em diversas condições de operação, tais como variações no conjugado de carga e no desequilíbrio de alimentação.

No artigo de Ojaghi *et al.* (2018) também é proposto um modelo analítico para o monitoramento de condições de falhas de estator e barras quebradas de rotor em MITs acionados diretamente pela rede elétrica. A modelagem de múltiplos circuitos acoplados, do inglês *multiple coupled circuit modeling* (MCCM), foi aplicada para obter o modelo analítico proposto. A partir dos resultados experimentais foi possível observar que os componentes harmônicos dos espectros dos sinais de correntes são produzidos ou aumentados devido à ocorrência de ambas as falhas, permitindo o diagnóstico eficiente dos defeitos. Deve-se salientar que nos ensaios, as máquinas só estiveram sujeitas a variações no torque de carga. Não foi avaliado o comportamento da metodologia sob desequilíbrios da tensão de alimentação.

As metodologias baseadas na correntes são amplamente utilizadas por serem não-invasivas, evitando assim a utilização de sensores específicos. Entretanto, outras grandezas como os sinais magnéticos tem vantagens específicas que as tornam atraentes em certas aplicações (BARZEGARAN *et al.*, 2013; LAMIM *et al.*, 2014; MIRZAEVA *et al.*, 2017; IRHOUMAH *et al.*, 2018).

Barzegaran *et al.* (2013) descreveram uma metodologia para o monitoramento e detecção de curto-circuito entre as espiras dos enrolamentos de estator por meio do uso de sinais de irradiação do campo magnético, combinando o método de elementos finitos com as RNAs. No artigo de Lamim *et al.* (2014), por meio dos espectros do fluxo magnético, os autores identificaram falhas de estator em MITs sujeitos a

desbalanceamento em suas tensões de alimentação.

Já no trabalho de Mirzaeva *et al.* (2017), apresentou-se um sistema on-line de diagnóstico de falhas de estator e de rotor baseado em medições da densidade de fluxo do entreferro de um MIT. Tais medidas são obtidas por meio de sensores de fluxo de efeito Hall. O sistema proposto mostrou ser adequado para aplicações dinâmicas de MITs, pois apresentou ter alta sensibilidade a falhas, imunidade a ruído e tolerância a variações dinâmicas das condições do motor.

Recentemente, o monitoramento e diagnóstico de falhas de estator baseado nos fluxos de dispersão têm atraído o interesse dos pesquisadores. Essas metodologias tem como características ser não-invasivas e de relativa facilidade de implementação. No artigo de Irhoumah *et al.* (2018) é proposto um método de diagnóstico que explora as medidas do fluxo de dispersão fornecidas por sensores de fluxo externos simples e de baixo custo colocados nas proximidades do MIT, a fim de detectar um curto-circuito entre as espiras de estator. Os resultados experimentais demonstram a satisfatória acurácia da metodologia no diagnóstico dessas falhas. No entanto, não foi descrito de forma clara no artigo se os autores utilizaram defeitos incipientes de curto-circuito de estator.

Por outro lado, Surya *et al.* (2017) utilizou os sinais de tensão (força eletromotriz induzida) do MITs para a detecção de curto-circuito entre as espiras do estator. Os autores analisaram os espectros dos sinais de tensão obtidos por meio de observadores instalados nas bobinas dos MITs. O comportamento dos observadores é semelhante ao do secundário de um transformador, onde a bobina do estator corresponde ao primário do transformador. O curto-circuito em qualquer local ao longo do enrolamento do estator, leva a uma mudança nas espiras do estator, bem como no fluxo de dispersão do estator. Além disso, produz uma variação na força eletromotriz nos observadores instalados nas bobinas, que é utilizada para a identificação do curto-circuito do estator.

Essa metodologia proposta por Surya *et al.* (2017) mostrou-se capaz de identificar a bobina de estator defeituosa. Ainda, comparando os resultados experimentais obtidos com as técnicas convencionais que empregam os sinais de corrente e o fluxo de dispersão, verifica-se a eficácia da nova ferramenta proposta frente as mesmas. Entretanto, a dificuldade dessa abordagem está na implementação, tendo em vista que os observadores das bobinas são sensores invasivos, os quais podem ser colocados

convenientemente durante a fabricação de novos motores ou durante o processo de manutenção das máquinas.

Além do uso de informações extraídas de sinais de tensão e fluxo de dispersão, abordagens baseadas na análise de assinatura de corrente do motor tornam-se vantajosas quando comparadas com outras metodologias, principalmente, às invasivas.

Como no monitoramento e no diagnóstico de barras quebradas de rotor, alguns autores estão apresentando metodologias baseadas em análises dos sinais da corrente de linha no domínio do tempo obtidos por sensores não-invasivos de baixo custo associadas com sistemas inteligentes para a classificação dos padrões de falhas. Godoy *et al.* (2015) busca estratégias alternativas às convencionais baseadas no monitoramento das amplitudes dos sinais das correntes, utilizando diretamente um semiciclo da forma de onda para a classificação de falhas no enrolamento de estator dos MITs acionados por três modelos distintos de inversores de frequência. Já em Palácios *et al.* (2015), os autores avaliam diversas técnicas de classificação de padrões, como *Naive Bayes*, *k-NN*, SVM, RNA e AD, para a identificação desse mesmo defeito em MITs alimentados diretamente pela rede elétrica.

No artigo de Guedes *et al.* (2016), foi proposta uma metodologia alternativa para avaliação da condição de isolamento do motor baseado no perfil da resistência de isolamento do condutor, do inglês *insulation resistance profile* (IRP). A metodologia emprega o algoritmo *k-means* para auxiliar no agrupamento (*clustering*) dos padrões de perfis de resistência de isolamento similares. Após, as RNAs são utilizadas para classificarem as condições de operação do motor.

Haroun *et al.* (2018) apresentaram uma abordagem para o diagnóstico de falhas de estator em MITs baseada em múltiplas análises de assinaturas extraídas dos sinais de corrente no domínio do tempo e da frequência. Inicialmente, o método emprega a transformada Park, a detecção de passagem por zero e os envelopes para a extração das características dos sinais da máquina. Em seguida, três técnicas diferentes de seleção de características são utilizadas para a seleção dos atributos mais adequados. Tais técnicas são o algoritmo ReliefF, a técnica de redundância mínima e relevância máxima, e a SVM baseada na eliminação recursiva de características. Por fim, a classificação dos padrões é realizada por meio de redes neurais com mapas auto-organizáveis, do inglês *self-organized maps* (SOM). Taxas de classificação em

torno de 94% obtidas nos ensaios experimentais, mesmo com a máquina submetida a diversas condições de operação, como variações nos níveis de carga e de curto-circuito de estator, além de tensões desequilibradas, validam a metodologia proposta.

Recentemente, o trabalho de Wang *et al.* (2019a) propôs um sistema de diagnóstico de falhas de estator em MITs baseado em *deep auto-encoder* (AE) e classificador *softmax*. Com a utilização da rede neural profunda, houve um aumento da qualidade dos atributos extraídos dos sinais de corrente da máquina. A acurácia dos testes superior a 99% demonstram a capacidade do sistema na identificação de falhas de estator em MITs.

Os trabalhos apresentados nessa seção revelam a importância do adequado diagnóstico das falhas elétricas e mecânicas dos MITs em suas aplicações, evitando assim uma parada indesejada no processo e reduzindo os custos com manutenção.

## 2.4 CONCLUSÃO DO CAPÍTULO

Neste capítulo foram apresentadas algumas metodologias para detecção de falhas de rolamentos, barras quebradas de rotor e enrolamento do estator em motores de indução. Estas falhas totalizam em torno de 90% do montante de paradas não programadas dos MITs principalmente no setor industrial. Por meio da revisão da literatura, conclui-se que, recentemente, boa parte dos pesquisadores estão adotando metodologias para o diagnóstico e identificação de falhas baseadas em técnicas para a extração de características dos sinais e sistemas inteligentes para a classificação de padrões. Ainda, verifica-se o aumento da busca por métodos que utilizam sensores não-invasivos e de baixo custo, possibilitando o adequado funcionamento e uma operação confiável das máquinas.

Assim, neste trabalho, são analisados os sinais de corrente de linha da máquina no domínio do tempo, utilizando medidas de informação mútua para a extração das características e algoritmos inteligentes para a classificação das amostras. O próximo capítulo descreve os aspectos associados as ferramentas utilizadas neste sistema proposto.

### 3 ESTRATÉGIAS PARA O MONITORAMENTO E DIAGNÓSTICO DE FALHAS

#### 3.1 INTRODUÇÃO

Diversos autores estão apresentando metodologias para o diagnóstico e identificação dos defeitos em máquinas elétricas, buscando detectar os mesmos em estágios incipientes para que falhas mais significativas não venham a ocorrer, acarretando assim em prejuízos ao processo industrial (BELLINI *et al.*, 2008; BOUZID; CHAMPENOIS, 2013; SILVA *et al.*, 2013; ANTONINO-DAVIU *et al.*, 2013; DEVI *et al.*, 2015; FROSINI *et al.*, 2015; TRACHI *et al.*, 2016; BOUDINAR *et al.*, 2016; TRACHI *et al.*, 2017; SINGH; KUMAR, 2017; LEITE *et al.*, 2015; ELBOUCHIKHI *et al.*, 2016; PRUDHOM *et al.*, 2017; DELGADO-ARREDONDO *et al.*, 2017; SURYA *et al.*, 2017; ABDALLAH; BENATMAN, 2017; GUEDES *et al.*, 2016; BESSAM *et al.*, 2016; GYFTAKIS *et al.*, 2016; HOU *et al.*, 2016; GODOY *et al.*, 2016; MOUSSA *et al.*, 2017; GARCÍA-ESCUDERO *et al.*, 2017; GARCIA-CALVA *et al.*, 2017; MARTINEZ *et al.*, 2017; SOUSA *et al.*, 2017; SAMANTA *et al.*, 2018; ROMERO-TRONCOSO *et al.*, 2016; MALEK *et al.*, 2017; PALÁCIOS *et al.*, 2016; NAYANA; GEETHANJALI, 2017; JERKAN *et al.*, 2017; IRHOUMAH *et al.*, 2018; BERZOY *et al.*, 2018; DEHGHAN *et al.*, 2018; DIAS; PEREIRA, 2018; TRUJILLO-GUAJARDO *et al.*, 2018; APPANA *et al.*, 2018; ALI *et al.*, 2019; CONTRERAS-HERNANDEZ *et al.*, 2019; DENG *et al.*, 2019; JIANG *et al.*, 2019; LIBONI *et al.*, 2019; STIEF *et al.*, 2019; WANG *et al.*, 2019b; ALI *et al.*, 2020; GANGSAR; TIWARI, 2020; NAYANA; GEETHANJALI, 2020; SABOURI *et al.*, 2020; SHAO *et al.*, 2020; VINAYAK *et al.*, 2020; XUE *et al.*, 2020; ZHAO; WANG, 2019). A identificação das falhas, bem como a determinação das prováveis causas e dos efeitos das ocorrências das mesmas sintetizam os processos de monitoramento e diagnóstico (SEERA; LIM, 2014; GODOY, 2016).

Neste trabalho, com o intuito de apresentar uma metodologia alternativa para o monitoramento e o diagnóstico de múltiplas falhas em MITs independente do tipo de alimentação adotado, verifica-se qual classificador de padrões inteligente MLP,  $k$ -NN e SVM que melhor adapta-se as medidas de associação entre as correntes das fases A e B obtidas pela ferramenta de extração de características MI. Nos ensaios experimentais, os MITs estão sujeitos a diversas situações de operações comuns

aos ambientes industriais como variação do conjugado de carga e do desequilíbrio de tensão de alimentação, além de uma ampla faixa de frequência de alimentação. Avaliam-se as estratégias de classificação de padrões com os mesmos conjuntos de dados provenientes dos ensaios experimentais, com o propósito de caracterizar em falhas de rolamentos, barras quebradas de rotor e curto-circuito entre as espiras do estator dos MITs operando em regime permanente.

Assim, neste capítulo são abordadas as principais ferramentas utilizadas na estratégia proposta para o reconhecimento de padrões de múltiplas falhas em MITs independente de sua alimentação. Descrevem-se os aspectos gerais relacionados à teoria da informação mútua empregada na etapa de processamento dos sinais, bem como aos algoritmos inteligentes MLP,  $k$ -NN e SVM utilizados para a classificação de padrões.

### 3.2 TEORIA DA INFORMAÇÃO EMPREGADA NA EXTRAÇÃO DE CARACTERÍSTICAS DOS SINAIS DE CORRENTES DOS MITS

Esta seção apresenta os aspectos da informação mútua, bem como seus modelos matemáticos envolvidos, empregados na etapa de extração de características. Assim, obtêm-se os padrões dos sinais sem defeitos e com defeitos de rolamentos, barras quebradas de rotor e curto-circuito do estator das máquinas de indução trifásicas.

Os avanços obtidos na tecnologia como em dispositivos de coleta e armazenamento de dados, têm resultado em um rápido aumento na quantidade dos dados disponíveis. Tendo isso em vista, os pesquisadores estão investigando ferramentas capazes de extraírem as informações úteis e necessárias a partir desta vasta quantidade de dados.

As técnicas da IT são aplicadas em estudos e problemas relacionados à área de reconhecimento de padrões, pois tem como uma de suas finalidades identificar medidas de associação ou conectividade entre sinais e séries temporais e variáveis relevantes, além da aplicabilidade em métodos de classificação (FAIZ *et al.*, 2010; ROMERO-TRONCOSO *et al.*, 2011; LI *et al.*, 2011; LEIVA-MURILLO; ARTÉS-RODRÍGUEZ, 2012; SILJAK *et al.*, 2018; KUMAR *et al.*, 2021). Isto tornou-se possível com a introdução de dois conceitos definidos por Shannon: a entropia e a informação mútua (COVER; THOMAS, 2006). A entropia é definida como uma medida de incerteza de variáveis

aleatórias isoladas ou combinadas. A informação mútua, por sua vez, consiste na medida de dependência estocástica entre estas variáveis, quantificando a informação comum e a medida de associação entre elas.

Shannon define a Entropia ( $H$ ) de uma variável aleatória discreta  $X$ , em *bits*, por meio da Equação (1) (COVER; THOMAS, 2006).

$$H(X) = - \sum_{x \in \chi} p_X(x) \log_2 p(x) \quad (1)$$

onde o alfabeto de eventos da variável aleatória  $X$  é  $\chi$  e a função distribuição de probabilidade, do termo inglês *probability density function* (PDF), associada a esta variável é  $p(x)$ . É importante salientar que ao utilizar o logaritmo na base 2 para o cálculo da entropia, essa grandeza é medida em *bits*. Contudo, quando utiliza-se a base neperiana, a entropia é dada em *nats*.

Na literatura são encontrados diversos autores que utilizaram a entropia como ferramenta para a extração de características dos sinais combinada com classificadores inteligentes para o monitoramento e identificação de defeitos em máquinas elétricas (ZHANG *et al.*, 2010; ZHU *et al.*, 2014; VERMA *et al.*, 2014; SCHMITT *et al.*, 2013; SCHMITT *et al.*, 2015; ZHENG *et al.*, 2018).

A MI é muito empregada na área de sistemas biológicos, para o reconhecimento de padrões, principalmente de imagens (LOECKX *et al.*, 2010; ONG; SEGHOUANE, 2011; MELIA *et al.*, 2015). Tal grandeza pode ser determinada por meio do cálculo da entropia entre duas variáveis aleatórias,  $H(X)$  e  $H(Y)$ .

Além de sua ampla utilização em sistemas biológicos, atualmente, alguns autores passaram a usar a MI como ferramenta de extração de características do conjunto de dados para o diagnóstico de falhas em máquinas elétricas, como pode ser observado em Faiz *et al.* (2010), Li *et al.* (2011), Romero-Troncoso *et al.* (2011), Siljak *et al.* (2018) e Kumar *et al.* (2021).

Segundo Cover e Thomas (2006), a MI é uma medida que permite determinar a informação compartilhada entre duas variáveis por meio das medidas de incerteza dadas pelas entropias condicionais destas mesmas variáveis, indicando assim a diminuição no nível de incerteza relacionado a uma variável aleatória baseada na informação

trazida por outra variável. Portanto, pode-se definir a MI pela Equação (2).

$$I(X,Y) = H(X) - H(X|Y) = H(Y) - H(Y|X) \quad (2)$$

onde  $H(X|Y)$  e  $H(Y|X)$  são as entropias condicionais de  $X$  dado  $Y$  e de  $Y$  dado  $X$ , respectivamente.

Esta medida descreve a associação entre séries temporais coletadas simultaneamente a partir de um sistema em estudo (NICHOLS, 2006; ALONSO *et al.*, 2007; MELIA *et al.*, 2015). Assim, ao aplicar esta ferramenta em sinais de máquinas elétricas, quantifica-se a associação entre as variáveis, permitindo assim, o eficiente monitoramento das condições de operação da máquina. A Equação (3) demonstra como é determinada esta medida, utilizando as funções densidade de probabilidade dos sinais em estudo.

$$I(X,Y) = \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x,y) \log_2 \frac{p(x,y)}{p(x) \cdot p(y)} \quad (3)$$

onde  $X$  e  $Y$  são as variáveis aleatórias;  $p(x)$  e  $p(y)$  são as PDFs marginais de  $x$  e  $y$ , respectivamente; e  $p(x,y)$  é a PDF conjunta entre estas duas variáveis  $x$  e  $y$ .

Considerando a dificuldade na obtenção das funções de transferência e modelos de um sistema, o emprego de medidas de associação por meio da MI se apresenta como uma satisfatória alternativa para determinar as relações de causalidade dos sinais em estudo, sem a necessidade de uma função de transferência ou de um modelo. Assim, pode-se denominar as aplicações com a MI como *model-free* (ENDO, 2014; ENDO *et al.*, 2015; BAZAN, 2016).

Nesse trabalho, os sinais analisados são as correntes das fases A e B dos MITs, as quais estão defasados 120 graus elétricos entre si, tornando-se assim necessário utilizar uma outra variação da MI, conhecida como informação mútua atrasada, do inglês *Delayed Mutual Information* (DMI), que é capaz de estimar a associação entre as variáveis aleatórias em função de um deslocamento de tempo,  $\tau$  (NICHOLS, 2006; ALONSO *et al.*, 2007; MELIA *et al.*, 2015). A DMI é definida pela Equação (4).

$$I(X,Y^\tau) = \sum_{x_n \in \mathcal{X}} \sum_{y_{n-\tau} \in \mathcal{Y}} p(x_n, y_{n-\tau}) \log_2 \frac{p(x_n, y_{n-\tau})}{p(x_n) \cdot p(y_{n-\tau})} \quad (4)$$



onde  $X$  e  $Y$  podem ser definidos como processos estocásticos, sendo  $X = (x_1, x_2, \dots, x_n)$  e  $Y^\tau = (y_{1-\tau}, y_{2-\tau}, \dots, y_{n-\tau})$  variáveis aleatórias. Ainda,  $p(x_n)$  e  $p(y_{n-\tau})$  são as PDFs marginais de  $X$  e  $Y^\tau$ , respectivamente, e  $p(x_n, y_{n-\tau})$  é a PDF conjunta em função do tempo de atraso,  $\tau$ .

Para os conceitos fundamentais da IT, o  $\tau$  é definido como o atraso da informação transmitida entre dois sinais (MELIA *et al.*, 2015). Neste trabalho, o atraso no tempo,  $\tau$ , está associado ao deslocamento de amostras na obtenção da curva de atraso da MI. Assim, trata-se a DMI como um deslocamento da MI, objetivando analisar o atraso ou avanço no valor máximo da MI para as diversas condições de operação das máquinas.

A MI detecta as dependências estatísticas lineares e não-lineares entre as séries temporais. Já a DMI, busca detectar estas dependências em função do deslocamento de tempo  $\tau$ . Neste trabalho, são analisadas as séries temporais dos sinais das correntes das fases A e B do motor utilizando a informação mútua atrasada para detectar a medida de associação entre os referidos sinais. Além disso, busca-se verificar o atraso ou o avanço no seu valor máximo mediante a situação em que a máquina estiver operando; a saber: variação no nível de conjugado de carga, alteração no nível de desequilíbrio entre as tensões de alimentação, condição de falha mecânica ou elétrica e variação na frequência de alimentação.

Após a abordagem dos conceitos relacionados à etapa de extração de características, são descritos os aspectos gerais associados aos classificadores de padrões. Neste trabalho, utilizam-se a rede neural artificial MLP, o  $k$ -NN e o SVM, devido a ampla aplicação desses algoritmos inteligentes em pesquisas recentes, na área de mineração de dados, reconhecimento de padrões e identificação de falhas em máquinas elétricas (BARZEGARAN *et al.*, 2013; GODOY *et al.*, 2015; GODOY *et al.*, 2016; PALÁCIOS *et al.*, 2015; PALÁCIOS *et al.*, 2016; PRIETO *et al.*, 2013; SESHADRINATH *et al.*, 2014a; YAGAMI *et al.*, 2015; SEERA; LIM, 2014; PANDARAKONE *et al.*, 2017; BESSAM *et al.*, 2016; APPANA *et al.*, 2018; DIAS; PEREIRA, 2018; ALI *et al.*, 2019; DENG *et al.*, 2019; LIBONI *et al.*, 2019; WANG *et al.*, 2019a; ALI *et al.*, 2020; ZHANG *et al.*, 2020).

### 3.3 REDES NEURAIS ARTIFICIAIS APLICADAS NA CLASSIFICAÇÃO DE PADRÕES

As RNAs são modelos computacionais que têm grande aplicação nos problemas de engenharia, devido às suas características como a capacidade intrínseca de operação em paralelo e não necessitarem de conhecimento a priori de eventuais modelos matemáticos que descrevem o comportamento de determinada aplicação. Ainda, as RNAs podem ser caracterizados como um sistema inspirado no cérebro humano e sua habilidade em aprender a partir da experiência (HAYKIN, 2008; SILVA *et al.*, 2017).

Diversas topologias de RNAs podem ser construídas utilizando uma ou mais camadas neurais, dentre as quais pode-se citar a MLP. A rede neural artificial MLP tem como características principais: (i) ser composta ao menos de uma camada neural escondida, encontrada entre a camada de entrada e a camada neural de saída; e (ii) o fluxo de informações em sua estrutura segue especificamente um caminho, iniciando-se na camada neural de entrada e percorrendo, posteriormente, as camadas neurais intermediárias e a camada neural de saída, respectivamente. A Figura 2 exibe uma rede MLP com duas camadas intermediárias.

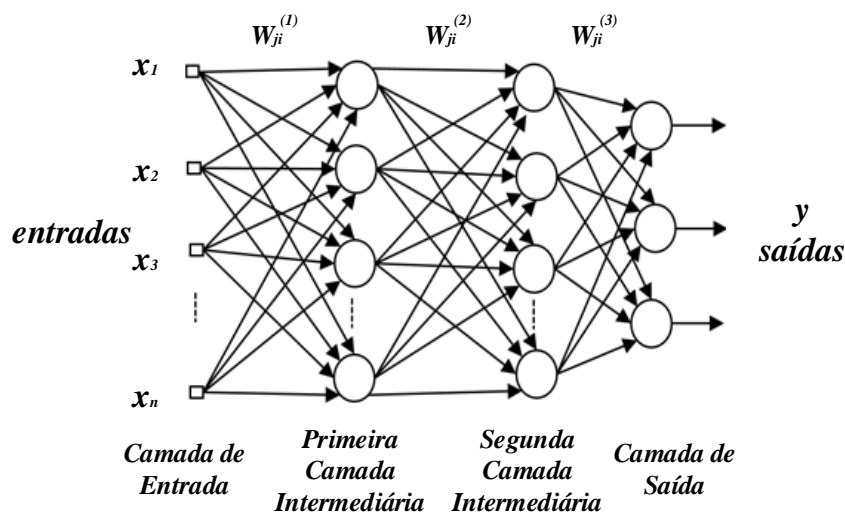


Figura 2 – Exemplo de uma rede neural artificial MLP com duas camadas escondidas

Fonte: Autoria Própria

A RNA MLP emprega o algoritmo *backpropagation*, que é dividido em dois estágios: *forward* e *backward*. No primeiro estágio conhecido por ser supervisionado, propagam-se os vetores de entrada de uma amostra do conjunto de treinamento, representados por  $x_1, x_2, x_3, \dots, x_n$ , camada a camada até a produção das suas respectivas

saídas, a fim de se obter as suas respostas. Nesta etapa, levam-se em consideração apenas os valores atuais dos pesos sinápticos e dos limiares dos neurônios. As respostas fornecidas pelas saídas da rede são comparadas com os seus respectivos valores desejados, gerando assim um desvio em função entre os valores atual e desejado. Após, utiliza-se esse desvio, no segundo estágio do algoritmo designado como *backward*, para ajustar os valores dos pesos sinápticos e dos limiares dos neurônios. Executando os dois estágios recursivamente, atualizam-se estes valores, de forma automática, em cada iteração do processo de treinamento, promovendo a diminuição progressiva da soma dos erros produzidos pelas respostas da rede frente aos seus respectivos valores desejados (HAYKIN, 2008; SILVA *et al.*, 2017).

As grandezas, erro quadrático ( $E(k)$ ) e erro quadrático médio ( $E_M$ ), determinam o desvio entre as respostas fornecidas pela camada neural de saída relativas aos respectivos valores desejados. O erro quadrático estabelece o desempenho local relacionado aos resultados produzidos pelos neurônios da camada de saída frente à referida amostra e o erro quadrático médio indica a evolução do desempenho global do algoritmo *backpropagation*, calculado pela soma dos erros quadráticos relativos a todos os padrões de entrada usados no treinamento da rede. Essas duas medidas são definidas pela Equação (5) e pela Equação (6), respectivamente.

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_s} (d_j(k) - Y_j(k))^2 \quad (5)$$

onde  $Y_j(k)$  é o valor fornecido pelo  $j$ -ésimo neurônio de saída da rede, considerando a  $k$ -ésima amostra de treinamento;  $d_j(k)$  é o valor da saída desejada do neurônio  $j$  em relação a  $k$ -ésima entrada e  $n_s$  é o número total de saídas da rede.

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (6)$$

onde o parâmetro  $p$  é o número de padrões de treinamento ou a quantidade de vetores de entrada.

Durante o processo de treinamento da rede, ao executar o algoritmo *backpropagation*, ajustam-se as matrizes de pesos  $W_{ji}^{(1,2,3)}$  da rede, com o objetivo de minimizar o erro quadrático médio,  $E_M$ . Pode-se observar esse processo detalhadamente em Haykin (2008) e Silva *et al.* (2017).

Neste trabalho, o classificador RNA MLP é utilizado para a identificação de falhas de rolamentos, barras quebradas de rotor e curto-circuito de estator em MITs acionados independentemente do tipo de alimentação, devido a sua comprovada aplicação em problemas relacionados a área de mineração de dados, reconhecimento de padrões e detecção de falhas elétricas (GHATE; DUDUL, 2010; GHATE; DUDUL, 2011; SEERA *et al.*, 2012; BARZEGARAN *et al.*, 2013; SEERA *et al.*, 2013; TRAN *et al.*, 2013; ZAREI *et al.*, 2014; GODOY *et al.*, 2015; PALÁCIOS *et al.*, 2015; GODOY *et al.*, 2016; PALÁCIOS *et al.*, 2016; BESSAM *et al.*, 2016; APPANA *et al.*, 2018; DIAS; PEREIRA, 2018; ZHANG *et al.*, 2020).

### 3.4 K-VIZINHOS MAIS PRÓXIMOS APLICADOS NA CLASSIFICAÇÃO DE PADRÕES

O classificador  $k$ -NN foi desenvolvido baseado no algoritmo dos  $k$ -vizinhos mais próximos, o qual é uma metodologia não-paramétrica fundamentada na análise da semelhança entre um determinado conjunto de validação com seu respectivo conjunto de treinamento (BISHOP, 2006; GODOY, 2016). Ainda, o algoritmo descreve o conjunto de treinamento em  $n$  atributos, onde cada amostra deve representar um ponto nesse espaço  $n$ -dimensional. Assim, armazenam-se todas as amostras do conjunto de treinamento em um espaço padrão  $n$ -dimensional. Para a classificação do conjunto de amostras desconhecido, o algoritmo  $k$ -NN procura nesse espaço padrão  $n$ -dimensional os  $k$  conjuntos mais próximos, conhecidos como  $k$ -vizinhos.

A metodologia  $k$ -NN identifica uma amostra de acordo com a sua distância em relação a certas amostras de treinamento pré-rotuladas, isto é, se grande parte das amostras mais próximas da amostra desconhecida for de uma determinada classe, essa classe será atribuída a esta amostra. Geralmente, para a determinação dessa proximidade adota-se o método da distância Euclidiana. Pode-se afirmar, ainda, que o  $k$ -NN é um classificador que possui apenas um parâmetro livre, sendo esse o número de  $k$ -vizinhos, que é controlado pelo usuário com o objetivo de obter uma melhor classificação (DUDA *et al.*, 2001; GODOY, 2016).

Em estudos recentes relacionados ao reconhecimento de defeitos em máquinas elétricas, alguns autores abordam o uso do método  $k$ -NN, como mostrado em Seshadrinath *et al.* (2014a), Godoy *et al.* (2015), Palácios *et al.* (2015), Godoy *et al.*

(2016), Palácios *et al.* (2016), Ali *et al.* (2019) e Ali *et al.* (2020).

### 3.5 MÁQUINA DE VETORES DE SUPORTE APLICADA NA CLASSIFICAÇÃO DE PADRÕES

As máquinas de vetor de suporte, desenvolvida por Vladimir Vapnik, são sistemas de aprendizagem de máquinas treinados com uma otimização de algoritmo matemático que implementa um limite derivado da teoria da aprendizagem estatística (PLATT, 1998). O processo de treinamento consiste em treinar um classificador de forma que este aprenda um mapeamento por meio dos exemplos de treinamento  $(x_i, y_i)$ , objetivando que a máquina seja capaz de classificar um  $(x, y)$  ainda não visto e que siga a mesma distribuição de probabilidade dos exemplos de treinamento. Assim, a tomada de decisões em problemas de classificação pode ser feita por meio de funções que usam hiperplanos para dividir o espaço das características das amostras em regiões.

No SVM, deve-se mapear os dados de treinamento em um espaço de características dimensionais maior utilizando a função Kernel, possibilitando assim a construção de um hiperplano separador com margem máxima do espaço de características. A otimização do SVM pode ser realizada por meio de uma programação quadrática, onde encontram-se os parâmetros necessários para a maximização da margem garantindo a satisfatória classificação das amostras. Deste modo, para encontrar o hiperplano de separação ideal, o SVM deve resolver o problema de otimização por meio das Equações (7) e (8).

$$\frac{\min \|\omega^2\|}{2} + C \sum_{i=1}^N \xi_i \quad (7)$$

$$\text{sujeito a: } \begin{cases} y_i(\omega^t \varphi(x_i) + b) \leq 1 - \xi_i \\ \xi \geq 0, i = 1, \dots, N \end{cases} \quad (8)$$

onde  $\omega$  é o vetor de pesos e  $b$  é o bias, sendo esses parâmetros responsáveis por controlar a função e a regra de decisão, assegurando que as amostras sejam bem classificadas;  $\xi \geq 0, i = 1, \dots, N$  são as variáveis de folga empregadas na redução do erro de classificação do conjunto de treinamento;  $C$  é o parâmetro de custo utilizado no ajuste da compensação entre a quantidade de erros aceitos e  $\varphi(\cdot)$  é a função

de transformação. O Multiplicador de Lagrange,  $\alpha_i$ , é empregado para a solução do problema de programação quadrática. Entretanto, a partir do mesmo um outro problema de otimização aparece, denominado dual, definido pelas equações (9) e (10).

$$\frac{\max \sum_{i=1}^N \alpha_i - (\sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j k(x_i, y_j))}{2} \quad (9)$$

$$\text{sujeito a: } \begin{cases} \sum_{i=1}^N \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq C, i = 1, \dots, N \end{cases} \quad (10)$$

Em problemas não-lineares, primeiro deve-se mapear os dados em um grande espaço de características dimensionais  $F$  por meio da função de transformação  $\varphi \rightarrow \varphi(x) \in F \subset \mathbb{R}^p$ , resultando na função de decisão definida pela Equação (11).

$$f(x) = \text{sign}\left(\sum_{\alpha_i > 0} \alpha_i y_i k(x, x_i) + b\right) \quad (11)$$

sendo  $k(x, x_i)$ , uma função Kernel de mapeamento entre a amostragem  $x$  e o vetor de suporte  $x_i$ .

Essencialmente, o SVM é caracterizado por ser um classificador de duas classes, o que fez que várias metodologias propusessem a combinação de múltiplos SVMs, com o intuito de construir um classificador multiclases (PLATT, 1998; BISHOP, 2006).

Para o treinamento do SVM, uma das possibilidades é a utilização do algoritmo de Otimização Mínima Sequencial, do inglês *Sequential Minimal Optimization* (SMO). Esse algoritmo emprega o conceito de segmentação para o limite externo considerando apenas dois multiplicadores de Lagrange por vez, podendo solucionar o problema analiticamente, não necessitando de uma programação quadrática (BISHOP, 2006).

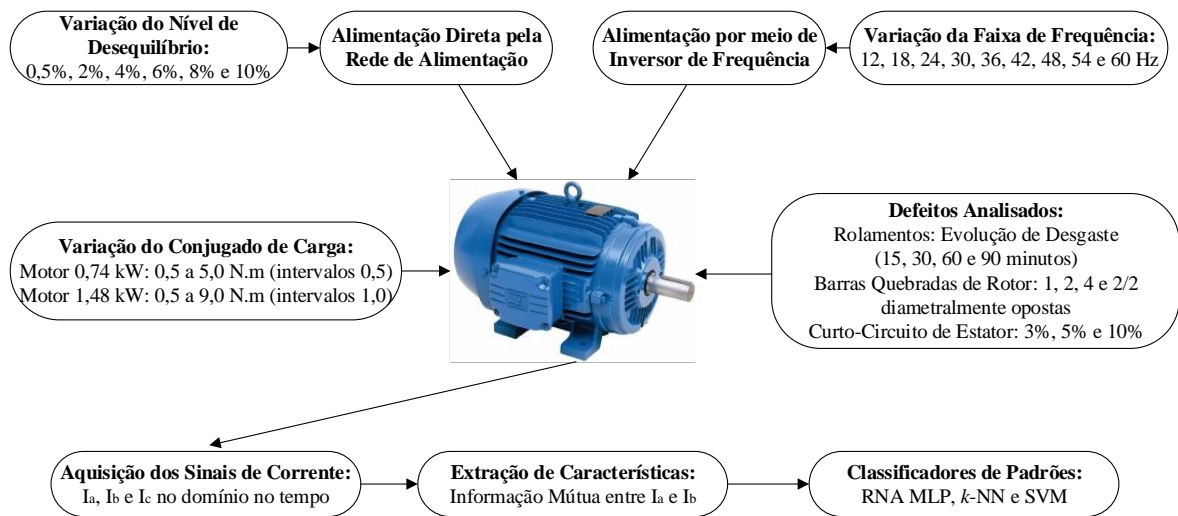
O SVM/SMO demonstrou ser uma ferramenta promissora para classificar defeitos em máquinas elétricas, conforme apresentado em Seshadrinath *et al.* (2014a), Yagami *et al.* (2015), Pandarakone *et al.* (2017), Ali *et al.* (2019), Liboni *et al.* (2019), Deng *et al.* (2019), Wang *et al.* (2019a) e Ali *et al.* (2020). Tendo isso em vista, neste trabalho utiliza-se essa técnica para a detecção de falhas de rolamentos, barras quebradas de rotor e curto-circuito do estator em motores de indução trifásicos independente do tipo de alimentação.

### 3.6 CONCLUSÃO DO CAPÍTULO

Neste capítulo foram apresentados os conceitos fundamentais relacionados às ferramentas utilizadas no modelo de reconhecimento de padrões aplicado na identificação de múltiplas falhas de motores de indução trifásicos independente de seu tipo de alimentação. Ainda, foram descritos os conceitos da informação mútua, a qual é responsável por extrair as características mais significativas dos sinais de correntes dos MITs, bem como dos classificadores inteligentes MLP  $k$ -NN e SVM utilizados para a identificação dos padrões obtidos por meio da ferramenta de extração de características. O próximo capítulo apresenta os aspectos gerais relativos ao desenvolvimento e implementação deste sistema proposto.

## 4 METODOLOGIA

Neste capítulo são descritos os principais elementos utilizados no processo de aquisição experimental dos dados para a implementação e validação do sistema de monitoramento e diagnósticos de múltiplas falhas em MITs alimentados tanto por fontes senoidais quanto por fontes não-senoidais. Ainda, são abordados os aspectos gerais relativos à criação e aquisição do conjunto de dados, bem como a descrição dos procedimentos para a extração de características dos sinais de correntes trifásicas de estator por meio da informação mútua, empregadas como dados de entrada dos classificadores de padrões RNA MLP,  $k$ -NN e SVM. A Figura 3 apresenta a organização geral de desenvolvimento da metodologia proposta, onde seus detalhes são discutidos ao longo deste capítulo.



**Figura 3 – Organização geral de desenvolvimento e implementação da metodologia proposta neste trabalho**

**Fonte: Autoria própria**

Por meio da Figura 3 é possível observar que nos ensaios experimentais são utilizados motores de distintas potências, onde os mesmos estão sujeitos a diversas condições de operação comuns aos ambientes industriais como variação nos níveis de conjugado de carga, desde a vazio (0,5 N.m) até a sobrecarga (5 N.m para 1 CV e 9 N.m para 2 CV); e variação nos níveis de severidade de defeitos de rolamentos, de barras quebradas de rotor e de curto-circuito de estator. Além disso, dependendo da forma de alimentação das máquinas, foram simuladas outras condições possíveis como variação




no desequilíbrio de tensão para uma alimentação direta pela rede ou na faixa de frequência quando as máquinas estão sendo alimentadas por inversores de frequência. Ao realizar esses ensaios, são coletados os sinais de correntes das máquinas, os quais serão utilizados para a extração das características por meio da informação mútua. Após, essas características extraídas serão classificadas pelos algoritmos inteligentes RNA MLP,  $k$ -NN e SVM. Ao longo desse capítulo, serão descritas com mais detalhes cada etapa dessa metodologia proposta para o monitoramento e o diagnóstico de múltiplas falhas em MITs independentemente do seu tipo de alimentação.

#### 4.1 ASPECTOS GERAIS RELACIONADOS AO CONJUNTO DE DADOS

O conjunto de dados experimentais utilizado nesse trabalho foi coletado no Laboratório de Sistemas Inteligentes (LSI) do Centro Integrado de Pesquisa em Controle e Automação (CIPECA) da Universidade Tecnológica Federal do Paraná (UTFPR), Campus Cornélio Procópio. Para a realização desses ensaios experimentais e a subsequente coleta do conjunto de dados, utilizou-se a bancada de ensaios do LSI, originalmente proposta por Goedel (2007) e também usada em diversos trabalhos como em Broniera *et al.* (2013), Santos *et al.* (2014), Palácios *et al.* (2014), Godoy *et al.* (2015), Palácios *et al.* (2015), Godoy *et al.* (2016), Gongora *et al.* (2016), Graciola *et al.* (2016), Palácios *et al.* (2016), Lopes *et al.* (2017), Bazan *et al.* (2017), Bazan *et al.* (2019), Guedes *et al.* (2019), Bazan *et al.* (2020), Bazan *et al.* (2020), entre outros trabalhos. Tal bancada foi idealizada para o acompanhamento de grandezas elétricas e mecânicas de MITs, como medidas de tensão, de corrente, de vibração, de torque e de velocidade. Além disso, essa estrutura permite a reprodução de várias situações de operação como variações na tensão de alimentação, na frequência de alimentação e no conjugado de carga, bem como defeitos de rolamentos, barras quebradas de rotor e curto-circuito do estator. A Figura 4 apresenta a bancada experimental de ensaios utilizada no trabalho.

Os variadores de tensão operam independentes por fase e permitem a mudança no nível de tensão na alimentação do MIT. O Gerador de Corrente Contínua (GCC) de 2 kW de potência, 250 V de tensão nominal de campo e 250 V de tensão nominal de armadura, é responsável por estabelecer o conjugado de carga resistente no eixo do MIT. Ainda, observa-se que a bancada dispõe de um torquímetro de dupla faixa



**Figura 4 – Bancada Experimental de Ensaios Experimentais do LSI - UTFPR**

**Fonte: Autoria própria**

de atuação com sensor de velocidade integrado. Esse torquímetro da marca *Kistler* é encarregado pela leitura dos sinais de torque e de velocidade até de 50 N.m e 7000 rpm, respectivamente.

As placas de condicionamento de sinais dos sensores Hall coletam individualmente os sinais de tensões e correntes da máquina que são transferidas às entradas analógicas da placa de aquisição de dados, DAQ USB-6221 da *National Instruments*. Por meio de uma interface de comunicação fornecida pela própria placa de aquisição de dados, as informações dos sinais são recebidas e armazenadas em um microcomputador em forma de planilhas. Em Goedtel (2007) está disponível uma descrição mais aprofundada da bancada experimental de ensaios.

A criação do banco de dados deu-se a partir de informações coletadas nos ensaios experimentais dos MITs operando em condições saudáveis e em condições de falhas de rolamentos, barras quebradas de rotor e curto-circuito entre as espiras do estator. Analisaram-se e coletaram-se as medidas mecânicas e elétricas disponíveis na bancada, tais como o torque, a velocidade, as tensões e as correntes. As especificações dos motores empregados no trabalho, bem como as condições de defeitos emuladas nos mesmos, são demonstradas na Tabela 1.

**Tabela 1 – Especificações dos Motores de Indução Trifásicos Utilizados no Trabalho**

Parâmetro	Motor 1	Motor 2
Fabricante	WEG	WEG
Modelo	Alto rendimento	Alto rendimento
Potência	0,74 kW	1,48 kW
Tensão de Alimentação ( $\Delta/Y$ )	220/380 V	220/380 V
Corrente de Alimentação ( $\Delta/Y$ )	3,02/1,75 A	5,98/3,46 A
Número de Fases	3	3
Frequência	60	60
Número de Polos	4	4
Velocidade Nominal	1730 rpm	1750 rpm
Conjugado Nominal	4,1 N.m	8,2 N.m
Fases Rebobinadas	3	3
Desgaste de Rolamentos	15, 30, 60 e 90 min	15, 30, 60 e 90 min
Número de Barras Quebradas de Rotor	1, 2, 4 e 2/2	1, 2, 4 e 2/2
Nível de Curto-Circuito	3, 5 e 10%	3, 5 e 10%

A base de dados experimentais consiste de 9194 testes realizados em um motor de 0.74 kW (Motor 1) e em um motor de 1.48 kW (Motor 2) operando em regime permanente, sob a alimentação direta e por meio de inversores de frequência, além de diversas condições de operação, todas estas comuns a um ambiente industrial. Este banco de dados baseia-se nos experimentos realizados nos trabalhos de Gongora (2013), Broniera (2014), Godoy (2016), Palácios (2016), Bazan (2016), Lopes (2016) e Guedes (2016).

Para os ensaios realizados a partir do motor conectado diretamente à rede, foram coletadas 2679 amostras, sendo que dividiu-se da seguinte forma: para o Motor 1 foram coletadas 1339 amostras variando o nível de conjugado de carga de 0,5 N.m à 5,0 N.m, em intervalos de 0,5 N.m, e desequilíbrio de tensão na fase A, de 0 a +10%, com intervalos de +2%, na fase B, de 0 a +10%, com intervalos de +2%, e na fase C, de 0 a -10%, com intervalos de -2%. Já no caso do Motor 2, foram coletadas 1340 amostras variando o nível de conjugado de carga de 0,5 N.m à 9,0 N.m, em intervalos de 1,0 N.m, e os mesmos desequilíbrios de tensão assimétricas do Motor 1. Essas condições descritas anteriormente, foram coletadas para cada tipo de defeito de rolamentos e de barras quebradas de rotor, bem como para cada nível de severidade dos defeitos. Especificamente para o caso em que os motores estiveram sujeito a curto-circuito de estator, o desequilíbrio de tensão na fase A adotado foi de 0 a -10%, com intervalos de -2%, na fase B, de 0 a +8%, com intervalos de +2%, e na fase C, de 0 a -8%, com intervalos de -2%.

Para os testes realizados a partir do motor alimentado por meio de inversores

de frequência, foram realizados 6515 experimentos; a saber: para o Motor 1, foram coletadas 3213 amostras, variando o nível de conjugado de carga de 0,5 N.m à 5,0 N.m, em intervalos de 0,5 N.m, e frequência de alimentação, de 20% à 100% do valor nominal, com intervalos de 10%. Já no caso do Motor 2, foram coletadas 3302 amostras variando o nível de conjugado de carga de 0,5 N.m à 9,0 N.m, em intervalos de 1,0 N.m, com a variação de frequência de alimentação igual ao do Motor 1. É importante destacar que a alimentação dos motores foram realizadas utilizando 3 inversores de frequência de modelos diferentes, tais quais são: Schneider Electric ATV12HU15M2 (ATV), Siemens Sinamics G110 (G110) e Siemens MicroMaster 440 (MM440). Como no caso da alimentação direta pela rede, as condições descritas anteriormente, foram coletadas para cada nível de severidade dos defeitos de rolamentos, barras quebradas de rotor e curto-circuito de estator. A Tabela 2 resume as características gerais das condições adotadas para a criação do banco de dados de defeitos usado neste trabalho.

**Tabela 2 – Número de amostras por classe de defeitos**

Motor	Condição	Alimentação Senoidal	Alimentação Não-Senoidal
Motor 1 (0,74 kW)	Sem defeito	110	250
	Desgaste de 15 min. de rolamentos	110	250
	Desgaste de 30 min. de rolamentos	110	250
	Desgaste de 60 min. de rolamentos	110	254
	Desgaste de 90 min. de rolamentos	110	254
Motor 2 (1,48 kW)	Sem defeito	110	238
	Desgaste de 15 min. de rolamentos	110	238
	Desgaste de 30 min. de rolamentos	110	238
	Desgaste de 60 min. de rolamentos	110	236
	Desgaste de 90 min. de rolamentos	110	236
Motor 1 (0,74 kW)	Sem defeitos	109	222
	1 barra quebrada de rotor	110	204
	2 barras quebradas de rotor	110	203
	4 barras quebradas de rotor	110	204
	2/2 barras quebradas de rotor	110	202
Motor 2 (1,48 kW)	Sem defeitos	110	238
	1 barra quebrada de rotor	110	239
	2 barras quebradas de rotor	110	234
	4 barras quebradas de rotor	110	232
	2/2 barras quebradas de rotor	110	233
Motor 1 (0,74 kW)	Sem defeito	60	250
	3% curto-circuito de estator	60	224
	5% curto-circuito de estator	60	223
	10% curto-circuito de estator	60	223
Motor 2 (1,48 kW)	Sem defeito	60	238
	3% curto-circuito de estator	60	234
	5% curto-circuito de estator	60	234
	10% curto-circuito de estator	60	234
Número total de aquisições por tipo de alimentação		2679	6515
Número total de aquisições		9194	

A fim de simular as condições de operação do MIT, um conjunto de dados experimentais foi criado por meio da aquisição dos sinais de torque, velocidade, tensões e correntes de dois MITs operando sem defeitos e com defeitos de rolamentos, barras quebradas e curto-circuito de estator, conforme a Tabela 2.

Com o intuito de emular os rolamentos com desgaste excessivo, foram reproduzidos defeitos desses desgastes para avaliar a similaridade do processo de degradação do rolamento por meio do seu uso excessivo, falta de lubrificação e carga excessiva no eixo. Após a limpeza do rolamento, a lubrificação foi substituída por uma pasta abrasiva usada para desgastar as peças e o motor entrou em funcionamento pelos tempos de 15, 30, 60 e 90 minutos para a degradação dos rolamentos com quatro níveis de severidade do desgaste abrasivo. Após este processo, os rolamentos foram limpos e lubrificados novamente para a aquisição adequada dos dados.

Para reproduzir os defeitos de barras quebradas do rotor, empregou-se uma técnica de perfuração das barras que constituem a gaiola de esquilo do rotor, a qual realiza-se utilizando uma broca (bit<sup>1</sup>) com diâmetro suficientemente maior do que as barras presentes no rotor. Ainda, com o intuito de emular esses defeitos são utilizados cinco rotores diferentes, onde as quebras são executadas de acordo com a sua sequência e também contra a circunferência do rotor, totalizando defeitos de uma a quatro barras quebradas.

Por fim, a reprodução do curto-circuito de estator baseou-se no procedimento de simulação de um defeito na isolação do enrolamento. Os enrolamentos de estator foram rebobinados, possibilitando construir diversas derivações. É importante salientar que as bobinas foram isoladas com verniz, respeitando sempre as medidas originais e a classe de isolamento do motor. Ainda, todas as três fases do enrolamento do estator foram preparadas para possibilitar emular defeitos de isolamento entre espiras, viabilizando a realização de ensaios experimentais com 3%, 5% e 10% de curto-circuito entre as espiras de estator. Os trabalhos de Godoy *et al.* (2015), Palácios *et al.* (2015), Godoy *et al.* (2016), Palácios *et al.* (2016) e Lopes *et al.* (2017) descrevem com mais detalhes como foram gerados os dados experimentais utilizados nesse trabalho.

A frequência de amostragem utilizada na coleta dos sinais variou-se de acordo

---

<sup>1</sup>De acordo com o Manual de Comunicação do Senado Federal. Disponível em: <<https://www12.senado.leg.br/manualdecomunicacao/redacao-e-estilo/estilo/estrangeirismos-grafados-sem-italico>>. Acesso em: 21/10/2020 às 14h.

com o tipo de alimentação, senoidal ou não-senoidal. Para os ensaios realizados por meio de uma alimentação direta, empregou-se uma taxa de amostragem de 15,0 kHz. Já nos ensaios em que os MITs foram acionados por meio de inversores de frequência, utilizou-se a taxa de amostragem de 25,0 kHz.

De acordo com a necessidade de cada processo, caracterizado principalmente pela dinâmica dos motores, bem como pelas variações das grandezas e condições de defeitos observadas, o tempo para a coleta de dados pode ser alterado. Assim, nesse trabalho, foram realizadas amostragens com intervalos de tempo de 5 e 6 segundos para os ensaios com rolamentos e barras quebradas de rotor realizados a partir de alimentação senoidal e não-senoidal, respectivamente. Já para os ensaios de curto-circuito de estator, as amostragens foram de 1,5 e 3 segundos para os ensaios com as máquinas acionadas diretamente pela rede e por meio de inversores de frequência, respectivamente. Tendo em vista que as grandezas foram coletadas com o motor já em regime permanente, o tempo de coleta de dados empregado em qualquer um dos casos é satisfatório para representar os sinais a serem processados sem sobrecarregar as aquisições com vetores de tamanhos excessivos.

A ferramenta de processamento de sinais utilizada na extração de características emprega apenas as correntes das fases A e B das máquinas. Assim, as outras variáveis não serão utilizadas no presente trabalho. Na próxima seção, demonstra-se como são extraídas as características dos sinais.

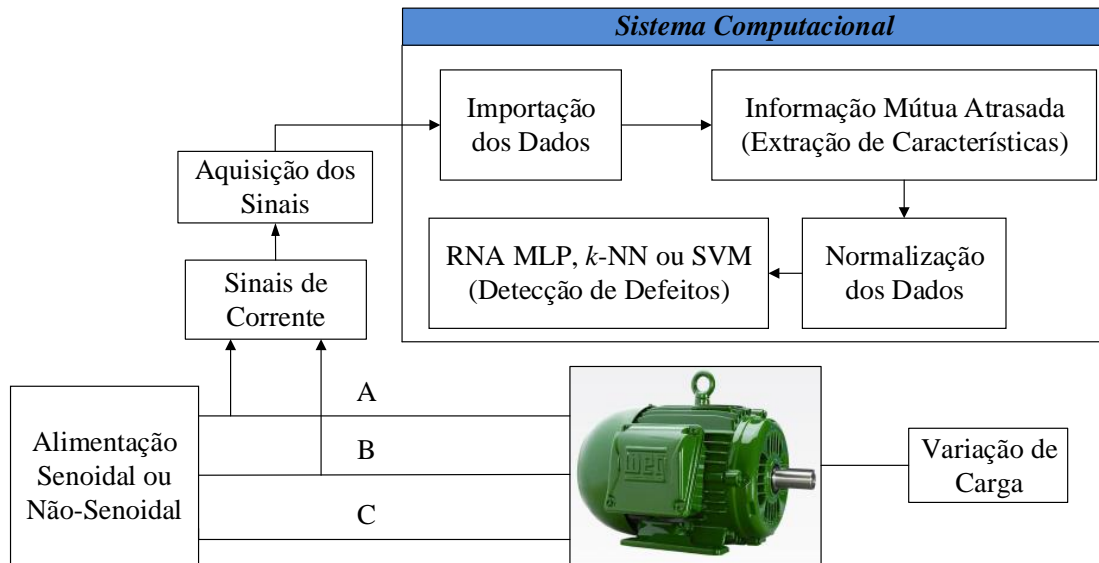
## 4.2 EXTRAÇÃO DE CARACTERÍSTICAS USANDO MEDIDAS DA INFORMAÇÃO MÚTUA

Por meio do uso de um algoritmo desenvolvido para o pré-processamento e aquisição de dados, o conjunto de sinais, descrito na Tabela 2, são processados e seus resultados avaliados no software<sup>1</sup> Matlab®. O objetivo desta etapa consiste em extrair as relevantes informações presentes nos dados, buscando assim simplificar o número de entradas do sistema de classificação. A Figura 5 apresenta o procedimento de aquisição, processamento de sinais e classificação utilizados neste trabalho.

Na referida figura, verifica-se que a abordagem proposta coleta os sinais de

---

<sup>1</sup>De acordo com o Manual de Comunicação do Senado Federal. Disponível em: <<https://www12.senado.leg.br/manualdecomunicacao/redacao-e-estilo/estilo/estrangeirismos-grafados-sem-italico>>. Acesso em: 21/10/2020 às 14h.




**Figura 5 – Diagrama de Blocos do Sistema Proposto para a Identificação de Defeitos em Motores de Indução Trifásicos**

**Fonte: Autoria própria**


correntes das fases A e B dos MITs independente da forma que ele são acionados. Tais dados são importados para um microcomputador, onde o algoritmo para o tratamento dos dados e para o cálculo da DMI foi desenvolvido no Matlab®. Esse algoritmo trabalha com os sinais das correntes das fases A e B do motor, bem como com o deslocamento de amostras  $\tau$ . A corrente  $i_b$  deve ser deslocada de 1 em 1 amostra até que se atinja o deslocamento em  $\tau$  pontos. Para cada iteração, calcula-se a MI a partir das PDFs marginais das correntes  $i_a$  e  $i_b$ , e da PDF conjunta entre estas duas correntes. Cada valor da MI calculado é, então, armazenado em uma matriz de dados. Estes passos são realizados recursivamente até que se obtenha a curva a partir do deslocamento total,  $\tau$ . Por fim, é encontrado a DMI do sinal em análise. A definição do deslocamento total de amostras,  $\tau$ , depende da frequência de amostragem na aquisição dos dados. Assim, utiliza-se, neste trabalho, o deslocamento de 150 pontos, pois observou-se que, com esta quantidade de pontos, as correntes estão em fase em pelo menos um ciclo, conforme Bazan *et al.* (2017), Bazan *et al.* (2019), Bazan *et al.* (2020) e Bazan *et al.* (2020). É importante também destacar que foram realizados testes preliminares com o deslocamento de 300 pontos, obtendo resultados levemente superiores do que com um deslocamento de 150 pontos. Entretanto, os testes com deslocamentos de 300 pontos dispendem de um tempo computacional maior, assim, com o objetivo de exigir um menor esforço de processamento, considerou-se apenas o deslocamento de 150 pontos. As Figuras 6 e 7 apresentam os sinais de correntes das fases A e B do Motor

1 e a curva da MI com o deslocamento de amostras  $\tau$  (*shifted samples*) para esses sinais de correntes em uma determinada condição de operação, respectivamente.



**Figura 6 – Sinais de Correntes das Fases A e B - Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas**

Fonte: Autoria própria




**Figura 7 – Curva da Informação Mútua - Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas**

Fonte: Autoria própria



Conforme demonstrado nas equações da Seção 3.2, para o cálculo da medida de associação entre os sinais de corrente é necessário encontrar as suas respectivas funções densidade de probabilidade. Tais funções podem ser obtidas utilizando os histogramas dos sinais a serem analisados, bem como por funções conhecidas como as gaussianas e estimadores de *Kernel*. Neste trabalho, as PDFs foram estimadas usando histogramas, dependendo apenas dos sinais, sem a utilização de parâmetros de aproximação. É importante ressaltar que as barras (*bins*) representam as ocorrências dos dados em faixas de intervalos específicos. Definiu-se um número fixo de 16 barras (*bins*), pois observou-se que com esse valor, é possível obter uma satisfatória representação dos sinais. Entretanto, segundo Shimazaki e Shinomoto (2007), podem ser encontradas em outras pesquisas diversas técnicas para a otimização do número de barras, onde cada técnica é utilizada de acordo com a sua aplicação. Um exemplo das funções densidade de probabilidade, marginais e conjunta, empregadas para o cálculo da medida da informação mútua podem ser visualizadas nas Figuras 8, 9 e 10.



**Figura 8 – Exemplo da PDF marginal da corrente  $i_a$  para o Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas**

**Fonte: Autoria própria**




Figura 9 – Exemplo da PDF marginal da corrente  $i_b$  para o Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas

Fonte: Autoria própria





Figura 10 – Exemplo da PDF conjunta das correntes,  $i_a$  e  $i_b$ , para o Motor 1 operando sem defeitos, com carga nominal e tensões de alimentação equilibradas

Fonte: Autoria própria

Ao encontrar as medidas da MI, com suas respectivas PDFs, para as amostras pertencentes ao banco de dados, observa-se que as curvas características são similares, independente da condição de operação dos motores. A fim de corroborar com esta afirmação, as Figuras 11 a 20 apresentam as curvas da MI para diversas situações de operação.


A Figura 11 apresenta a curva característica para o Motor 1 quando o mesmo está sendo alimentado diretamente pela rede, operando sem defeitos e sujeito a variações no seu conjugado de carga. Observa-se que o aumento no nível de conjugado de carga acarreta no acréscimo também do valor máximo da MI. É importante ressaltar que  $T_n$  é o conjugado nominal da máquina.



**Figura 11 – Variação no conjugado de carga - Motor 1 operando sem defeitos e com as tensões equilibradas**

**Fonte: Autoria própria**

A Figura 12 permite observar que a alteração no desequilíbrio negativo de tensão da fase A produz um atraso, já o desequilíbrio positivo de tensão na fase B juntamente com o desequilíbrio negativo na fase C ocasiona em um avanço em relação à curva com tensões equilibradas. Além disso, é importante observar que os valores máximos da MI diminuem em função do aumento do nível de desequilíbrio de tensão.



**Figura 12 – Variação no nível de desequilíbrio de tensão - Motor 1 operando sem defeitos e com carga nominal**

**Fonte: Autoria própria**

Ainda, o desequilíbrio positivo de tensão na fase A produz o avanço, bem como a diminuição nos valores máximo da MI, conforme apresenta-se na Figura 13.

As análises de variação de carga e desequilíbrio entre as tensões também podem ser visualizadas quando o motor está operando com defeitos, sejam falhas de rolamentos, barras quebradas de rotor ou curto-circuito de estator, não importando qual o nível de severidade do defeito.

Nas Figuras 14 e 15 são ilustradas as assinaturas características da MI em que o Motor 1 está operando com desgaste abrasivo de 15 minutos nos rolamentos. Quando esta máquina está sob variações no conjugado de carga nominal, observa-se, novamente, que o aumento no nível de conjugado de carga gera o aumento no valor máximo da MI, como exibe-se na Figura 14. Já a Figura 15 ilustra que a variação positiva na tensão de alimentação da fase A gera um avanço na curva, bem como uma redução no valor máximo da MI. Quando alteram-se os níveis de tensão nas fases B e C, observa-se o avanço em relação a curva em que as tensões do Motor 1 estão equilibradas, além da diminuição nos valores de pico das assinaturas da MI.

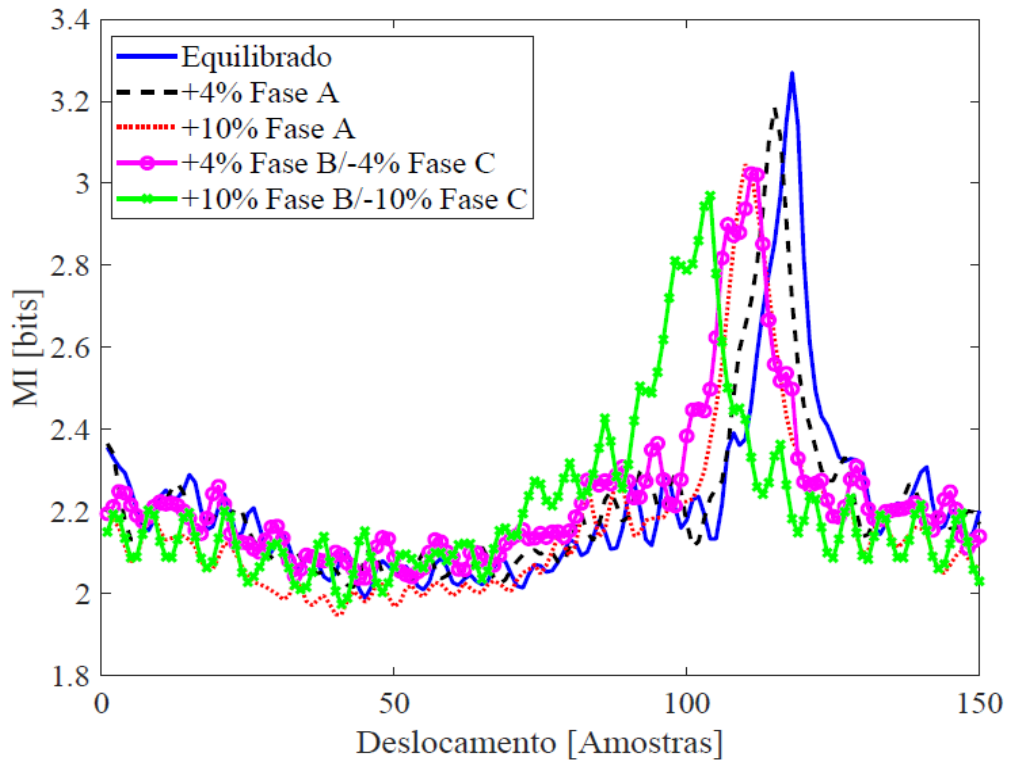


Figura 13 – Variação no nível de desequilíbrio de tensão - Motor 1 operando sem defeitos e com carga nominal

Fonte: Autoria própria





Figura 14 – Variação no conjugado de carga - Motor 1 operando com defeitos de rolamentos e tensões equilibradas

Fonte: Autoria própria



**Figura 15 – Variação no nível de desequilíbrio de tensão - Motor 1 operando com defeitos de rolamentos e carga nominal**

**Fonte: Autoria própria**

As Figuras 16 e 17 exibem as curvas da MI quando o Motor 1 está operando com uma barra quebrada de rotor. Ambas as curvas apresentam comportamento similar às análises observadas nas figuras anteriores, de variação no conjugado de carga e variação no desequilíbrio de tensão, independente se está apresentando defeitos.

Quando o Motor 1 está sujeito a curto-circuito de estator, as assinaturas características seguem comportamentos semelhantes às Figuras 11 e 12. Ao aumentar o nível de torque, o valor máximo da MI também aumenta, conforme apresenta-se na Figura 18. Já a Figura 19 demonstra o comportamento das curvas da MI para a situação em que os motores estão sujeitos a curto-circuito de estator e desequilíbrios de tensão. O desequilíbrio negativo na fase A produz o deslocamento da curva da MI à direita, já o desequilíbrio positivo na fase B aliado ao desequilíbrio negativo na fase C ocasiona o deslocamento à esquerda. Em ambos os casos há a diminuição nos valores máximos da MI à medida que há o aumento no desequilíbrio de tensão.




Figura 16 – Variação no conjugado de carga - Motor 1 operando com uma barra quebrada de rotor e tensões equilibradas

Fonte: Autoria própria

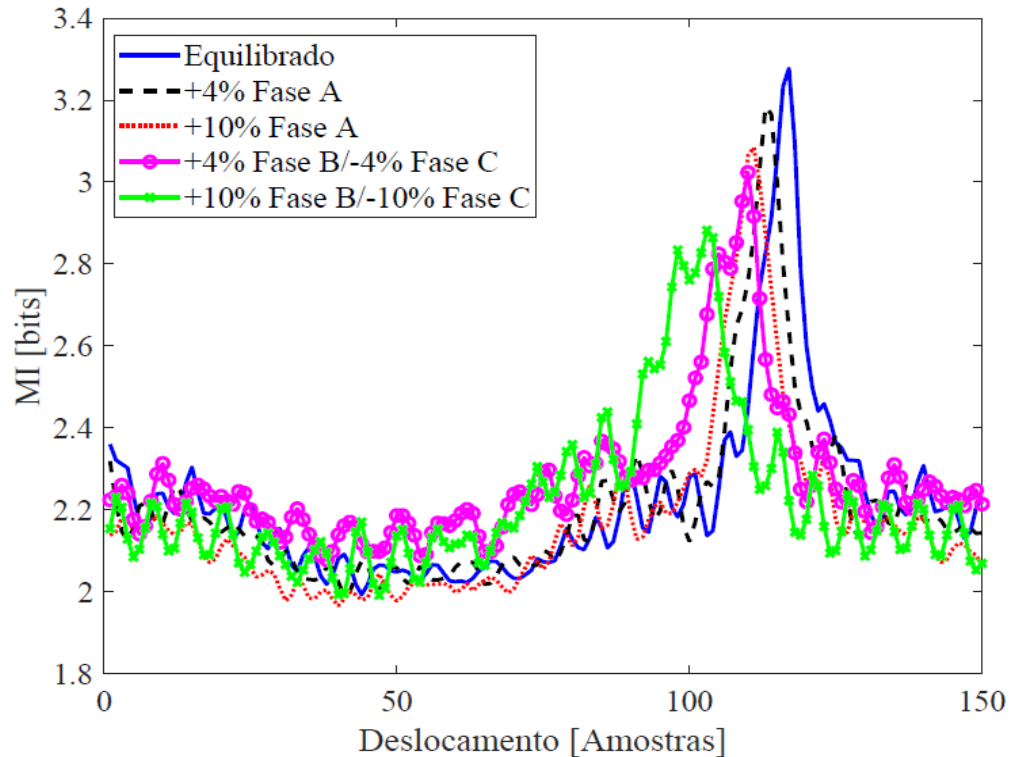


Figura 17 – Variação no nível de desequilíbrio de tensão - Motor 1 operando com uma barra quebrada de rotor e carga nominal

Fonte: Autoria própria

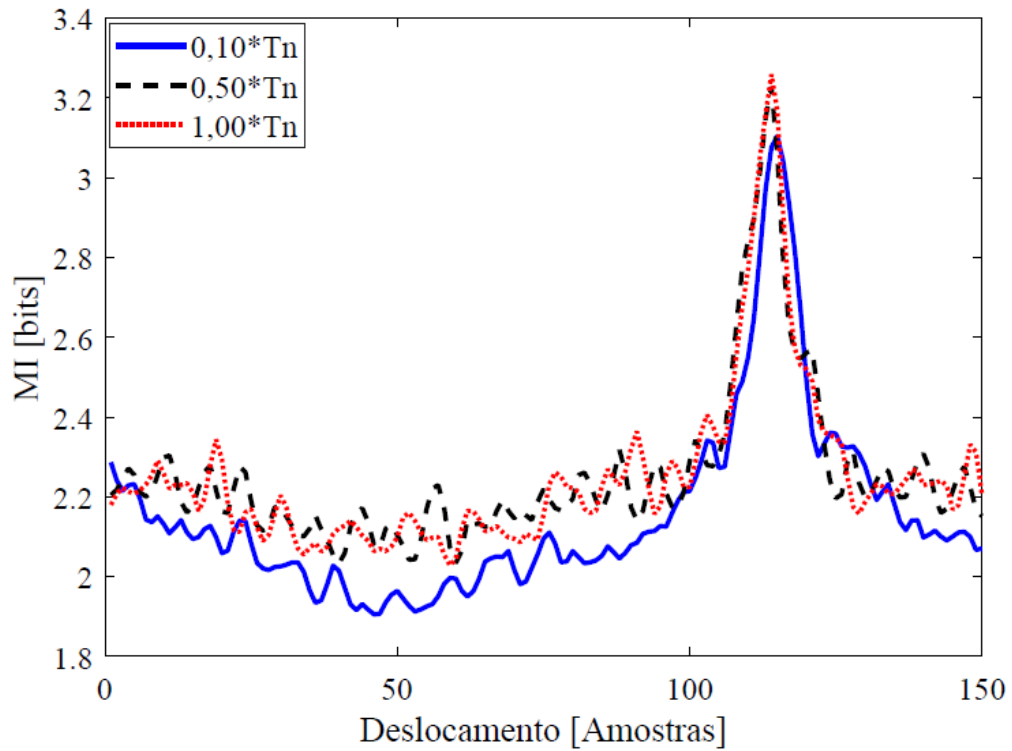


Figura 18 – Variação no conjugado de carga - Motor 1 operando com 3% de curto-circuito de estator e tensões equilibradas

Fonte: Autoria própria

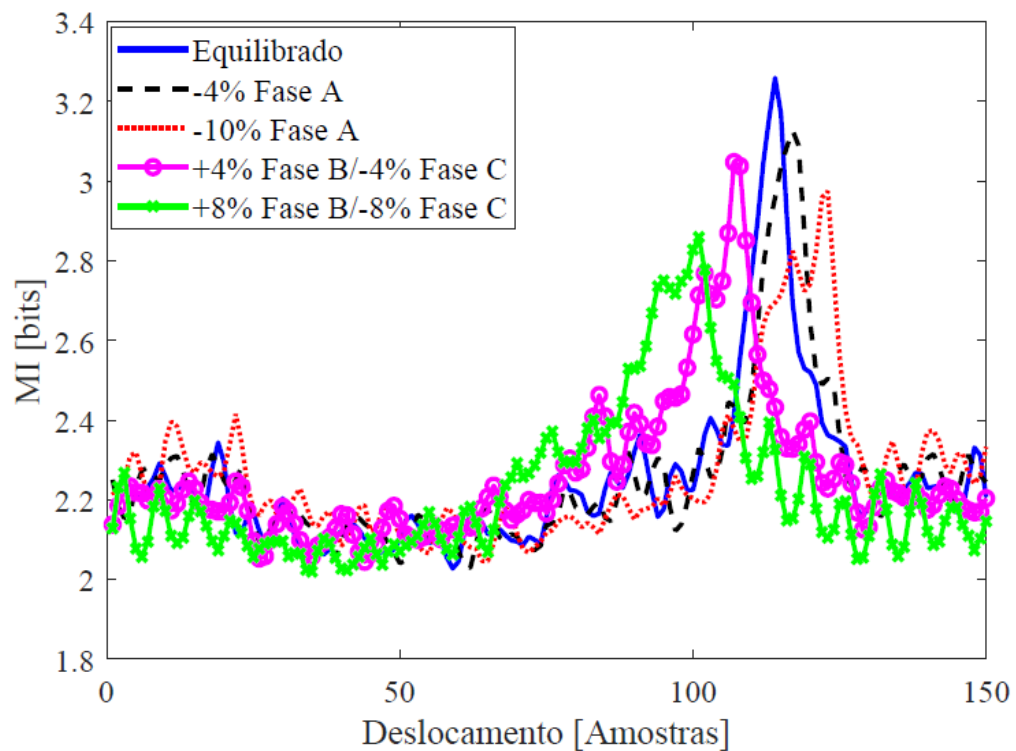



Figura 19 – Variação no nível de desequilíbrio de tensão - Motor 1 operando com 3% de curto-circuito de estator e carga nominal

Fonte: Autoria própria



Ao alimentar o Motor 1 por meio de fontes não-senoidais, isto é, por inversores de frequência, verifica-se que a variação na frequência de alimentação influencia no deslocamento das amostras. Com o aumento da frequência de alimentação, a curva da MI desloca-se à esquerda, ou seja, o aumento da frequência provoca o avanço na assinatura da MI. Possivelmente, isto deve-se as diferentes relações de frequência de alimentação versus<sup>1</sup> frequência de amostragem. A Figura 20 exhibe essa situação.



**Figura 20 – Variação no nível de frequência de alimentação - Motor 1 operando sem defeitos e com carga nominal**

**Fonte: Autoria própria**

É importante destacar que as análises descritas para o Motor 1 também podem ser realizadas para o Motor 2 em todas as situações, tais como as variações no conjugado de carga, no nível de desequilíbrio, na frequência de alimentação, nas severidades dos defeitos, bem como independentemente do tipo de alimentação.

Assim, obtém-se a curva da MI para todas as amostras pertencentes ao conjunto de dados, ou seja, para as amostras de ambos os motores. Após, deve-se normalizar os valores da MI em função do valor máximo da informação mútua ( $MI_{max}$ ) encontrado para todas as condições de operação. Desta forma, esses dados

<sup>1</sup>De acordo com o Manual de Comunicação do Senado Federal. Disponível em: <<https://www12.senado.leg.br/manualdecomunicacao/redacao-e-estilo/estilo/estrangeirismos-grafados-sem-italico>>. Acesso em: 21/10/2020 às 14h.

já normalizados irão constituir a matriz de dados de entrada do sistema de classificação de múltiplas falhas (rolamentos, barras quebradas de rotor e curto-circuito de estator) em MITs independente de seu tipo de alimentação. Os dados desta matriz são rotulados de acordo com a sua classe. No próximo capítulo, as classificações de defeitos são realizadas de forma individual. Assim, definiu-se que as amostras de sinais do motor saudável recebem uma *tag* de saída desejada igual a 0 e os sinais com defeitos, uma *tag* de saída desejada igual a 1.

### 4.3 IDENTIFICAÇÃO DE FALHAS USANDO SISTEMAS INTELIGENTES

Para a adequada identificação das falhas presentes em MITs, foram empregadas diferentes estratégias inteligentes, tais quais foram escolhidas devido a amplas aplicações em pesquisas recentes, na área de mineração de dados, reconhecimento de padrões e identificação de falhas em máquinas elétricas (GODOY *et al.*, 2015; GODOY *et al.*, 2016; PALÁCIOS *et al.*, 2015; PALÁCIOS *et al.*, 2016; LOPES *et al.*, 2017; GONGORA *et al.*, 2016; GUEDES *et al.*, 2016; BAZAN *et al.*, 2017; BAZAN *et al.*, 2019; BAZAN *et al.*, 2020; BAZAN *et al.*, 2020; PRIETO *et al.*, 2013; SESHADRINATH *et al.*, 2014a; YAGAMI *et al.*, 2015; SEERA; LIM, 2014; BESSAM *et al.*, 2016; PANDARAKONE *et al.*, 2017; APPANA *et al.*, 2018; DIAS; PEREIRA, 2018; ALI *et al.*, 2019; DENG *et al.*, 2019; LIBONI *et al.*, 2019; WANG *et al.*, 2019a; ALI *et al.*, 2020; ZHANG *et al.*, 2020).

O conjunto das amostras da matriz de entrada são, aleatoriamente, separadas, de forma a permitir que o conjunto de dados de treinamento seja representativo o suficiente em relação à base de dados na qual se deseja prever. Tendo isso em vista, neste estudo utiliza-se o método de validação cruzada de  $k$ -partições, com  $k = 10$ . O processo é realizado por  $k$  vezes, sendo que em cada iteração, 1 subconjunto é designado como conjunto de teste e os outros  $(k-1)$  subconjuntos restantes, designados como conjunto de treinamento. A cada iteração, a taxa de classificação incorreta do conjunto de teste é calculada, sendo que ao final, o desempenho é estimado pelo erro médio do classificador nos  $k$  testes realizados.

Para a classificação dos padrões associados aos sinais gerados por meio de ensaios experimentais, empregou-se o software WEKA. O referido software permite a resolução de problemas concretos de mineração de dados e classificação de padrões

por meio do conjunto de algoritmos que nele estão disponíveis, possibilitando assim treinar e testar diversas metodologias de classificação de forma interativa (HALL *et al.*, 2009).

Um parâmetro estatístico muito importante disponível no WEKA é o coeficiente Kappa, o qual é definido como a medida de associação utilizada para descrever ou testar o grau de concordância, confiabilidade e precisão, na identificação das amostras. A Tabela 3 apresenta as diferentes categorias do coeficiente Kappa de acordo com o grau de concordância sugerido pelo trabalho de Landis e Koch (1977).

**Tabela 3 – Categorias do coeficiente Kappa conforme Landis e Koch (1977)**

<i>Intervalos do Coeficiente Kappa</i>	<i>Nomenclatura Considerada</i>
<0	Nenhuma concordância
0 - 0,19	Pobre concordância
0,20 - 0,39	Fraca concordância
0,40 - 0,59	Moderada concordância
0,60 - 0,79	Substancial concordância
0,80 - 1,00	Perfeita concordância

Na classificação das falhas, todas as estratégias adotadas foram configuradas para o treinamento de forma supervisionada. Para a definição das características e dos parâmetros dos classificadores RNA MLP, *k*-NN e SVM foram realizados diversos ensaios com o intuito de encontrar as características e os valores mais adequados. Após estes ensaios, definiram-se as especificações de cada classificador como segue nos parágrafos abaixo.

Para a rede neural artificial MLP, empregou-se apenas uma camada intermediária de 25 neurônios, a taxa de aprendizagem para o treinamento de 0,3, o termo *momentum* de 0,2 e o número máximo de épocas para o treinamento de 500. São utilizadas as funções de ativação logística e linear para as camadas intermediária e de saída, respectivamente.

Na construção do modelo do classificador *k*-NN, utilizou-se apenas 1 *k*-vizinho e o método euclidiano para o cálculo da distância. Já os parâmetros básicos da metodologia SVM são a taxa de erro de arredondamento de  $1,0e^{-12}$ , o parâmetro de margem C que determina o ponto razoável entre a maximização da margem e a minimização do erro de 5,0, a "Polinomial Kernel" como função núcleo do classificador SVM e o erro do parâmetro de tolerância recebeu um valor de 0,001.

#### 4.4 CONCLUSÃO DO CAPÍTULO

Neste capítulo foram apresentados os aspectos gerais relacionados ao desenvolvimento e implementação da metodologia para o monitoramento e diagnóstico de múltiplas falhas em MITs. Foram descritas as particularidades relacionadas a bancada experimental de ensaios experimentais utilizada para a coleta e tratamento dos sinais, a metodologia para a extração de características relevantes dos sinais, bem como dos parâmetros usados nos algoritmos inteligentes de classificação. No capítulo 5, serão apresentados e discutidos os resultados obtidos a partir dos ensaios experimentais.

## 5 RESULTADOS EXPERIMENTAIS

Neste capítulo são descritos os principais resultados obtidos utilizando os algoritmos inteligentes RNA MLP,  $k$ -NN e SVM, treinados a partir das medidas de informação mútua dos sinais das correntes das fases A e B no domínio do tempo. As medidas são obtidas por meio de ensaios experimentais utilizando diferentes motores de indução trifásicos acionados pela rede de alimentação e por inversores de frequência.

No contexto desse trabalho, a abordagem proposta foi utilizada para o monitoramento e identificação de defeitos de rolamentos, barras quebradas de rotor e curto-circuito de estator em MITs. A classificação dos defeitos foram realizadas considerando estratégias de classificação simples, ou seja, motor sem defeito e motor com defeito. Neste trabalho não foi realizada a avaliação dos algoritmos funcionando como multiclassificadores de defeitos.

A alimentação dos MITs por meio de inversores de frequência pode provocar distorções nos sinais de tensão e corrente em virtude dos ruídos provenientes dos chaveamentos dos transistores de potência. Assim, no presente trabalho, faz-se necessária a utilização de um filtro FIR passa baixa como uma estratégia digital para a filtragem dos sinais, a qual é responsável em atenuar as referidas distorções dos sinais. A frequência de banda de rejeição desse filtro digital foi fixada em torno de 1500 Hz.

Na sequência, apresenta-se uma avaliação dos resultados de classificação obtidos pelos diversos algoritmos inteligentes estudados nesse trabalho. Como já descrito no Capítulo 4, os MITs foram sujeitos a diversas condições de operação, como uma variação do conjugado de carga de 10% à 120% do valor nominal, uma variação no desequilíbrio de tensão de até 10% e uma variação de frequência de 12 Hz à 60 Hz.

### 5.1 RESULTADOS EXPERIMENTAIS - DEFEITOS DE ROLAMENTOS

Nesta seção são apresentados os resultados obtidos pelos algoritmos inteligentes no monitoramento e identificação de defeitos de rolamentos utilizando como matriz de entrada as medidas de informação mútua das correntes das fases A e B dos MITs independente de seu tipo de alimentação.

Conforme descrito na Tabela 2, a base de dados experimentais consiste de



**Tabela 6 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador SVM**

Classificador	SVM					
	≤0.5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão						
Acurácia de Todas as Amostras (%)	100	86,7	88,4	85,1	84,7	84,0
Acurácia das Amostras Saudáveis (%)	100	43,3	44,0	25,7	24,4	20,0
Acurácia das Amostras Defeituosas (%)	100	97,5	99,5	85,1	99,7	100,0
Estatística Kappa	1,00	0,49	0,55	0,36	0,34	0,29
Tempo para a Criação do Modelo (s)	0,03	0,05	0,09	0,13	0,17	0,23

Por meio das Tabelas 4, 5 e 6, verifica-se que ao aumentar o nível de desequilíbrio entre as tensões de alimentação, o sistema reduz as acurácias de classificação, independente do classificador de padrões utilizado. É importante destacar que para o desequilíbrio de tensão de até 0,5%, tanto o classificador RNA MLP quanto o SVM são capazes de identificar corretamente 100% das amostras. Ainda, com o aumento do desequilíbrio de tensão, considerando adversas situações de operação, observa-se que o sistema utilizando o classificador RNA MLP apresenta acurácias de classificação satisfatórias. De acordo com a Tabela 4, com o desequilíbrio de até 4%, o sistema com esse classificador neural atinge uma taxa de classificação de 95,6% de todas amostras, 86,0% das amostras saudáveis e 98,0% das amostras com defeitos. Assim, demonstra-se a capacidade de separação das classes, que pode colaborar no monitoramento de falhas de um MIT, mesmo esse estando sujeito a defeitos incipientes em seus rolamentos. O coeficiente Kappa de 0,86 para esse teste experimental confirma a perfeita concordância com esses resultados.

Quando se utiliza o classificador SVM, verifica-se que o aumento do desequilíbrio de tensão, acarreta a redução das taxas de classificação. Ao aumentar o desequilíbrio de até 0,5% para até 2%, as taxas de classificação das amostras sem falhas caem de 100% para 43,3%, conforme apresenta-se na Tabela 6. Isso pode ser explicado pelo motivo desse tipo de classificador não conseguir encontrar um hiperplano separador entre os dados das classes sem e com defeitos, a medida que o desequilíbrio de tensão na alimentação do motor cresce devido a similaridade entre os dados.

Além disso, a Tabela 5 possibilita notar que o classificador *k*-NN também não é capaz de fazer a separação das amostras saudáveis e defeituosas. As taxas de classificação das amostras saudáveis, independente do nível de desequilíbrio na alimentação do MIT, apresentam acurácias de no máximo 63,3%, indicando que esse

classificador não é o ideal quando deseja-se trabalhar com a técnica de extração de característica baseada na MI. Ainda, a Tabela 4 revela que o classificador RNA MLP apresenta o melhor comportamento para o conjunto total de dados do Motor 1 com 90,5% de acurácia.

Uma das possíveis razões para a classificação incorreta das amostras sem defeitos, é que os desgastes abrasivos de 15 e 30 minutos são defeitos em estágio inicial, os quais podem induzir o sistema de diagnóstico a identificar de forma equivocada esse tipo de amostra com os dados da máquina operando sem defeitos, ocorrendo de forma similar em situações contrárias. Também, considerando que os defeitos de rolamentos tendem a ter um comportamento simétrico em todas as fases do motor, esse tipo de defeito pode ser classificado de forma errônea com o motor operando sem defeitos e com desequilíbrios de tensão.

Semelhante aos ensaios realizados no Motor 1, executam-se testes utilizando o conjunto de dados do Motor 2, com variação de carga de 10% à 120% do conjugado de carga nominal e desequilíbrios de tensão na alimentação de até 10% nas fases A, B e C. Esses novos testes realizados tem o objetivo de verificar se o comportamento é similar aos observados para o Motor 1. As Tabelas 7, 8 e 9 apresentam os resultados de classificação para esse conjunto de dados empregando os classificadores MLP, *k*-NN e SVM, respectivamente. É importante ressaltar que o Motor 2 também está sujeito ao desgaste abrasivo nos rolamentos de 15, 30, 60 e 90 minutos, além de variações no conjugado de carga e desequilíbrios de tensão entre as fases, todas estas situações comuns a um ambiente industrial.

**Tabela 7 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador MLP**

Classificador	MLP					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	98,0	98,7	96,0	92,9	93,1	92,0
Acurácia de Todas as Amostras (%)	100	93,3	88,0	78,6	77,8	74,5
Acurácia das Amostras Saudáveis (%)	97,5	100	98,0	96,4	96,9	96,4
Estatística Kappa	0,94	0,96	0,87	0,77	0,78	0,74
Tempo para a Criação do Modelo (s)	5,5	16,5	27,0	40,8	53,4	64,6

Conforme ilustrado nas Tabelas 7, 8 e 9, para um desequilíbrio de tensão de até 0,5%, os três classificadores de padrões utilizados, RNA MLP, *k*-NN e SVM, apresentam resultados satisfatórios, atingindo 98,0%, 96,0% e 98,0% de acurácias de classificação para o conjunto total de amostras, respectivamente. Assim, demonstra-se



**Tabela 8 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador *k*-NN**

Classificador	<i>k</i> -NN					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Acurácia de Todas as Amostras (%)	96,0	87,3	86,0	86,3	86,9	84,2
Acurácia das Amostras Saudáveis (%)	100	50,0	56,0	57,1	54,4	49,1
Acurácia das Amostras Defeituosas (%)	95,0	96,7	93,5	93,6	95,0	93,0
Estatística Kappa	0,88	0,54	0,53	0,54	0,55	0,46
Tempo para a Criação do Modelo (s)	0,01	0,01	0,01	0,01	0,01	0,01

**Tabela 9 – Classificação dos defeitos de rolamentos considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador SVM**

Classificador	SVM					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Acurácia de Todas as Amostras (%)	98,0	94,7	88,0	86,3	86,9	86,2
Acurácia das Amostras Saudáveis (%)	100	73,3	46,0	35,7	40,0	38,2
Acurácia das Amostras Defeituosas (%)	97,5	100	98,5	98,9	98,6	98,2
Estatística Kappa	0,94	0,81	0,54	0,45	0,49	0,46
Tempo para a Criação do Modelo (s)	0,03	0,01	0,02	0,04	0,05	0,08

que em situações normais de operação, o sistema proposto consegue fazer uma eficaz separação entre as classes. Os coeficientes Kappa de 0,94, 0,88 e 0,94, para os classificadores RNA MLP, *k*-NN e SVM, corroboram com os resultados obtidos para essa situação de operação do Motor 2. A medida que o desequilíbrio de tensão cresce, as taxas de classificação diminuem, de acordo com os resultados apresentados para o Motor 1. Além disso, novamente, destacam-se as acurácias de classificação para o classificador RNA MLP, pois mesmo com um desequilíbrio de tensão de até 4%, são atingidas taxas de classificação de 96,0% do conjunto global de amostras, 88,0% do conjunto de amostras sem defeitos e 98,0% do conjunto das amostras com defeitos, segundo a Tabela 7. É importante verificar que o índice Kappa para esse teste, foi obtido um valor de 0,87, o qual ratifica os resultados encontrados para o classificador RNA MLP, identificando o mesmo como o mais adequado para a técnica de extração de características baseada na MI.

Com o intuito de verificar o comportamento da abordagem proposta a condições de operação desconhecidas, foram realizados novos ensaios experimentais. Nesses novos testes, são utilizados para o treinamento dos algoritmos inteligentes as amostras dos motores operando com desequilíbrios de tensão de 0,5%, 2%, 6%, 8% e 10%, e para a validação dos classificadores, as amostras com desequilíbrio de tensão de 4%, além das condições de carga já descritas nos ensaios anteriores. As Tabelas 10 e 11 apresentam os resultados obtidos para os classificadores inteligentes MLP, *k*-NN e

SVM para as amostras dos Motores 1 e 2, respectivamente.

**Tabela 10 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 operando diretamente pela rede elétrica - Defeitos de rolamentos**

Classificador	MLP	<i>k</i> -NN	SVM
Desequilíbrio de Tensão	4%	4%	4%
Acurácia de Todas as Amostras (%)	90,0	89,0	90,0
Acurácia das Amostras Saudáveis (%)	85,0	70,0	65,0
Acurácia das Amostras Defeituosas (%)	91,3	93,8	96,3
Estatística Kappa	0,71	0,65	0,66
Tempo para a Criação do Modelo (s)	16,9	0,04	0,01

**Tabela 11 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 operando diretamente pela rede elétrica - Defeitos de rolamentos**

Classificador	MLP	<i>k</i> -NN	SVM
Desequilíbrio de Tensão	4%	4%	4%
Acurácia de Todas as Amostras (%)	92,0	90,0	91,0
Acurácia das Amostras Saudáveis (%)	75,0	80,0	55,0
Acurácia das Amostras Defeituosas (%)	96,3	92,5	100
Estatística Kappa	0,74	0,70	0,66
Tempo para a Criação do Modelo (s)	12,9	0,03	0,01

Observa-se por meio das Tabelas 10 e 11 que os classificadores MLP e SVM tem resultados levemente superiores ao algoritmo *k*-NN. Em relação aos ensaios do Motor 1 apresentados na Tabela 10, os classificadores MLP e SVM identificaram corretamente 90,0% de todas as amostras. É importante destacar que a rede neural MLP apresenta acurácia de classificação das amostras saudáveis superior, identificando corretamente 85,0% desse tipo de amostras, enquanto que os outros dois classificadores, *k*-NN e SVM, apresentaram acurácias de 70,0% e 65,0%, respectivamente. Analisando a Tabela 11, novamente, o algoritmo MLP apresenta acurácia superior de classificação, embora apresente um tempo computacional maior para a criação do modelo. São atingidas taxas de classificação de todas as amostras de 92,0%, 90,0% e 91,0% para os classificadores MLP, *k*-NN e SVM, respectivamente, conforme está ilustrado na Tabela 11.

Os resultados apresentados nessa seção demonstram a capacidade do sistema de diagnóstico proposto em identificar os defeitos de rolamentos em MITs alimentados diretamente da rede de alimentação. Na próxima seção, verifica-se se a metodologia é robusta independente do tipo de alimentação, assim, são realizados novos ensaios com os MITs sendo alimentados por inversores de frequência.

### 5.1.2 Defeitos de Rolamentos - Motores Alimentados por meio de Inversores de Frequência

Esta seção apresenta os resultados experimentais dos testes quando os motores são alimentados por meio de inversores de frequência. Tais testes são realizados a fim de verificar se a metodologia abordada nesse trabalho é generalista, isto é, apresenta resultados de classificação independente do tipo de alimentação da máquina, seja ela senoidal ou não-senoidal. Similar ao ocorrido na Seção 5.1.1, utilizam-se como dados de entrada para os classificadores RNA MLP,  $k$ -NN e SVM os valores da curva de MI obtidos na etapa anterior de extração de características. Com o intuito de verificar o comportamento do MIT frente a diversas condições de operação, esses testes foram executados utilizando o conjunto de dados dos motores, com variação na frequência de alimentação de 20% à 100% do valor nominal e variações no conjugado de carga conforme descrito no Capítulo 4. É importante destacar que os resultados são separados por inversores de frequência, tendo em vista que cada um apresenta característica de chaveamento específica, conforme Martin-Diaz *et al.* (2017). Assim, na Tabela 12 são apresentados os resultados de classificação para o conjunto de dados do Motor 1, quando este motor está sujeito ao desgaste abrasivo nos rolamentos de 15, 30, 60 e 90 minutos.

**Tabela 12 – Classificação dos defeitos de rolamentos considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 1**

Conjunto de Dados	ATV			G110			MM440		
	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	97,3	96,7	92,4	98,1	93,2	98,1	99,5	98,4	99,5
Acurácia das Amostras Saudáveis (%)	87,8	85,6	64,4	91,8	74,0	94,5	98,9	94,3	97,7
Acurácia das Amostras Defeituosas (%)	99,7	99,4	99,4	99,7	98,0	99,0	99,7	99,4	99,4
Estatística Kappa	0,91	0,89	0,73	0,94	0,77	0,94	0,99	0,95	0,99
Tempo para a Criação do Modelo (s)	17,7	0,01	0,17	15,1	0,01	0,06	16,2	0,01	0,03

A partir da Tabela 12, analisa-se que ao ser alimentado pelo inversor de frequência ATV, os melhores resultados são atingidos quando utiliza-se o classificador MLP. Observa-se que são classificadas corretamente 97,3% do conjunto global de amostras, 87,8% do conjunto de amostras saudáveis e 99,7% do conjunto de amostras defeituosas. Ainda, destaca-se o índice Kappa de 0,91 que confirma os resultados descritos anteriormente. Quando utiliza-se o classificador  $k$ -NN, verifica-se que são atingidos resultados próximos, já para o classificador SVM apresenta um comportamento inferior aos demais.

Quando emprega-se o inversor G110 na alimentação do Motor 1, os classificadores MLP e SVM apresentam taxas de classificação globais de 98,1%. Contudo, verifica-se que o classificador SVM consegue uma taxa superior na classificação das amostras sem defeitos. Os índices Kappa de 0,94 quando utilizam-se ambos classificadores, seja o MLP ou o SVM, indicam a total concordância com os resultados obtidos. O classificador *k*-NN apresentou taxas de classificação inferiores, principalmente nas amostras saudáveis, atingindo uma acurácia de classificação de 74,0% para esse conjunto de amostras.

Ao alimentar o Motor 1 usando o inversor de frequência MM440, verifica-se que os três classificadores apresentam satisfatórias acurácias de classificação, todas estas acima de 98,0%, além de coeficientes Kappa acima de 0,95, que confirmam a boa separação entre as classes, sem defeitos e com defeitos.

Assim, no geral, quando trabalha-se com uma ampla faixa de variação de frequência, de 20% à 100% do valor nominal, e com os resultados apresentados para todos os inversores, verifica-se que o classificador mais adequado é o classificador MLP, onde são atingidas as maiores taxas de classificação, embora tenha um maior tempo computacional na construção do modelo.

Semelhante aos ensaios realizados para o Motor 1, efetuam-se testes experimentais utilizando o Motor 2 a partir de alimentação por fontes não-senoidais. Para esse conjunto de dados, variaram-se a frequência de alimentação e o conjugado de carga em níveis similares ao utilizados para o Motor 1. A Tabela 13 apresenta os resultados de classificação para o conjunto total de dados do Motor 2 quando este motor está sujeito ao desgaste abrasivo nos rolamentos de 15, 30, 60 e 90 minutos, além de ser alimentado por diferentes tipos de inversores de frequência.

**Tabela 13 – Classificação dos defeitos de rolamentos considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 2**

Conjunto de Dados	ATV			G110			MM440		
	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	98,1	93,7	92,3	99,7	98,2	99,7	99,2	99,7	98,2
Acurácia das Amostras Saudáveis (%)	90,4	72,3	61,4	100	94,7	100	100	98,7	93,7
Acurácia das Amostras Defeituosas (%)	100	99,1	100	99,7	99,0	99,7	99,0	100	99,4
Estatística Kappa	0,94	0,78	0,72	0,99	0,94	0,99	0,98	0,99	0,94
Tempo para a Criação do Modelo (s)	13,0	0,01	0,26	13,6	0,01	0,04	12,4	0,01	0,03

Quando o Motor 2 é alimentado pelo inversor de frequência ATV, nota-se que há melhor separação entre as classes sem defeitos e com defeitos ao empregar o classificador MLP, conforme está descrito na Tabela 13. Observa-se que ao utilizar a

RNA MLP, classificam-se corretamente 98,1% do conjunto total de amostras, além de 90,4% e 100% das amostras sem defeitos e com defeitos, respectivamente. Assim, para esse conjunto de dados, o classificador MLP apresenta-se como o mais apropriado.

Já quando empregam-se os inversores de frequência G110 e MM440 como fonte de alimentação do Motor 2, observa-se que independente do classificador, MLP, *k*-NN e SVM, são atingidas taxas de classificação globais acima de 98,2%, bem como coeficientes Kappa acima de 0,94, que confirma a concordância com os resultados obtidos. Contudo, é importante salientar que para a construção do modelo, os classificadores *k*-NN e SVM despendem de um processamento menor quando comparado com a RNA MLP.

Novos testes foram executados a fim de avaliar o comportamento da abordagem proposta a condições de operação ainda não conhecidas. Para o treinamento dos algoritmos inteligentes, foram empregadas as amostras dos motores operando com níveis de frequência de alimentação de 12, 18, 24, 30, 36, 42, 54 e 60 Hz, e para a validação dos classificadores, as amostras com níveis de frequência de alimentação de 48 Hz, além das condições de carga já descrita anteriormente. Nas Tabelas 14 e 15 são apresentados os resultados obtidos para os classificadores de padrões MLP, *k*-NN e SVM para as amostras dos Motores 1 e 2, respectivamente. Como nos ensaios apresentados nas Tabelas 12 e 13, os resultados foram separados pelo inversor de frequência utilizado na alimentação do motor.

**Tabela 14 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 alimentado por inversores de frequência - Defeitos de rolamentos**

Conjunto de Dados	ATV			G110			MM440		
	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	94,0	90,0	96,0	98,0	96,0	94,0	100	92,0	96,0
Acurácia das Amostras Saudáveis (%)	100	50,0	80,0	90,0	80,0	70,0	100	70,0	80,0
Acurácia das Amostras Defeituosas (%)	92,5	100	100	100	100	100	100	97,5	100
Estatística Kappa	0,83	0,62	0,86	0,94	0,86	0,79	1,00	0,73	0,86
Tempo para a Criação do Modelo (s)	17,8	0,01	0,14	14,8	0,01	0,09	17,5	0,02	0,04

Quando o Motor 1 é alimentado pelo inversor ATV, observa-se que o classificador SVM tem desempenho levemente superior aos demais classificadores, identificando corretamente 96,0% de todas as amostras, conforme descrito na Tabela 14. No caso em que o Motor 1 é alimentado pelos inversores G110 e MM440, nota-se que a rede neural MLP tem desempenho superior aos demais algoritmos, detectando de forma correta 98,0% e 100% todas as amostras, para os respectivos inversores, conforme ilustrado

**Tabela 15 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 alimentado por inversores de frequência - Defeitos de rolamentos**

Conjunto de Dados	ATV			G110			MM440		
	MLP	k-NN	SVM	MLP	k-NN	SVM	MLP	k-NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	98,0	88,0	92,0	100	88,0	100	98,0	94,0	92,0
Acurácia das Amostras Saudáveis (%)	90,0	50,0	60,0	100	80,0	100	100	70,0	60,0
Acurácia das Amostras Defeituosas (%)	100	97,5	100	100	90,0	100	97,5	100	100
Estatística Kappa	0,94	0,56	0,71	1,00	0,65	1,00	0,94	0,79	0,71
Tempo para a Criação do Modelo (s)	18,8	0,01	0,20	21,0	0,01	0,03	26,7	0,01	0,16

na Tabela 14. Os índices Kappa de 0,94 e 1,00, demonstram a total concordância com os resultados obtidos.

Conforme descrito na Tabela 15, quando o Motor 2 é alimentado pelo inversor de frequência ATV, verifica-se que há uma melhor estimativa da real situação dessa máquina com o emprego da rede MLP. Ao utilizar esse classificador, detectam-se corretamente 98,0% do conjunto total de amostras, além de 90,0% e 100% das amostras sem defeitos e com defeitos, respectivamente. Os demais classificadores, *k*-NN e SVM, apresentam acurácias globais satisfatórias, no entanto, identificam incorretamente 50% e 40% das amostras saudáveis.

Ainda na Tabela 15, para o caso em que o Motor 2 é acionado pelo inversor G110 como fonte de alimentação, os classificadores MLP e SVM detectam corretamente todas as amostras. É importante ainda destacar que o SVM obtém o menor tempo para a construção do seu modelo quando comparado com a RNA MLP. Já na situação na qual o Motor 2 é alimentado pelo inversor MM440, a rede neural MLP apresenta melhor comportamento frente aos demais algoritmos, identificando de modo correto 98,0% de todas as amostras. Assim, observa-se que esse algoritmo é o mais adequado à ferramenta de extração de característica empregado na metodologia proposta.

Pelos resultados apresentados na Seção 5.1.1 e Seção 5.1.2, demonstra-se que o sistema proposto identifica e detecta falhas de rolamentos em MITs independente da fonte de alimentação, bem como do nível de conjugado de carga em que atua.

## 5.2 RESULTADOS EXPERIMENTAIS - BARRAS QUEBRADAS DE ROTOR

Nesta seção são apresentados os resultados obtidos pelos classificadores no diagnóstico de defeitos de barras quebradas de rotor utilizando como matriz de entrada as medidas de associação entre as correntes das fases A e B dos MITs independente

de seu tipo de alimentação. De forma similar ao apresentado na Seção 5.1.1, os motores analisados nessa seção foram submetidos a diversas condições de operação como uma ampla variação de conjugado de carga (10% à 120% do valor nominal), desequilíbrio de tensão de até 10% e variação na frequência de alimentação de 20% à 100% da frequência nominal.

De acordo com a Tabela 2, o conjunto de ensaios experimentais é composto de 3310 testes realizados no Motor 1 e no Motor 2; a saber: 1099 e 2211 amostras coletadas a partir dos motores conectados diretamente a rede e por meio de inversores de frequência, respectivamente. É importante salientar que o referido conjunto de dados foi dividido de forma equilibrada nas possíveis condições de operação: saudável, uma barra quebrada de rotor, duas barras quebradas de rotor, 4 barras quebradas de rotor e 2/2 barras quebradas de rotor diametralmente opostas.

### 5.2.1 Barras Quebradas de Rotor - Motores Conectados Diretamente à Rede

Nesta seção são apresentados os resultados experimentais dos testes para o Motor 1 e Motor 2 conectados diretamente à rede de alimentação. Os valores da curva de MI obtidos na etapa anterior de extração de características são empregados como dados de entrada para os classificadores: Rede MLP,  $k$ -NN e SVM. As Tabelas 16, 17 e 18 apresentam os resultados de classificação para o conjunto de dados do Motor 1 para os algoritmos inteligentes RNA MLP,  $k$ -NN e SVM, respectivamente.

**Tabela 16 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador MLP**

Classificador	MLP					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão						
Acurácia de Todas as Amostras (%)	100	93,9	95,2	92,0	94,7	93,8
Acurácia das Amostras Saudáveis (%)	100	75,9	79,6	71,0	85,4	78,0
Acurácia das Amostras Defeituosas (%)	100	98,3	99,0	97,1	96,9	97,7
Estatística Kappa	1,00	0,79	0,84	0,73	0,83	0,80
Tempo para a Criação do Modelo (s)	2,77	9,55	17,3	21,5	25,7	37,8

Por meio das Tabelas 16, 17 e 18, verifica-se que ao alimentar o Motor 1 com um desequilíbrio entre as tensões de alimentação, o sistema tende a reduzir as acurácias de classificação, independente do classificador de padrões utilizado. Para um desequilíbrio de tensão de até 0,5%, situação onde considera-se que a alimentação do motor está praticamente equilibrada, destaca-se que tanto o classificador RNA MLP quanto o SVM são capazes de identificar corretamente 100% das amostras.

**Tabela 17 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador *k*-NN**

Classificador	<i>k</i> -NN					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Acurácia de Todas as Amostras (%)	89,8	79,9	75,9	71,6	73,1	74,0
Acurácia das Amostras Saudáveis (%)	66,7	34,5	32,7	21,7	29,2	31,2
Acurácia das Amostras Defeituosas (%)	95,0	90,8	86,5	83,9	83,9	84,5
Estatística Kappa	0,64	0,28	0,20	0,06	0,13	0,16
Tempo para a Criação do Modelo (s)	0,01	0,01	0,01	0,01	0,01	0,01

**Tabela 18 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador SVM**

Classificador	SVM					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Acurácia de Todas as Amostras (%)	100	93,3	95,6	92,3	91,5	90,7
Acurácia das Amostras Saudáveis (%)	100	69,0	79,6	63,8	62,9	57,8
Acurácia das Amostras Defeituosas (%)	100	99,2	99,5	99,3	98,6	98,9
Estatística Kappa	1,00	0,76	0,85	0,72	0,70	0,66
Tempo para a Criação do Modelo (s)	0,02	0,06	0,09	0,20	0,29	0,33

Já, ao realizar a alimentação do Motor 1 com desequilíbrio de até 2%, as taxas de classificação caem para aproximadamente 93% em ambos os casos, mostrando a influência do desequilíbrio na identificação de barras quebradas de rotor em MITs acionados diretamente da rede de alimentação.

No entanto, mesmo com o aumento do desequilíbrio de tensão, sendo estas consideradas situações anormais de operação do motor na indústria, observa-se na Tabela 16 que o sistema utilizando o classificador RNA MLP apresenta acurácias de classificação satisfatórias. Com desequilíbrio de até 8%, o sistema com esse classificador neural atinge a taxa de classificação de 94,7% de todas amostras, 85,4% das amostras saudáveis e 96,9% das amostras com defeitos, demonstrando a capacidade de separação das classes. O índice Kappa de 0,83 para esse ensaio experimental confirma a total concordância com os resultados.

Ao empregar o classificador SVM, apresentado na Tabela 18, constata-se a redução nas taxas de classificação das amostras sem defeitos com o aumento do desequilíbrio de tensão. Ao aumentar o desequilíbrio de 0,5% para 2%, as taxas de classificação das amostras sem falhas caem de 100% para 69,0%. Isso pode ser explicado pelo motivo desse tipo de classificador não conseguir encontrar um hiperplano separador entre as amostras das classes saudável e com barras quebradas de rotor.

Na Tabela 17 é possível notar que o classificador *k*-NN também não é capaz de fazer a adequada separação das amostras saudáveis e defeituosas. As taxas





**Tabela 21 – Classificação de barras quebradas de rotor considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador SVM**

Classificador	SVM					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão						
Acurácia de Todas as Amostras (%)	96,0	96,7	97,6	95,7	94,7	94,4
Acurácia das Amostras Saudáveis (%)	100	90,0	92,0	82,9	80,0	80,0
Acurácia das Amostras Defeituosas (%)	95,0	97,2	99,0	98,9	98,3	98,0
Estatística Kappa	0,88	0,89	0,92	0,86	0,82	0,82
Tempo para a Criação do Modelo (s)	0,01	0,02	0,06	0,16	0,18	0,29

Observa-se pelas Tabelas 19, 20 e 21 que nesse novo cenário, quando o Motor 2 está sendo alimentado com desequilíbrio de tensão de até 0,5%, os três classificadores de padrões utilizados, RNA MLP, *k*-NN e SVM, apresentam resultados satisfatórios, atingindo 98,0%, 96,0% e 96,0% de acurácias de classificação para o conjunto total de amostras, respectivamente. Isso certifica que em situações comuns de operação, o sistema proposto é capaz de fazer a separação entre as classes. Os coeficientes Kappa de 0,94, 0,88 e 0,88, para os classificadores RNA MLP, *k*-NN e SVM, corroboram com os resultados atingidos para essa situação de operação do Motor 2.

Ao passo que cresce o desequilíbrio de tensão na alimentação, as taxas de classificação diminuem, em conformidade com os resultados apresentados nas Tabelas 16, 17 e 18 para o Motor 1. Ainda, mais uma vez, evidenciam-se as acurácias de classificação para a RNA MLP, pois ainda que com um desequilíbrio de tensão de até 4%, são atingidas taxas de classificação de 96,8% do conjunto global de amostras, 88,0% do conjunto de amostras sem defeitos e 99,0% do conjunto de amostras com defeitos, conforme apresenta-se na Tabela 19. O índice Kappa para esse teste tem o valor de 0,90 e indica a total concordância com os resultados encontrados. Ainda, observa-se que com o desequilíbrio de tensão na alimentação de até 10%, o qual é considerada a pior situação nos ensaios realizados, a metodologia proposta empregando MI associada com um classificador MLP obtém acurácias de classificação de 95,6% das amostras globais e o coeficiente Kappa de 0,86. Esses dados ratificam os promissores resultados encontrados para esse classificador, identificando o mesmo como o mais adequado para a técnica de extração de características utilizada no trabalho.

Quando são empregados outros classificadores de padrões como o caso do *k*-NN, observa-se pela Tabela 20 que com o aumento do desequilíbrio, os índices de

acertos das amostras saudáveis diminuem significativamente até 37,3%. Já com o desequilíbrio de até 2%, são classificadas corretamente em torno de 50,0% desse tipo de amostras. Assim, verifica-se que para a situação dos motores alimentados a partir de uma fonte senoidal, esse classificador não é o mais apropriado.

Por meio da Tabela 21, observa-se que ao utilizar o classificador SVM, constata-se que são atingidos índices de classificação ligeiramente inferiores ao do classificador RNA MLP. No pior caso de desequilíbrio de tensão de alimentação, obtém-se a acurácia de classificação de 94,4%, 80,0% e 98,0% das amostras globais, sem defeitos e com defeitos, respectivamente. É importante destacar que o tempo para a construção do modelo é menor quando comparado a rede MLP. Enquanto para o treinamento do SVM depende-se um tempo computacional de 0,29 segundos, na rede MLP é gasto um tempo computacional de 31,9 segundos para um computador Lenovo Ideapad 300, processador Intel® Core i5-6200 CPU @ 2,30 GHz, memória RAM 8GB utilizando a ferramenta Weka.

Mais uma vez, com o intuito de verificar o desempenho do sistema na detecção de amostras desconhecidas, foram realizados os seguintes ensaios experimentais. Empregou-se como dados de treinamento dos classificadores, as amostras com os motores sendo alimentados com desequilíbrios de tensão de 0,5%, 2%, 6%, 8% e 10%. Já para a validação, foram utilizadas as amostras com desequilíbrio de tensão de 4%. As Tabelas 22 e 23 exibem os resultados alcançados em ambos os motores (Motor 1 e Motor 2), respectivamente.

**Tabela 22 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 operando diretamente pela rede elétrica - Barras quebradas de rotor**

Classificador	MLP	k-NN	SVM
Desequilíbrio de Tensão	4%	4%	4%
Acurácia de Todas as Amostras (%)	97,0	88,0	92,0
Acurácia das Amostras Saudáveis (%)	85,0	45,0	60,0
Acurácia das Amostras Defeituosas (%)	100	98,8	100
Estatística Kappa	0,90	0,54	0,71
Tempo para a Criação do Modelo (s)	15,9	0,03	0,15

Analisando as Tabelas 22 e 23, observa-se que a metodologia apresentada nesse trabalho é capaz de diagnosticar eficientemente a situação das máquinas mesmo em condições de operação desconhecidas, principalmente quando é utilizado a rede MLP para a classificação dos padrões obtidos por meio da MI. Para os testes realizados com os dados do Motor 1 e do Motor 2, 97,0% e 96,0% de todas as amostras são

**Tabela 23 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 operando diretamente pela rede elétrica - Barras quebradas de rotor**

Classificador	MLP	<i>k</i> -NN	SVM
Desequilíbrio de Tensão	4%	4%	4%
Acurácia de Todas as Amostras (%)	96,0	91,0	93,0
Acurácia das Amostras Saudáveis (%)	80,0	65,0	65,0
Acurácia das Amostras Defeituosas (%)	100	97,5	100
Estatística Kappa	0,86	0,69	0,75
Tempo para a Criação do Modelo (s)	14,1	0,03	0,08

classificadas corretamente quando emprega-se a rede neural MLP, conforme é ilustrado nas Tabelas 22 e 23. Quando empregam-se os demais algoritmos, *k*-NN e SVM, são atingidos resultados satisfatórios, com acurácias acima de 88,0%. No entanto, esses índices são menores quando comparado com a rede MLP, principalmente na identificação das amostras sem falhas, o que contribui para a classificação de um falso positivo.

Assim, ao investigar os resultados apresentados nessa seção, verifica-se que o classificador mais oportuno para trabalhar em um sistema que emprega a MI como técnica de extração de características no diagnóstico de barras quebradas do enrolamento do rotor em MITs operando por meio de fontes senoidais é a RNA MLP.

### 5.2.2 Barras Quebradas de Rotor - Motores Alimentados por meio de Inversores de Frequência

Nesta seção são apresentados os resultados experimentais dos testes para o Motor 1 e para o Motor 2 alimentados por meio de inversores de frequência. Esse teste é realizado a fim de verificar se a metodologia abordada nesse trabalho é generalista para o diagnóstico de barras quebradas de rotor, isto é, se apresenta resultados promissores independente do tipo de alimentação da máquina. É importante destacar que a busca por sistemas de diagnóstico de falhas em máquinas alimentadas por inversores de frequência está cada vez maior, tendo em vista a sua grande utilização na alimentação e controle dos motores (GARCÍA-ESCUADERO *et al.*, 2017).

Semelhante aos ensaios realizados na Seção 5.2.1, utilizam-se os valores da MI como dados de entrada dos algoritmos inteligentes MLP, *k*-NN e SVM. Nesses novos testes variou-se a frequência de alimentação de 20% à 100% e o conjugado de carga de 10% a 120% dos valores nominais, conforme já descrito no Capítulo 4. Assim, nas

Tabelas 24 e 25 são apresentados os resultados de classificação para o conjunto de dados do Motor 1 e do Motor 2, respectivamente, quando estes estão sujeitos aos defeitos de barras quebrados no enrolamento do rotor descritos no Capítulo 4.

**Tabela 24 – Classificação de barras quebradas de rotor considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 1**

Conjunto de Dados	ATV			G110			MM440		
Classificador	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM
Acurácia de Todas as Amostras (%)	98,7	94,2	95,2	99,7	92,6	99,1	100	98,7	100
Acurácia das Amostras Saudáveis (%)	95,2	77,4	85,5	98,6	67,1	95,9	100	95,4	100
Acurácia das Amostras Defeituosas (%)	99,6	98,4	97,6	100	99,3	100	100	99,7	100
Estatística Kappa	0,96	0,81	0,85	0,99	0,75	0,97	1,00	0,96	1,00
Tempo para a Criação do Modelo (s)	15,1	0,01	0,04	19,0	0,01	0,05	20,0	0,01	0,03

**Tabela 25 – Classificação de barras quebradas de rotor considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 2**

Conjunto de Dados	ATV			G110			MM440		
Classificador	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM
Acurácia de Todas as Amostras (%)	97,6	94,5	93,0	99,7	98,9	99,7	100	99,2	100
Acurácia das Amostras Saudáveis (%)	90,4	73,5	65,1	98,7	96,1	98,7	100	96,2	100
Acurácia das Amostras Defeituosas (%)	99,4	99,7	100	100	99,7	100	100	100	100
Estatística Kappa	0,92	0,81	0,75	0,99	0,97	0,99	1,00	0,98	1,00
Tempo para a Criação do Modelo (s)	24,3	0,01	0,20	12,3	0,01	0,04	10,8	0,01	0,03

A Tabela 24 permite observar que ao ser alimentado pelo inversor de frequência ATV, os melhores resultados são atingidos quando utiliza-se o classificador MLP. Verifica-se que são classificadas corretamente 98,7% das amostras globais, 95,2% das amostras saudáveis e 99,6% das amostras defeituosas. Ainda, destaca-se o índice Kappa de 0,96 que confirma os resultados descritos anteriormente. Quando utiliza-se tanto o classificador *k*-NN quanto o classificador SVM, verifica-se que são atingidos resultados próximos, sendo em torno de 94% a 95% do conjunto global de amostras identificadas corretamente. No entanto, observa-se que no conjunto de amostras sem defeitos, o classificador SVM apresenta resultados superiores ao *k*-NN.

Ao empregar o conjunto de dados quando o Motor 1 é alimentado por meio do inversor G110, os classificadores MLP e SVM apresentam taxas de classificação globais de aproximadamente 99%. Contudo, verifica-se que o classificador MLP obtém a taxa de 98,6% das amostras sem defeitos, superior ao classificador de padrões SVM. Os índices Kappa acima de 0,94 para os referidos classificadores indicam a total concordância com os resultados obtidos. O classificador *k*-NN apresentou taxas de classificação inferiores, principalmente, das amostras saudáveis, atingindo uma acurácia de classificação de 67,1% para esse conjunto de amostras.

Ao alimentar o Motor 1 usando o inversor de frequência MM440, verifica-se que os três classificadores apresentam satisfatórias acurácias de classificação, todos estas acima de 98,7%, além de coeficientes Kappa acima de 0,96, que confirmam a boa separação entre as classes sem defeitos e com defeitos. É importante destacar que os classificadores MLP e SVM identificam corretamente todas as amostras para esse conjunto de dados.

Nos resultados experimentais para o Motor 2, apresentados por meio da Tabela 25, quando este motor é alimentado pelo inversor de frequência ATV, nota-se que a RNA MLP é capaz de realizar a separação entre as classes sem defeitos quando comparado com os demais classificadores. Constata-se que ao utilizar a rede MLP, classificam-se corretamente 97,6% do conjunto total de amostras, além de 90,4% e 99,4% das amostras sem defeitos e com defeitos, respectivamente. Assim, para esse conjunto de dados, o classificador MLP apresenta ser o mais apropriado para esta aplicação. Ao empregar os classificadores  $k$ -NN e SVM atingem-se acurácias de classificação das amostras globais de 94,5% e 93,0%, respectivamente. Contudo, verifica-se que 65,1% do conjunto das amostras sem defeitos são classificadas de forma inadequada para o algoritmo SVM. Ainda, quando utiliza-se o classificador  $k$ -NN são identificadas corretamente 73,5% para esse mesmo tipo de amostras.

Os testes experimentais que empregam os inversores G110 e MM440 como fonte de alimentação do Motor 2, observa-se que independente do classificador, MLP,  $k$ -NN e SVM, são atingidas taxas de classificação globais acima de 98,9%, bem como coeficientes Kappa acima de 0,97, que confirma a total concordância com os resultados obtidos.

Assim, em geral, quando trabalha-se com uma ampla faixa de variação de frequência, 20% a 100% do valor nominal, com os resultados apresentados para todos os inversores, verifica-se que o classificador mais apropriado é a RNA MLP, onde são atingidas as maiores taxas de classificação, apesar de ter um maior tempo computacional na construção do modelo.

De forma similar aos aspectos metodológicos descritos na Seção 5.1.2, são realizados novos ensaios a fim de verificar o desempenho do sistema a condições não apresentadas na etapa de treinamento dos classificadores. Nesses ensaios são utilizados as amostras com frequência de alimentação dos inversores de 12, 18, 24, 30,

36, 42, 54 e 60 Hz para o treinamento dos classificadores e para o estágio de validação utilizam-se os dados coletados na frequência de 48 Hz. As Tabelas 26 e 27 descrevem os resultados para o conjunto de dados dos três inversores utilizados na alimentação, ATV, G110 e MM440, para as amostras dos Motores 1 e 2, respectivamente.

**Tabela 26 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 alimentado por inversores de frequência - Barras quebradas de rotor**

Conjunto de Dados	ATV			G110			MM440		
	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	96,0	90,0	92,0	100	90,0	100	100	96,0	100
Acurácia das Amostras Saudáveis (%)	100	60,0	100	100	90,0	100	100	100	100
Acurácia das Amostras Defeituosas (%)	95,0	90,0	90,0	100	90,0	100	100	95,0	100
Estatística Kappa	0,88	0,65	0,78	1,00	0,72	1,00	1,00	0,88	1,00
Tempo para a Criação do Modelo (s)	6,36	0,02	0,02	7,59	0,02	0,02	8,52	0,01	0,08

**Tabela 27 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 alimentado por inversores de frequência - Barras quebradas de rotor**

Conjunto de Dados	ATV			G110			MM440		
	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM	MLP	<i>k</i> -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	96,0	90,0	90,0	100	96,0	100	100	96,0	100
Acurácia das Amostras Saudáveis (%)	100	50,0	50,0	100	100	100	100	100	100
Acurácia das Amostras Defeituosas (%)	95,0	100	100	100	95,0	100	100	95,0	100
Estatística Kappa	0,88	0,62	0,62	1,00	0,88	1,00	1,00	0,88	1,00
Tempo para a Criação do Modelo (s)	9,26	0,01	0,02	8,87	0,01	0,03	8,79	0,01	0,04

Analisando a Tabela 26, nota-se que a rede MLP apresenta as maiores acurácias de classificação, independente do tipo de inversor utilizado na alimentação do Motor 1. O pior caso de classificação de padrões ocorre com a aplicação do inversor ATV, para o qual são identificadas corretamente 96,0% de todas as amostras. O algoritmo dos *k*-vizinhos mais próximos é o que apresenta os piores resultados quando comparado com os outros dois algoritmos de classificação. No entanto, ainda são obtidas taxas de acerto superiores a 90,0% independente do inversor. Já as máquinas vetores de suporte apresentam resultados promissores quando o Motor 1 é alimentado pelo inversor G110 e pelo MM440. Nessas condições, são classificadas corretamente todas as amostras. Somente no caso em que o Motor 1 é alimentado pelo inversor ATV que o SVM apresenta resultado inferior a rede neural MLP.

Quando são analisados os resultados obtidos para o conjunto de dados do Motor 2, verifica-se o mesmo comportamento observado para o conjunto de dados do Motor 1, onde a rede neural MLP apresenta maior acurácia quando comparada aos demais classificadores, conforme é demonstrado na Tabela 27. Esse classificador de

padrões atinge acurácias de classificação superior a 96,0% independente do inversor de frequência utilizado para a alimentação do Motor 2. Os resultados obtidos estão em concordância com os resultados descritos nas Tabelas 24 e 25, onde a rede neural MLP obteve desempenho superior aos demais algoritmos, demonstrando ser mais adequado a estratégia de extração de características adotado na metodologia.

Além disso, por meio dos resultados experimentais apresentados na Seção 5.2.2, pode-se concluir que os sinais obtidos da MI na etapa de extração de características para o inversor de frequência ATV tem menor acurácia no diagnóstico dos defeitos. Entretanto, destaca-se que no mínimo, 93% de todas as amostras são identificadas corretamente. Quando as máquinas são alimentadas pelos inversores G110 e MM440 são obtidos resultados de 99,7% e 100%. Uma das razões é o chaveamento peculiar de cada inversor, o que pode causar a interferência nas frequências específicas na detecção do defeito (MARTIN-DIAZ *et al.*, 2017). Mesmo assim, no geral, o sistema proposto apresenta acima de 92,6% de acurácia na identificação de barras quebradas de rotor em MITs alimentados por fonte de alimentação não-senoidal, independente da faixa de velocidade em que atua.

### 5.3 RESULTADOS EXPERIMENTAIS - CURTO-CIRCUITO DE ESTATOR

Nesta seção são apresentados os resultados para o diagnóstico de curto-circuito de estator dos MITs independentemente de sua alimentação, em que os classificadores utilizam como entrada as medidas de associação entre as correntes das fases A e B dos MITs. Em conformidade com os resultados apresentados na Seções 5.1 e 5.2, os motores analisados nessa seção foram submetidos a diversas condições de operação como uma ampla variação de conjugado de carga (10% a 120% do valor nominal), desequilíbrio de tensão de até 10% e variação na frequência de alimentação de 20% à 100% da frequência nominal.

O conjunto de dados é constituído de 2340 ensaios experimentais realizados no Motor 1 e no Motor 2, divididos em 480 e 1860 testes coletados a partir dos motores conectados diretamente a rede e por meio de inversores de frequência, respectivamente. Deve-se destacar que a divisão do referido conjunto de dados foi realizada de forma equilibrada nas seguintes possíveis condições de operação: saudável, 3% de curto-circuito, 5% de curto-circuito e 10% de curto-circuito de estator, de acordo com a Tabela



2.

## 5.3.1 Curto-circuito de Estator - Motores Conectados Diretamente à Rede

Nesta seção são apresentados os resultados experimentais dos testes para o Motor 1 e Motor 2 conectados diretamente à rede de alimentação. Os valores da curva de MI obtidos na etapa anterior de extração de características são empregados como dados de entrada para os classificadores: rede MLP,  $k$ -NN e SVM. As Tabelas 28, 29 e 30 apresentam os resultados de classificação para o conjunto de dados do Motor 1 dos algoritmos inteligentes RNA MLP,  $k$ -NN e SVM, respectivamente.

**Tabela 28 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador MLP**

Classificador	MLP					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Acurácia de Todas as Amostras (%)	95,8	98,6	95,8	94,6	94,0	93,8
Acurácia das Amostras Saudáveis (%)	100	94,4	90,0	85,7	85,2	81,7
Acurácia das Amostras Defeituosas (%)	94,4	100	97,8	97,6	96,9	97,8
Estatística Kappa	0,89	0,96	0,89	0,85	0,84	0,83
Tempo para a Criação do Modelo (s)	0,82	2,45	4,37	6,15	6,85	8,69

**Tabela 29 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador  $k$ -NN**

Classificador	$k$ -NN					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Acurácia de Todas as Amostras (%)	95,8	98,6	96,6	94,6	92,6	92,9
Acurácia das Amostras Saudáveis (%)	100	94,4	90,0	85,7	83,3	86,7
Acurácia das Amostras Defeituosas (%)	94,4	100	98,9	97,6	95,7	95,0
Estatística Kappa	0,89	0,96	0,91	0,85	0,80	0,81
Tempo para a Criação do Modelo (s)	0,01	0,01	0,01	0,01	0,01	0,01

**Tabela 30 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 1 - Classificador SVM**

Classificador	SVM					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Acurácia de Todas as Amostras (%)	100	98,6	96,7	94,6	94,0	93,8
Acurácia das Amostras Saudáveis (%)	100	94,4	86,7	78,6	77,8	78,3
Acurácia das Amostras Defeituosas (%)	100	100	100	100	99,4	98,9
Estatística Kappa	1,00	0,96	0,91	0,85	0,83	0,82
Tempo para a Criação do Modelo (s)	0,03	0,04	0,06	0,08	0,10	0,12

As Tabelas 28, 29 e 30 permitem observar que na situação de desequilíbrio de tensão de até 0,5%, o classificador SVM faz a melhor separação entre as classes sem e com defeitos em relação aos demais classificadores. Para esse caso, o classificador SVM identifica corretamente 100% de todas as amostras. O coeficiente

Kappa de 1,00 demonstra a total concordância com os resultados obtidos, conforme está ilustrado na Tabela 30. Ainda, nas Tabelas 28, 29 e 30 é possível verificar que com o aumento do nível de desequilíbrio de tensão para 2%, são apresentadas a mesma taxa de classificação de todas as amostras de 98,6% independente do algoritmo empregado. Nessa situação, observa-se que todos os classificadores MLP, *k*-NN e SVM obtêm índices promissores na identificação de curto-circuito de estator mesmo em situações indesejáveis de operação do motor. A medida que o desequilíbrio de tensão aumenta até 10%, as acurácias de classificação tendem a cair, como observa-se nas Tabelas 28, 29 e 30.

A partir da Tabela 28, observa-se que ao utilizar o classificador RNA MLP na situação onde há desequilíbrio de até 0,5% são classificadas corretamente 95,8% de todas as amostras, 100% das amostras saudáveis e 94,4% das amostras defeituosas. Com o aumento do desequilíbrio, nota-se que as acurácias de classificação de todo o conjunto de amostras variam em torno de 93,8% a 98,6%. O coeficiente Kappa de 0,83 indica a promissora separação entre as classes saudáveis e com falhas de curto-circuito de estator, mesmo quando o Motor 1 está na pior condição de operação.

Na situação onde é empregado o algoritmo inteligente dos *k*-vizinhos mais próximos, é possível observar que até um desequilíbrio de 6%, as acurácias de classificação são análogas aos dos demais classificadores. Somente quando há o agravamento do desequilíbrio de tensão é que há uma ligeira queda nas taxas de identificação de curto-circuito de estator. Os resultados demonstram que o *k*-NN tem um pouco mais de dificuldade em fazer a separação entre as amostras, em concordância com a Tabela 29. Entretanto, deve-se ressaltar que no pior caso de operação, são identificadas corretamente 92,9% de todas as amostras, 86,7% das amostras sem defeitos e 95,0% das amostras defeituosas. O coeficiente Kappa 0,81 demonstra uma perfeita concordância com os resultados atingidos.

Na Tabela 30 é possível verificar que ao adotar o classificador SVM, são obtidas acurácias de classificação similares a RNA MLP. Quando o desequilíbrio é de até 0,5% são atingidos resultados superiores a da RNA MLP, identificando corretamente todas as amostras. Ao aumentar o nível de desequilíbrio até 10%, a acurácia do algoritmo SVM é semelhante ao da rede MLP, no entanto, deve-se destacar que a rede neural apresenta acurácia levemente superior nas amostras saudáveis. Os resultados observados nas

Tabelas 28, 29 e 30 mostram que os classificadores RNA MLP e SVM apresentam resultados equivalentes, sendo ambos indicados para o monitoramento desse tipo de defeito.

Nas Tabelas 31, 32 e 33 são exibidos os resultados de classificação para os algoritmos RNA MLP, *k*-NN e SVM, respectivamente, quando estes estão sujeitos a monitorar o curto-circuito de estator no Motor 2.

**Tabela 31 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador MLP**

Classificador	MLP					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	100	93,1	94,2	94,6	92,6	91,7
Acurácia de Todas as Amostras (%)	100	77,8	90,0	92,9	87,0	88,3
Acurácia das Amostras Saudáveis (%)	100	98,1	95,6	95,2	94,4	92,8
Estatística Kappa	1,00	0,80	0,85	0,86	0,80	0,78
Tempo para a Criação do Modelo (s)	0,96	2,65	3,74	5,35	6,87	8,55

**Tabela 32 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador *k*-NN**

Classificador	<i>k</i> -NN					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	95,8	91,7	92,5	88,1	85,6	86,3
Acurácia de Todas as Amostras (%)	83,3	83,3	76,7	66,7	66,7	70,0
Acurácia das Amostras Saudáveis (%)	100	94,4	97,8	95,0	92,0	91,7
Estatística Kappa	0,88	0,78	0,79	0,66	0,61	0,63
Tempo para a Criação do Modelo (s)	0,01	0,01	0,01	0,01	0,01	0,01

**Tabela 33 – Classificação de curto-circuito de estator considerando variação no conjugado de carga de 10% a 120% do nominal - Motor 2 - Classificador SVM**

Classificador	SVM					
	≤0,5%	≤2%	≤4%	≤6%	≤8%	≤10%
Desequilíbrio de Tensão	100	91,7	93,3	92,3	92,1	91,7
Acurácia de Todas as Amostras (%)	100	72,2	83,3	81,0	83,3	80,0
Acurácia das Amostras Saudáveis (%)	100	98,1	96,7	96,0	95,1	95,6
Estatística Kappa	1,00	0,76	0,82	0,79	0,79	0,77
Tempo para a Criação do Modelo (s)	0,01	0,01	0,02	0,03	0,03	0,04

Semelhante ao ocorrido no Motor 1, nesses novos ensaios, o classificador *k*-NN apresenta resultados inferiores aos demais classificadores. No entanto, os resultados são promissores, pois na situação onde há o desequilíbrio de até 4%, uma condição atípica para o funcionamento de uma máquina, são identificadas corretamente 92,5% das amostras. A Tabela 32 apresenta o coeficiente Kappa de 0,79 para esse caso, o que demonstra o satisfatório desempenho desse classificador.

Já os classificadores RNA MLP e SVM, é importante salientar que são capazes de identificar todas as amostras corretamente para a situação onde o Motor 2 está

operando com até 0,5% de desequilíbrio de tensão, conforme demonstrado na Tabela 31 e na Tabela 33. Mesmo havendo amostras de curto-circuito de 3% de estator, que é considerada um defeito em estágio incipiente, esses classificadores conseguem fazer uma satisfatória separação entre as classes sem e com defeitos.

No pior cenário, onde a máquina está sujeita a um desequilíbrio de até 10%, em ambos os classificadores são atingidas taxas de classificação corretas acima de 91%. Em relação as amostras saudáveis, a rede neural MLP apresenta um resultado superior quando comparado ao algoritmo SVM, levando ao operador não determinar a parada da máquina em consequência de um falso positivo. Já em relação ao custo computacional, o classificador SVM tem um menor custo do que a RNA MLP, assim para essa máquina, pode-se afirmar que ambos os classificadores são os mais adequados para trabalharem com a metodologia para extração de características proposta nesse trabalho.

Após a realização desses ensaios, onde verificou-se que o sistema proposto apresenta resultados promissores no diagnóstico de curto-circuito de estator em MITs acionados por fontes senoidais, novos ensaios são necessários para verificar qual será o comportamento do sistema em condições de operação desconhecidas. Assim, o conjunto de dados descrito na Seção 4.1 foi dividido em dois grupos: i) treinamento e ii) validação. Os dados de treinamento consistem nos ensaios em que os motores são alimentados com desequilíbrios de tensão de 0,5%, 2%, 6%, 8% e 10%. Já o conjunto de dados para validação é composto pelas amostras em que os motores são alimentados com um desequilíbrio de tensão de 4%. É importante ressaltar que as condições de conjugado de carga são de 10% a 120% do torque nominal, conforme também já especificado na Seção 4.1. Nas Tabelas 34 e 35 são apresentados os resultados desses ensaios para os Motores 1 e 2, respectivamente.

**Tabela 34 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 operando diretamente pela rede elétrica - Curto-circuito de estator**

Classificador	MLP	k-NN	SVM
Desequilíbrio de Tensão	4%	4%	4%
Acurácia de Todas as Amostras (%)	91,7	87,5	91,7
Acurácia das Amostras Saudáveis (%)	91,7	75,0	66,7
Acurácia das Amostras Defeituosas (%)	91,7	91,7	100
Estatística Kappa	0,79	0,67	0,75
Tempo para a Criação do Modelo (s)	5,79	0,02	0,09

**Tabela 35 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 operando diretamente pela rede elétrica - Curto-circuito de estator**

Classificador	MLP	k-NN	SVM
Desequilíbrio de Tensão	4%	4%	4%
Acurácia de Todas as Amostras (%)	95,8	87,5	89,6
Acurácia das Amostras Saudáveis (%)	91,7	75,0	58,3
Acurácia das Amostras Defeituosas (%)	97,2	91,7	100
Estatística Kappa	0,89	0,67	0,68
Tempo para a Criação do Modelo (s)	5,73	0,01	0,05

Nos ensaios relacionados ao Motor 1, nota-se que são atingidas taxas semelhantes de classificação de todas as amostras (91,7%) tanto para a rede MLP quanto para o SVM, conforme ilustrado na Tabela 34. Entretanto, se analisadas apenas as amostras saudáveis, observa-se que a rede MLP identifica com maior acurácia esse tipo de amostra, levando a esse classificador obter um coeficiente Kappa superior ao obtido pelo SVM.

Quando são analisados os resultados relativos ao Motor 2 apresentados na Tabela 35, o classificador RNA MLP apresenta desempenho superior aos demais algoritmos. Esse classificador é capaz de diagnosticar corretamente 95,8% de todas as amostras. O índice Kappa de 0,89 demonstra uma total concordância com os resultados obtidos. Assim, os valores apresentados nas Tabelas 34 e 35 demonstram, novamente, que a rede MLP é o classificador mais adequado às medidas de informação mútua.

Os resultados apresentados nessa seção possibilitam afirmar que a metodologia proposta para esse trabalho é capaz de identificar os defeitos de curto-circuito de estator em MITs acionados diretamente da rede, incluindo os curto-circuito de 3% de estator que é considerado um defeito incipiente dessas máquinas. Na próxima seção são apresentados os resultados para os casos em que as máquinas são acionadas via inversores de frequência.

### 5.3.2 Curto-circuito de Estator - Motores Alimentados por meio de Inversores de Frequência

Nesta seção, apresentam-se os resultados experimentais dos ensaios realizados com os Motores 1 e 2 alimentados por inversores de frequência. Novamente, o intuito desse novo teste é verificar se a metodologia tem capacidade de diagnosticar o defeito de curto-circuito de estator independente do modo que o motor está sendo

alimentado.

Como nos demais testes já apresentados nas seções anteriores, serão utilizados as medidas de informação como matriz de entrada dos classificadores de padrões MLP,  $k$ -NN e SVM. As condições de operações empregadas nesses novos ensaios são as variações na frequência de alimentação de 20% à 100% e no conjugado de carga de 10% à 120% em relação aos seus valores nominais, bem como curto-circuito de estator de 3%, 5% e 10%. Desse modo, as Tabelas 36 e 37 exibem os resultados experimentais para o conjunto de dados do Motor 1 e do Motor 2, respectivamente.

**Tabela 36 – Classificação de curto-circuito de estator considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 1**

Conjunto de Dados	ATV			G110			MM440		
	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	98,5	99,5	97,7	99,7	93,2	99,2	99,5	98,7	97,6
Acurácia das Amostras Saudáveis (%)	95,3	97,7	90,7	98,6	78,1	95,9	97,7	97,7	93,1
Acurácia das Amostras Defeituosas (%)	99,4	100	99,7	100	96,9	100	100	99,0	99,0
Estatística Kappa	0,96	0,99	0,93	0,99	0,78	0,97	0,99	0,96	0,93
Tempo para a Criação do Modelo (s)	13,3	0,01	0,03	11,8	0,01	0,05	15,2	0,01	0,05

**Tabela 37 – Classificação de curto-circuito de estator considerando variação de frequência de alimentação de 20% a 100% do nominal - Motor 2**

Conjunto de Dados	ATV			G110			MM440		
	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	95,9	90,9	90,0	99,2	98,7	99,2	100	98,9	100
Acurácia das Amostras Saudáveis (%)	91,6	78,3	65,1	98,7	98,7	98,7	100	97,5	100
Acurácia das Amostras Defeituosas (%)	97,0	94,0	96,1	99,3	98,7	99,3	100	99,3	100
Estatística Kappa	0,87	0,72	0,66	0,98	0,96	0,98	1,00	0,97	1,00
Tempo para a Criação do Modelo (s)	13,7	0,01	0,24	14,4	0,01	0,03	13,0	0,01	0,02

Por meio da Tabela 36, verifica-se que na situação onde o Motor 1 é alimentado pelo inversor de frequência ATV, o classificador de padrões que faz a melhor separação entre as classes saudáveis e defeituosas é o  $k$ -NN. Nesse caso, são atingidas acurácias de classificação de 99,5%, 97,7% e 100% das amostras totais, saudáveis e defeituosas, respectivamente. O coeficiente Kappa de 0,99 confirma esses resultados. Os classificadores RNA MLP e SVM atingem resultados ligeiramente inferiores. No entanto, é importante salientar que os resultados obtidos também são promissores, tendo em vista que com a RNA MLP e o SVM foram classificadas corretamente 98,5% e 97,7% de todas as amostras, respectivamente. Sabe-se ainda que mesmo utilizando as amostras de 3% de curto-circuito de estator, que é considerado um defeito incipiente da máquina, as acurácias de classificação obtidas foram acima de 97,7%.

Para a situação em que o Motor 1 é alimentado pelo inversor de frequência G110, os algoritmos inteligentes MLP e SVM identificam corretamente, no mínimo,

99,2% de todas as amostras. Entretanto, observa-se que a RNA MLP atinge um resultado superior na identificação das amostras saudáveis. Os coeficientes Kappa de 0,99 e 0,97 para a RNA MLP e o SVM, respectivamente, indicam uma total concordância com os resultados atingidos.

Quando o Motor 1 é alimentado pelo inversor MM440, a Tabela 36 permite observar que os três classificadores apresentam acurácias de classificação satisfatórias, onde em todos os casos são obtidos valores acima de 97,6%. O classificador que obtém resultados superiores aos demais é a RNA MLP, onde identificam-se corretamente 99,5%, 97,7% e 100% das amostras globais, saudáveis e defeituosas, respectivamente. O índice Kappa de 0,99 confirma a boa capacidade dessa metodologia em realizar a separação das classes sem e com defeitos. Ainda, é importante destacar que o tempo para a criação do classificador é maior para a RNA MLP, totalizando 15,2 segundos.

Conforme os resultados experimentais apresentados na Tabela 37, em que utilizou-se o Motor 2 para esses referidos ensaios, observa-se que na situação onde esse motor é alimentado pelo inversor de frequência ATV, os melhores resultados são para o classificador RNA MLP. Neste caso, a RNA MLP tem uma maior capacidade na separação entre as classes saudáveis e com curto-circuito de estator. O classificador RNA MLP identifica corretamente 95,9% de todas as amostras, além de atingir um coeficiente Kappa de 0,87 que confirma esses promissores resultados. Já nas situações onde são empregados os algoritmos inteligentes *k*-NN e SVM, são classificados de forma adequada em torno de 90% de todo o conjunto de amostras. É importante salientar que nesses dois casos, entre 21,7% e 34,9% das amostras sem defeitos são identificadas incorretamente, pois há similaridade dos sinais entre as amostras sem defeitos e com curto-circuito de 3% de estator, os quais são caracterizados como um defeito incipiente da máquina.

Ainda na Tabela 37, são apresentados os resultados para os casos em que o Motor 2 é alimentado pelos inversores G110 e MM440. Nas duas situações, verifica-se a satisfatória separação entre as classes sem defeitos e com defeitos, independente do classificador utilizado. Observando todos os casos, são obtidas acurácias de classificação acima de 98,7% para o conjunto total de amostras. Além disso, essa tabela permite observar que o coeficiente mínimo de 0,96 obtido para esses ensaios, confirma a total concordância com os resultados obtidos. Analisando o tempo para a criação

do modelo classificador, nota-se que o classificador  $k$ -NN e o SVM necessitam de um tempo menor quando comparado com a RNA MLP de 0,01, 0,03 e 14,4 segundos, respectivamente.

Novos ensaios são realizados para a análise do desempenho do sistema proposto, em conformidade com a metodologia descrita na Seção 5.1.2 e na Seção 5.2.2. O conjunto de amostras para o treinamento dos classificadores é composto dos ensaios com frequências de alimentação de 12, 18, 24, 30, 36, 42, 54 e 60 Hz. Para a validação, são utilizados os ensaios com frequência de alimentação do inversor de 48 Hz. As Tabelas 38 e 39 exibem os resultados para os Motores 1 e 2, respectivamente.

**Tabela 38 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 1 alimentado por inversores de frequência - Curto-circuito de estator**

Conjunto de Dados	ATV			G110			MM440		
	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	100	100	92,0	98,0	92,0	92,0	100	100	90,0
Acurácia das Amostras Saudáveis (%)	100	100	60,0	100	80,0	70,0	100	100	70,0
Acurácia das Amostras Defeituosas (%)	100	100	100	97,5	95,0	97,5	100	100	95,0
Estatística Kappa	1,00	1,00	0,71	0,94	0,75	0,73	1,00	1,00	0,68
Tempo para a Criação do Modelo (s)	8,37	0,03	0,05	8,87	0,01	0,14	8,55	0,02	0,04

**Tabela 39 – Análise do comportamento do sistema proposto frente a amostras com condições de operação desconhecidas - Motor 2 alimentado por inversores de frequência - Curto-circuito de estator**

Conjunto de Dados	ATV			G110			MM440		
	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM	MLP	$k$ -NN	SVM
Classificador									
Acurácia de Todas as Amostras (%)	96,0	88,0	92,0	100	90,0	100	100	92,0	100
Acurácia das Amostras Saudáveis (%)	100	80,0	60,0	100	70,0	100	100	60,0	100
Acurácia das Amostras Defeituosas (%)	95,0	90,0	100	100	95,0	100	100	100	100
Estatística Kappa	0,88	0,65	0,71	1,00	0,68	1,00	1,00	0,71	1,00
Tempo para a Criação do Modelo (s)	28,8	0,03	0,02	14,0	0,03	0,03	14,0	0,01	0,03

Ao analisar a Tabela 38, observa-se que nos casos em que o Motor 1 é alimentado pelo inversor ATV ou pelo MM440, os algoritmos de classificação RNA MLP e  $k$ -NN diagnosticaram corretamente todas as amostras. Também, deve ser destacado que o custo computacional do algoritmo dos  $k$ -vizinhos é menor quando comparado a rede neural MLP. Já na situação em que o Motor 1 é alimentado pelo inversor de frequência G110, verifica-se que a RNA MLP apresenta resultado superior aos demais classificadores, identificando corretamente 98,0% de todas as amostras.

Para o conjunto de dados do Motor 2, nota-se que a rede neural MLP e as máquinas vetores de suporte apresentam os resultados mais promissores, conforme está demonstrado na Tabela 39. Analisando os dados desse motor alimentado pelo



inversor G110 ou pelo MM440, todas as amostras são classificadas de forma correta. Somente no caso em que emprega-se o inversor ATV para a alimentação do Motor 2 é que a rede neural apresenta resultado superior ao SVM.

Em geral, denota-se que o sistema é capaz de identificar a real situação da máquina mesmo diante de condições de operação desconhecidas. Ainda, os resultados apresentados nessa seção permitem afirmar que o classificador RNA MLP é o mais adequado para trabalhar com as medidas de informação mútua, pois nesse caso são alcançadas as maiores acurácias de classificação.

#### 5.4 QUADRO RESUMO DOS RESULTADOS EXPERIMENTAIS

Na Tabela 40 é apresentado o resumo dos resultados de classificação obtidos nos testes experimentais off-line. É importante destacar que avaliou-se a metodologia proposta para o monitoramento e a identificação de múltiplos defeitos em máquinas elétricas independente do seu tipo de alimentação. Ainda, na referida tabela, demonstram-se os resultados para as condições de variação no conjugado de carga de 10% a 120% do valor nominal, variação no desequilíbrio de tensão de alimentação até 10% e variação na frequência de alimentação de 20% a 100%.

**Tabela 40 – Quadro Resumo dos Resultados Experimentais**

Tipo de Alimentação	Motor	Tipo de Defeito		
		Rolamento	Rotor	Estator
Direto da Rede	1 CV	90,50% - MLP	93,80% - MLP	93,80% - MLP/SVM
	2 CV	92,00% - MLP	95,60% - MLP	91,70% - MLP/SVM
Inversor de Frequência - ATV	1 CV	97,30% - MLP	98,70% - MLP	99,50% - <i>k</i> -NN
	2 CV	98,10% - MLP	97,60% - MLP	95,90% - MLP
Inversor de Frequência - G110	1 CV	98,10% - MLP/SVM	99,70% - MLP	99,70% - MLP
	2 CV	99,70% - MLP/SVM	99,70% - MLP/SVM	99,20% - MLP/SVM
Inversor de Frequência - MM440	1 CV	99,50% - MLP/SVM	100% - MLP/SVM	99,50% - MLP
	2 CV	99,70% - <i>k</i> -NN	100% - MLP/SVM	100% - MLP/SVM

#### 5.5 COMPARATIVO COM OUTROS TRABALHOS ENCONTRADOS NA LITERATURA

Nesta seção, são apresentados algumas pesquisas encontradas na literatura que se relacionam com o presente trabalho. Destacam-se os aspectos relativos ao tipo de alimentação, às condições de operação, às metodologias para a extração de características e classificação dos padrões, e às acurácias para a identificação de

defeitos de rolamentos, barras quebradas de rotor e de estator.

Para o monitoramento e diagnóstico de falhas de rolamentos, os pesquisadores Picazo-Ródenas *et al.* (2015), Pandarakone *et al.* (2017), Dalvand *et al.* (2016), Delgado-Arredondo *et al.* (2017) e Jiang *et al.* (2019) alimentaram as máquinas diretamente da rede. Já nos trabalhos de Trachi *et al.* (2016), Leite *et al.* (2015) e Esfahani *et al.* (2014), as máquinas foram alimentadas por inversores de frequência. Nesse presente trabalho e nos estudos de Ali *et al.* (2019) e Ali *et al.* (2020), é importante destacar que são realizados ensaios experimentais tanto para uma alimentação senoidal quanto não-senoidal.

Na extração das características dos sinais, os autores Trachi *et al.* (2016), Leite *et al.* (2015), Pandarakone *et al.* (2017), Dalvand *et al.* (2016), Delgado-Arredondo *et al.* (2017), Esfahani *et al.* (2014), Jiang *et al.* (2019), Ali *et al.* (2019) e Ali *et al.* (2020) empregaram metodologias que analisam os sinais no domínio da frequência como medidas estatísticas, FFT, HT, IFMV, CEEMD, SVD e OMP. Na presente tese de doutorado, considerou-se a análise no domínio do tempo utilizando a MI entre os sinais de correntes de linha das fases A e B. Ainda, deve-se relatar que em Picazo-Ródenas *et al.* (2015) foi empregado imagens termográficas para a detecção dos defeitos de rolamentos.

Outro aspecto relevante refere-se as condições de operação em que as máquinas estiveram sujeitas como variações no conjugado de carga, no desequilíbrio de tensão e na frequência de alimentação. A Tabela 41 ilustra as particularidades de cada trabalho. Deve-se destacar que no presente trabalho, as máquinas estiveram sujeitas a essas três condições de operações, enquanto que nos demais trabalhos somente houveram variações no conjugado de carga, não havendo evidências de variações no desequilíbrio de tensão ou na frequência de alimentação.

Considerando as acurácias de classificação nos ensaios experimentais, observa-se que Trachi *et al.* (2016), Picazo-Ródenas *et al.* (2015), Leite *et al.* (2015), Dalvand *et al.* (2016) e Delgado-Arredondo *et al.* (2017) não especificaram os dados estatísticos, e sim, apresentaram análises gráficas dos resultados. No trabalho de Pandarakone *et al.* (2017), atingiram-se acurácias superiores a 96%. Entretanto, empregou-se apenas variação no conjugado de carga, não havendo evidências no texto do emprego de desequilíbrio de tensão na alimentação do motor. No artigo de

Esfahani *et al.* (2014) foram classificadas corretamente acima de 98% de todas as amostras, contudo, não há relatos da utilização de variações do torque de carga e da frequência de alimentação nos ensaios experimentais. No estudo de Jiang *et al.* (2019), a metodologia proposta obteve taxas de classificação superiores a 92%, mesmo com diversas condições de operação nos ensaios experimentais, tais como variações no conjugado de carga e no desequilíbrio de tensão de alimentação. Nos artigos de Ali *et al.* (2019) e Ali *et al.* (2020), foram alcançadas taxas de classificação superiores a 90% mesmo adotando diversas condições de operação como variação no conjugado de carga e variações nos níveis de tensão de alimentação. Já no presente trabalho, mesmo sob condições de variações no conjugado de carga, desequilíbrio de tensão e frequência de alimentação, foram atingidas taxas de classificação superiores a 90%. A Tabela 41 resume essa comparação para o monitoramento e diagnóstico de falhas de rolamentos.

**Tabela 41 – Resumo de alguns trabalhos relacionados ao diagnóstico de falhas de rolamentos**

Literatura	Alimentação	Variação			Extração de Características	Classificador	Acurácia (%)
		Carga	Tensão	Frequência			
Ref. [1]	Inversor	NE	NA	NE	LSE	FSCV	NE
Ref. [2]	Direto	Sim	NE	NA	Imagem Termográfica	NA	NE
Ref. [3]	Inversor	NE	NA	NE	Kurtosis	SES	NE
Ref. [4]	Direto	Sim	NE	NA	FFT	SVM	>96%
Ref. [5]	Direto	Sim	NE	NA	IFMV	Kurtosis	NE
Ref. [6]	Direto	NE	NE	NA	CEEMD	TFRG	NE
Ref. [7]	Inversor	NE	NA	NE	HT e FFT	QDA e SVM	>98%
Ref. [8]	Direto	Sim	Sim	NA	SVD	FIBL	>92%
Refs. [9]	Direto e Inversor	Sim	Sim	NE	TWD e OMP	SVM, k-NN e EC	>90%
Este trabalho	Direto e Inversor	Sim	Sim	Sim	MI	MLP	>90%

Ref. [1] - Trachi *et al.* (2016)/Ref. [2] - Picazo-Ródenas *et al.* (2015)/Ref. [3] - Leite *et al.* (2015)/Ref. [4] - Pandarakone *et al.* (2017)

Ref. [5] - Dalvand *et al.* (2016)/Ref. [6] - Delgado-Arredondo *et al.* (2017)/Ref. [7] - Esfahani *et al.* (2014)

Ref. [8] - Jiang *et al.* (2019)/Refs. [9] - Ali *et al.* (2019) e Ali *et al.* (2020)

NE - Não Especificado/NA - Não Aplicado/LSE - *Least Squares Estimation*/FFT - *Fast Fourier Transform*

FSCV - *Fault Severity Criterion Value*/SES - *Squared Envelope Spectrum*/IFMV - *Instantaneous Frequency of Motor Voltage*

HT - *Hilbert Transform*/TFRG - *Time Frequency Representation of Gabor*/QDA - *Quadratic Discriminant Analysis*

EC - *Ensemble Classifiers*

A Tabela 42 apresenta um comparativo dos trabalhos relativos a defeitos de barras quebradas de rotor. Nos estudos de Drif *et al.* (2017), Gyftakis *et al.* (2016), Moussa *et al.* (2017) e Dias e Pereira (2018), as máquinas foram alimentadas diretamente da rede elétrica. Além desse tipo de alimentação, em Malek *et al.* (2017), Sousa *et al.* (2017), Liboni *et al.* (2019) e no presente trabalho, os motores também foram alimentados por inversores de frequência.

Para a extração das características, Malek *et al.* (2017), Sousa *et al.* (2017), Drif *et al.* (2017), Gyftakis *et al.* (2016) e Moussa *et al.* (2017) analisaram os sinais no domínio da frequência utilizando TH e TF. O presente trabalho e o estudo de Liboni *et al.* (2019) analisaram os sinais no domínio do tempo por meio da MI entre os sinais de

correntes do estator das fases A e B, e da decomposição de componentes ortogonais dos sinais de tensão e de corrente, respectivamente. Por fim, Dias e Pereira (2018) analisaram os sinais tanto no domínio da frequência como no tempo, empregando PCA e outras medidas estatísticas.

Ao verificar as condições de operação em que as máquinas estiveram sujeitas, verifica-se que todos autores empregaram variação no conjugado de carga. Além disso, nos trabalhos de Gyftakis *et al.* (2016) e Malek *et al.* (2017) aplicaram-se variações no desequilíbrio de tensão e na frequência de alimentação das máquinas, respectivamente. No artigo de Liboni *et al.* (2019) e no presente estudo, as máquinas estiveram sujeitas a variações no conjugado de carga, ao desequilíbrio de tensão e a frequência de alimentação.

Em relação aos resultados experimentais, nota-se que Malek *et al.* (2017), Sousa *et al.* (2017), Drif *et al.* (2017), Gyftakis *et al.* (2016) e Moussa *et al.* (2017) demonstraram seus resultados por meio de análises gráficas. Taxas de classificação acima de 90% foram obtidas em Dias e Pereira (2018), mesmo com alterações nos níveis de torque de carga acoplado ao MIT. A metodologia proposta de Liboni *et al.* (2019) apresentou acurácias de precisão superiores a 98%, mesmo diante a diversos cenários experimentais. No presente trabalho, mesmo sob condições de variações no conjugado de carga, desequilíbrio de tensão e frequência de alimentação, a metodologia proposta conseguiu identificar acima de 93% de todas as amostras, conforme apresenta-se na Tabela 42.

**Tabela 42 – Resumo de alguns trabalhos relacionados ao diagnóstico de barras quebradas de rotor**

Literatura	Alimentação	Variação			Extração de Características	Classificador	Acurácia (%)
		Carga	Tensão	Frequência			
Ref. [1]	Direto e Inversor	Sim	NE	Sim	HT	ESA	NE
Ref. [2]	Direto e Inversor	Sim	NE	NE	FFT	ESA	NE
Ref. [3]	Direto	Sim	NE	NA	FFT	APSA/RPSA	NE
Ref. [4]	Direto	Sim	Sim	NA	FFT	ZSCSA	NE
Ref. [5]	Direto	Sim	NE	NA	DFT	FFA	NE
Ref. [6]	Direto	Sim	NE	NA	PCA	MLP	>90%
Ref. [7]	Direto e Inversor	Sim	Sim	Sim	OCD	SVM	>98%
Este trabalho	Direto e Inversor	Sim	Sim	Sim	MI	MLP	>93%

Ref. [1] - Malek *et al.* (2017)/Ref. [2] - Sousa *et al.* (2017)/Ref. [3] - Drif *et al.* (2017)/Ref. [4] - Gyftakis *et al.* (2016)

Ref. [5] - Moussa *et al.* (2017)/Ref. [6] - Dias e Pereira (2018)/Ref. [7] - Liboni *et al.* (2019)

NE - Não Especificado/NA - Não Aplicado/ESA - *Envelope Spectrum Analysis*/APSA - *Active Power Spectrum Analysis*

RPSA - *Reactive Power Spectrum Analysis*/ZSCSA - *Zero Sequence Current Spectrum Analysis*/FFA - *Fault Frequency Amplitude*

Quando são analisados as metodologias para o diagnóstico de falhas de estator, nos trabalhos de Das *et al.* (2010), Asfani *et al.* (2012), Seshadrinath *et al.* (2014b), Irlhoumah *et al.* (2018) e Surya *et al.* (2017), os motores foram alimentados diretamente

pela rede elétrica. Já em Wang *et al.* (2019a) e Vinayak *et al.* (2020), alimentam-se as máquinas elétricas por meio de inversores de frequência. No presente estudo, as máquinas são alimentadas por ambos os tipos de alimentação.

Na extração das características, o presente trabalho analisou os sinais no domínio do tempo, extraíndo as características mais significantes por meio da MI entre os sinais de corrente de linha das fases A e B. Wang *et al.* (2019a) também analisou os sinais no domínio do tempo, utilizando a deep AE para a extração das características dos sinais de corrente das máquinas. Já os demais autores utilizaram técnicas que trabalham no domínio da frequência, analisando os sinais por meio da TWC, TWD, DoV, RaV e FFT.

Quando refere-se às condições de operação das máquinas, pode ser verificado na Tabela 43 que apenas os trabalhos de Seshadrinath *et al.* (2014b), Irhoumah *et al.* (2018) e Surya *et al.* (2017) especificaram o emprego de variação no conjugado de carga. Já em relação ao desequilíbrio de tensão, somente Seshadrinath *et al.* (2014b) aplicou níveis de tensão diferentes na alimentação dos motores. Nos trabalhos de Wang *et al.* (2019a) e Vinayak *et al.* (2020), além de alterações nos níveis de conjugado de carga, os pesquisadores adotaram diversas faixas de frequência de alimentação das máquinas. É importante ressaltar que no presente trabalho, os MITs estiveram sujeitos a todas essas condições de operações descritas.

Em relação aos resultados experimentais, somente Surya *et al.* (2017) apresentou análises gráficas. Os demais autores especificaram os resultados por meio de dados estatísticos. Em Das *et al.* (2010) e Asfani *et al.* (2012) foram atingidas acurácias de classificação de 90% e superiores a 97%, respectivamente. Entretanto, não ficou evidenciado nos trabalhos a utilização de variações de carga e desequilíbrio de tensão. No artigo de Irhoumah *et al.* (2018), foram obtidas taxas de classificação acima de 98%, mesmo quando as máquinas estiveram sujeitas a níveis distintos de conjugados. Ainda, em Seshadrinath *et al.* (2014b), identificaram-se corretamente no mínimo 95% de todas as amostras, independente das situações de carga e níveis de tensão em que as máquinas estão sujeitas. As abordagens propostas por Wang *et al.* (2019a) e Vinayak *et al.* (2020) atingiram acurácias de classificação acima de 98%, mesmo com as máquinas sujeitas a diferentes níveis de conjugado de carga e da frequência de alimentação dos inversores. Já no presente trabalho, mesmo em diversas condições

de operação como variação no conjugado de carga, no desequilíbrio de tensão e na frequência de alimentação, foram obtidos resultados superiores a 91,7%. A Tabela 43 sintetiza essa comparação entre as diversas metodologias encontradas na literatura para a detecção de falhas de estator.

**Tabela 43 – Resumo de alguns trabalhos relacionados ao diagnóstico de falhas de estator**

Literatura	Alimentação	Variação			Extração de Características	Classificador	Acurácia (%)
		Carga	Tensão	Frequência			
Ref. [1]	Direto	NE	NE	NA	TWC	SVM	90%
Ref. [2]	Direto	NE	NE	NA	TWD	RNA	>97%
Ref. [3]	Direto	Sim	Sim	NA	DTCWT	SVM	>95%
Ref. [4]	Direto	Sim	NE	NA	DoV/RaV	MF	>98%
Ref. [5]	Direto	Sim	NE	NA	FFT	SSA	NE
Ref. [6]	Inversor	Sim	NA	Sim	Deep AE	Softmax	>98,8%
Ref. [7]	Inversor	Sim	NA	Sim	TWD	SVM	>99,7%
Este trabalho	Direto e Inversor	Sim	Sim	Sim	MI	MLP	>91,7%

Ref. [1] - Das *et al.* (2010)/Ref. [2] - Asfani *et al.* (2012)/Ref. [3] - Seshadrinath *et al.* (2014b)/Ref. [4] - Irhoumah *et al.* (2018)  
 Ref. [5] - Surya *et al.* (2017)/Ref. [6] - Wang *et al.* (2019a)/Ref. [7] - Vinayak *et al.* (2020)/NE - Não Especificado/NA - Não Aplicado  
 DTCWT - *Dual Tree Complex Wavelet Transform*/DoV - *Difference of Variation*  
 RaV - *Ratio of the Amplitudes*/SSA - *Signal Spectrum Analysis*

## 5.6 CONCLUSÃO DO CAPÍTULO

Esse capítulo avaliou os algoritmos inteligentes RNA MLP, *k*-NN e SVM no diagnóstico de defeitos de rolamentos, barras quebradas de rotor e curto-circuito de estator em motores de indução trifásicos acionados diretamente pela rede ou por inversores de frequência, operando em regime permanente e sujeito a vários níveis de carga, desequilíbrios de tensão e frequências de alimentação.

Em geral, os melhores desempenhos foram atingidos com o classificador RNA MLP, apesar do tempo destinado para a criação do modelo classificador ser maior quando comparado aos demais classificadores. Quando analisam-se os resultados experimentais para os MITs acionados por inversores de frequências, observa-se que há uma variação nas taxas de classificação dependendo do inversor empregado, isso se deve a frequência de chaveamento específica de cada inversor, conforme já foi analisado no trabalho de Martin-Diaz *et al.* (2017).

Os resultados apresentados nesse trabalho são promissores para o diagnóstico de múltiplas falhas de MITs independente do seu tipo de alimentação. Assim, essa abordagem proposta pode ser utilizada como ferramenta de um sistema de monitoramento de defeitos, podendo aplicá-la em uma estratégia de diagnóstico em tempo real, colaborando em um programa de manutenção programada do sistema de produção industrial. No Capítulo 6 são apresentadas a metodologia, bem como os resultados da

implementação em hardware da metodologia para o diagnóstico de curto-circuito entre as espiras do estator em MITs alimentados diretamente pela rede elétrica.

## **6 SISTEMA EMBARCADO PARA O DIAGNÓSTICO DE CURTO-CIRCUITO DE ESTATOR EM MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO TEORIA DA INFORMAÇÃO E REDES NEURAIS ARTIFICIAIS**

A rápida evolução e modernização dos processos industriais foram acompanhados por um aumento na complexidade das estruturas e dos diversos equipamentos presentes nesses processos. Como consequência desse avanço, as organizações estão buscando garantir a confiabilidade dos equipamentos contra falhas inesperadas nos processos industriais, tais quais podem resultar, principalmente, em grandes prejuízos econômicos (BENGHERBIA *et al.*, 2017).

O monitoramento baseado nas condições dos equipamentos, como por exemplo, por meio de sinais de vibrações, temperatura, corrente, tensão, dentre outras grandezas, é uma das mais eficazes metodologias de manutenção preditiva, pois fornece a condição real do equipamento, o que permite decidir o momento ideal para a realização da manutenção, aumentando a confiabilidade e a eficiência dos sistemas (HUANG *et al.*, 2015; BENGHERBIA *et al.*, 2017).

Conforme já descrito no Capítulo 1, as máquinas rotativas são elementos fundamentais nos processos produtivos industriais, dentre as quais pode-se destacar o MIT, por possuir uma estrutura simples e um baixo custo de manutenção, além de demonstrar bom desempenho a um reduzido custo operacional (HMIDA; BRAHAM, 2016; GUVEN; ATIS, 2018). Ainda que tenham confiabilidade na operação, os MITs estão sujeitos a várias falhas internas, que podem prejudicar a sua operação normal. Por esse motivo, a detecção de defeitos no estator ainda em um estágio inicial é essencial para aumentar a confiabilidade e garantir a disponibilidade dos equipamentos. Tendo isso em vista, o desenvolvimento de metodologias para o monitoramento e diagnóstico de falhas de estator são fundamentais nesse processo, pois possibilitam que o operador tome ações adequadas, evitando a ocorrência de paradas não-programadas e falhas mais prejudiciais às máquinas.

Um aspecto essencial a ser abordado é o método utilizado para a coleta e análise destes sinais, onde duas abordagens podem ser empregadas: i) uma plataforma central ou ii) dispositivo in loco<sup>1</sup> de processamento de dados. A utilização da plataforma

---

<sup>1</sup>De acordo com o Manual de Comunicação do Senado Federal. Disponível em:



central, geralmente, consiste em coletar os sinais por meio de sensores distribuídos ao longo do ambiente industrial e, então, enviá-los para um servidor para a tomada de decisão. Nesse tipo de estação de trabalho pode ser utilizada uma grande quantidade de dados para a análise da condição da máquina. No entanto, é importante destacar que os sensores e toda a estrutura de comunicação necessária devem estar previamente instalados, resultando no aumento do custo desse tipo de sistema. Já a utilização de dispositivos in loco utiliza equipamentos dedicados em processos críticos ou portáteis e, geralmente, envolvem o uso de um microcontrolador (MCU) ou um processador digital de sinais (DSP), sensores e periféricos. A abordagem portátil pode ser usada para verificar inúmeras máquinas em uma planta industrial, porque é flexível e móvel. No entanto, ainda é pouco utilizado esse nível de automação por meio de instrumentos portáteis (GUVEN; ATIS, 2018; LU *et al.*, 2020; NAHA *et al.*, 2017; LU *et al.*, 2017; PANIGRAHY *et al.*, 2016; HMIDA; BRAHAM, 2016; LU *et al.*, 2018). Ainda, deve-se destacar que o monitoramento portátil que emprega os indicadores das condições do motor, como tensão, corrente, temperatura, intensidade de vibração e nível de ruído, podem ser exibidos imediatamente para o operador, colaborando com a rápida tomada de decisão.

Assim, esse trabalho propõe a utilização de um sistema embarcado em hardware para o diagnóstico de curto-circuito entre as espiras do estator de MITs de diversas potências acionados diretamente pela rede elétrica. Todos os algoritmos necessários para a coleta e conversão A/D dos sinais de corrente, bem como para o processamento desses sinais são embarcados em hardware dedicado, permitindo identificar o estado de operação da máquina. Para isso, é utilizada uma ferramenta fundamentada na Teoria da Informação para a extração das características mais relevantes dos sinais e uma rede neural artificial MLP para a classificação dos padrões, em conformidade com os resultados experimentais observados nos testes off-line apresentados no Capítulo 5. É importante destacar que a análise do comportamento da metodologia embarcada para o diagnóstico de curto-circuito de estator em MITs alimentados diretamente pela rede elétrica consiste num estudo da viabilidade da implementação da metodologia em hardware. Em trabalhos futuros está prevista a análise de outros tipos de defeitos bem como para outro tipo de alimentação da máquina.

Com o objetivo de validar o sistema proposto nesse trabalho, são realizados ensaios experimentais off-line e on-line nos motores de 0,74 kW (Motor 1) e 1,48 kW (Motor 2). Nos testes off-line, foram coletadas experimentalmente 720 amostras com os motores operando em regime permanente, conectados de fontes de alimentação senoidais diretamente da rede elétrica, sob diversas condições de operação como variação no desequilíbrio de tensão de até 4%, variação no conjugado de carga ( $10\% \leq T_n \leq 120\%$ , onde  $T_n$  é o torque nominal), e níveis de curto-circuito entre as espiras de estator de 3% e 5%.

É importante destacar que os testes iniciais off-line foram executados no ambiente computacional Matlab®. Além disso, deve ser ressaltado que o desenvolvimento dos algoritmos da informação mútua, bem como o treinamento do classificador de padrões MLP foram realizados no software Matlab®. Na implementação em hardware da RNA MLP, observou-se que os pesos sinápticos e os limiares de ativação fornecidos pelo WEKA produziam resultados incompatíveis aos apresentados no Capítulo 5. Após a realização do treinamento e a implementação dos algoritmos em hardware, novos ensaios são executados de forma on-line para a validação da metodologia.

## 6.1 IMPLEMENTAÇÃO DA METODOLOGIA EMBARCADA EM HARDWARE

Nesse trabalho, utiliza-se um conjunto de dados experimentais obtidos por meio da coleta dos sinais de corrente de dois MITs funcionando sem defeitos e com curto-circuito entre as espiras do estator emulando as diversas situações adversas de um ambiente industrial.

A reprodução do curto-circuito de estator baseou-se no procedimento de simulação de um defeito na isolação do enrolamento. Os enrolamentos de estator foram rebobinados, possibilitando construir diversas derivações. É importante salientar que as bobinas foram isoladas com verniz, respeitando as medidas originais e a classe de isolamento do motor. Ainda, todas as três fases do enrolamento do estator foram preparadas para possibilitar emular defeitos de isolamento entre espiras, viabilizando a realização de ensaios experimentais com 3% e 5% de curto-circuito entre as espiras de estator.

Conforme já descrito no início desse capítulo, o conjunto de dados experimentais é composto de 720 ensaios executados em dois motores trabalhando em regime

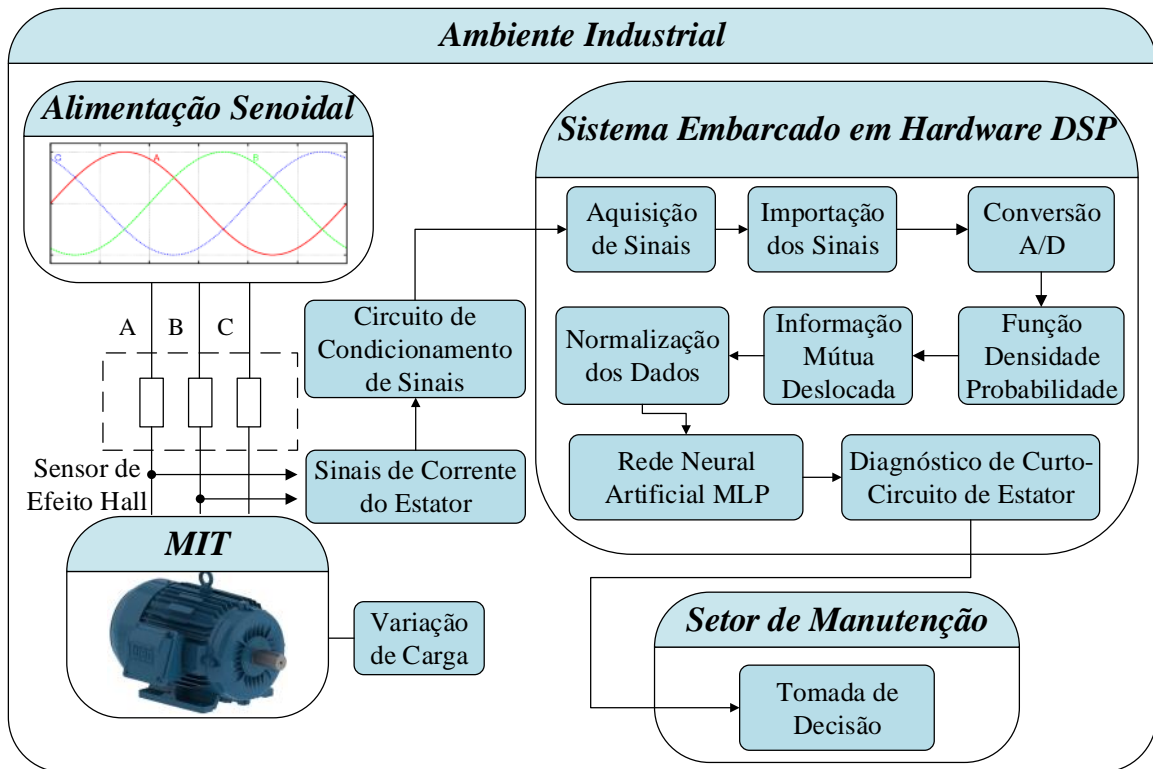
permanente, conectados diretamente à rede elétrica e sujeitos a diversas condições de operação como variações no desequilíbrio de tensão e no conjugado de carga. Estas condições de operação foram empregadas para os MITs em todos os níveis de defeitos, ou seja, sem falha e com falha de curto-circuito entre as espiras do estator de 3% e 5%.

As falhas de estator podem evoluir rapidamente para a parada total do processo e podem gerar grandes prejuízos financeiros. Neste contexto, tem crescido a demanda na indústria por dispositivos portáteis de monitoramento e diagnóstico de falhas em motores, que possibilitam uma estratégia proativa para a sua manutenção (LU *et al.*, 2020). Assim, nesta seção é apresentada a implementação do sistema proposto embarcado em hardware, cuja capacidade de processamento é adequada à aplicação das ferramentas de extração de características e classificação de padrões para o monitoramento e diagnóstico de curto-circuito entre espiras do estator em MITs.

Ainda, a seção descreve o processador digital de sinais utilizado no sistema, as ferramentas para a extração de características dos sinais de correntes de linha trifásicas de estator por meio da teoria da informação, bem como os dados que servirão de entrada do classificador de padrões RNA MLP. A Figura 21 apresenta a organização geral de desenvolvimento da metodologia proposta, onde seus detalhes são discutidos ao longo desta seção. Conforme ilustrado na Figura 21, o sistema proposto auxilia o operador na tomada de decisão do momento mais adequado para a manutenção no equipamento.

Os sistemas embarcados são capazes de implementar uma rotina para a realização de tarefas previamente definidas, pois combinam as funções de hardware com atributos de software. Assim, as partes que constituem o sistema podem ser definidas como elementos de software e elementos de hardware, permitindo ao DSP além do processamento de dados, a capacidade de executar a aquisição dos sinais a partir de seus blocos periféricos de conversão A/D.

Neste trabalho, empregou-se o DSP TMS320F28379D da empresa Texas Instruments, presente no kit de desenvolvimento LAUNCHXL-F28379D. A seleção desse hardware fundamenta-se nas suas características, tais como: CPU dual-core de 32 bits, com suporte a ponto flutuante, funções trigonométricas e a números complexos; *clock* base de 200 MHz; 16 canais de conversão analógica para digital; 3 saídas de conversão digital para analógica; 512 kB de memória flash por núcleo e 102 kB de RAM




**Figura 21 – Metodologia embarcada em hardware DSP para o diagnóstico de curto-circuito entre espiras de estator de MITs.**

**Fonte: Autoria própria**

por núcleo.

A alimentação do kit deve ser realizada por meio de uma conexão mini USB, ou a partir de uma fonte de 3,3 V ou 5 V. O referido DSP também possui capacidade de memória e processamento suficientes para a coleta e o tratamento de dados. Ainda, o microprocessador TMS320F28379D suporta uma ampla faixa de temperatura ambiente (-40°C a 125°C), o que torna ainda mais atrativo o seu uso em aplicações industriais. A Figura 22 apresenta o kit de desenvolvimento LAUNCHXL-F28379D.

Nesse estudo, a ferramenta de extração de características utiliza os sinais de corrente elétrica das fases A e B dos MITs. Esses sinais são coletados individualmente por meio de sensores de efeito Hall, os quais devem transmitir os sinais às entradas analógicas do DSP. O conversor A/D do DSP é capaz de realizar a leitura de sinais de corrente de linha limitados ao intervalo de 0 a 3 V a uma frequência de amostragem de 15,5 kHz adotado nesse trabalho. Esses sinais são convertidos em valores discretos no conversor A/D, para que o DSP possa executar a leitura e o processamento de forma adequada. Portanto, os sinais coletados pelos sensores Hall devem ser previamente



**Figura 22 – Kit de desenvolvimento LAUNCHXL-F28379D empregado no sistema proposto de diagnóstico de falhas de estator.**

**Fonte: Autoria própria**

condicionados, de forma a adequar sua faixa de valores às das entradas do periférico.

No próximo passo, inicia-se o estágio para a extração das características dos sinais por meio da informação mútua deslocada. O cálculo da DMI previamente descritos no Capítulo 3, foi desenvolvido em linguagem C e implementado no DSP. Inicialmente, a partir de histogramas com 16 intervalos de classes, devem ser calculadas as PDFs conjunta e marginais dos sinais de correntes das fases A e B dos MITs. Após, executa-se o cálculo para encontrar o valor da informação mútua, utilizando a Equação 3. Enquanto as amostras referentes à corrente do estator da fase A do motor permanecem fixas, a corrente do estator da fase B é deslocada em uma amostra por iteração, repetindo recursivamente esse processo até um deslocamento  $\tau$  de 150 amostras. Assim, armazena-se o valor da informação mútua para cada iteração em uma matriz, para enfim obter a informação mútua deslocada. O pseudocódigo intitulado de Algoritmo 1 ilustra o processo para o cálculo da informação mútua deslocada.

Como já citado nesse estudo, para o cálculo das PDFs são necessários a estimação dos histogramas por meio dos sinais amostrados, sem a necessidade de funções de estimação. Deve ser salientado que o histograma torna-se mais representativo quanto maior a quantidade de dados de um sinal. Assim, após a implementação do algoritmo da DMI no hardware DSP, deve-se avaliar o desempenho do mesmo frente ao algoritmo desenvolvido no ambiente do Matlab®. Além disso, investiga-se a topologia da rede neural MLP mais adequada ao sistema. Na próxima seção, são apresentadas

### Algoritmo 1 – Informação Mútua Deslocada

---

**inserir** Deslocamento  $\tau$ , Corrente elétrica da fase A, Corrente elétrica da fase B  
 Amostrar os sinais de corrente elétrica das fases A e B ( $i_a$  e  $i_b$ )  
 Preencher o histograma para a corrente elétrica da fase A  
**repita**  
 Preencher o histograma para a corrente elétrica da fase B  
 Preencher o histograma conjunto para ambas correntes  $i_a$  e  $i_b$   
 Determinar a PDF marginal da corrente  $i_a$   
 Determinar a PDF marginal da corrente  $i_b$   
 Determinar a PDF conjunta entre as correntes  $i_a$  e  $i_b$   
 Determinar a MI entre a corrente  $i_a$  e a corrente  $i_b$   
 Deslocar em uma amostra os dados da corrente  $i_b$   
**até** Deslocamento de  $\tau$  amostras  
**imprime** Informação mútua atrasada entre os sinais das correntes elétricas das fases A e B

---

**Fonte: Autoria própria.**

essas duas análises que constituem os resultados experimentais off-line da estrutura embarcada.

#### 6.1.1 Resultados Experimentais Embarcados Off-line

Nesta seção, são apresentados os resultados experimentais embarcados de forma off-line. Neste contexto, as amostras de dados experimentais previamente coletadas são carregadas no hardware DSP para aferir o desempenho dessa ferramenta frente ao Matlab®. Esse estágio da implementação da metodologia é extremamente importante para investigar o número de amostras dos sinais de correntes necessárias para produzir a assinatura da DMI com um custo computacional otimizado sem perder a sua característica.

Assim, realizou-se a comparação entre a performance do sistema embarcado ao algoritmo desenvolvido no software Matlab®, ambos com os dados amostrados em 15,5 k amostras/segundo. Assim, foi possível aferir o custo computacional e memória necessária para a implementação do algoritmo para o cálculo da DMI no DSP.

Para determinar o grau de similaridade entre os sistemas, utiliza-se a Raiz do Erro Quadrático Médio (RMSE - *Root Mean Squared Error*) para realizar a avaliação, definida pela Equação 12.

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (x_j - y_j)^2} \quad (12)$$

onde  $N$  representa o número de pontos da DMI,  $x_j$  consiste no  $j$ -ésimo valor de

informação mútua obtido via MATLAB® e por fim  $y_j$  demonstra o valor de informação mútua para a respectiva iteração proveniente do sistema embarcado. A Tabela 44 apresenta a quantidade de pontos fornecidos a ambos os sistemas tanto em DSP quanto no Matlab®.

**Tabela 44 – Quantidade Necessária de Pontos das Correntes para a Estimação das PDFs em Comparação entre o DSP e o Matlab®**

Experimento	Dados fornecidos ao DSP		Dados fornecidos ao Matlab	
	Fase A	Fase B	Fase A	Fase B
1	2000	2150	2000	2150
2	2000	2150	4000	4150
3	2000	2150	7000	7150
4	2000	2150	10000	10150
5	2000	2150	70000	70150

Assim, o desempenho do sistema é expresso em relação da sua Raiz do Erro Quadrático Médio, confrontando com os resultados obtidos para cada experimento via Matlab®, conforme é demonstrado na Tabela 45.

**Tabela 45 – Desempenho do Sistema Proposto Implementado em DSP Comparado ao Matlab®**

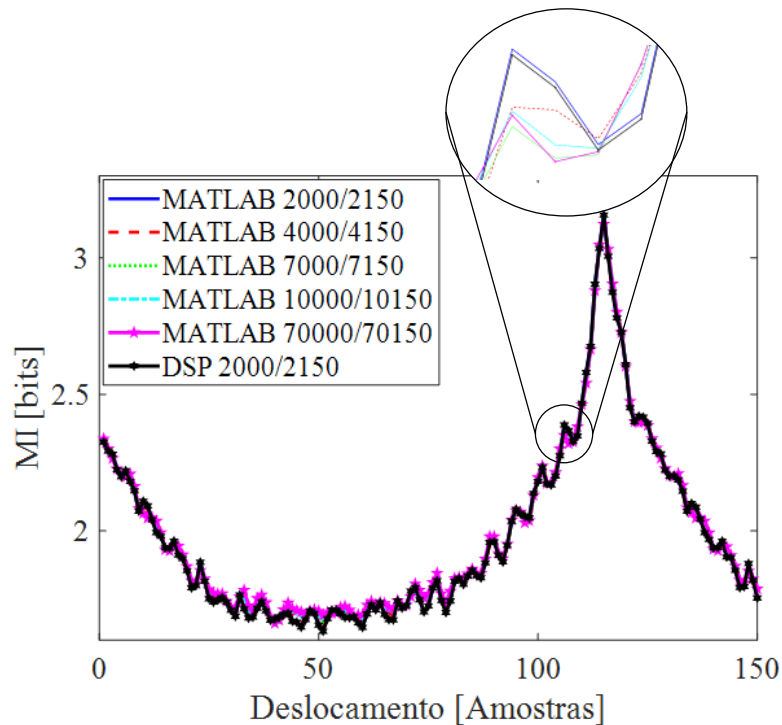
Experimento	RMSE (%)
1	0,2495
2	1,1785
3	1,9935
4	1,8891
5	2,3872

Na Tabela 45, observa-se a similaridade entre valores de informação mútua provenientes do software Matlab® e os alcançados pelo sistema embarcado em hardware. No experimento 5, que é considerado o pior caso, tem-se a maior diferença entre a quantidade dos pontos dos sinais de corrente elétrica com RMSE de 2,3872%.

A Figura 23 apresenta a comparação gráfica entre as diversas curvas características da DMI para os experimentos descritos Matlab® versus DSP para uma dada condição de operação da máquina. Neste caso, o Motor 1 está operando à vazio, ou seja, sem carga adicional aplicada ao eixo, em condição saudável, e sendo alimentado diretamente por tensões senoidais simétricas e equilibradas.

Por meio da Figura 23 e pela Tabela 45, a DMI implementada em hardware DSP tem resultados similares à estimada em Matlab®, apresentando uma RMSE satisfatória para a aplicação proposta nesse trabalho.

Ainda, verificou-se por meio de análises experimentais que ao selecionar a mesma taxa de aquisição de 15,5 k amostras/segundo, o tempo para a coleta de 70000



**Figura 23 – Análise da Informação Mútua Calculada pelo Sistema Proposto Implementado em DSP Comparado com as Estimadas pelo Matlab®**

**Fonte: Autoria própria**

amostras é superior ao tempo para a aquisição de 2000 amostras. Enquanto que a duração para a aquisição de 70000 amostras é de 4,52 segundos, 2000 amostras são coletadas em 0,13 segundos. Mesmo no experimento 5, onde a máquina poderia ter sofrido uma ligeira variação de tensão de alimentação e/ou variação de conjugado de carga em algum momento da coleta das amostras, observa-se que a curva característica da DMI implementada em DSP apresenta comportamento análogo à curva característica estimada no Matlab®. Assim, levando em consideração a relação eficiência e espaço de memória disponível do hardware, definiu-se utilizar 2000 e 2150 amostras dos sinais de correntes de linha das fases A e B do motor.

Após essa definição, são estimadas as DMIs para todas as condições de operação das máquinas, previamente citadas nesse capítulo. Para cada uma dessas condições, apresenta-se uma curva característica da DMI. Em seguida, deve-se normalizar os valores da DMI entre 0 e 1 em relação ao maior valor da informação mútua ( $MI_{max}$ ) obtido em todo o conjunto de dados. Por fim, é obtida a matriz de entrada da rede neural MLP para a identificação de curto-circuito entre as espiras do estator em MITs, onde cada dado é composto pelas 150 amostras deslocadas entre as correntes



das fases A e B. É importante destacar que as amostras dessa matriz de dados são separadas em classes de acordo com o seu tipo de condição de operação, as amostras sem falha e com defeitos no estator são definidas com *tags* de saída iguais a 0 e 1, respectivamente. Além disso, deve ser novamente ressaltado que a rede neural MLP foi treinada no ambiente Matlab®, pois os parâmetros da rede gerados pelo WEKA foram incompatíveis com a implementação em hardware quando comparados aos resultados de classificação obtidos usando a referida plataforma no computador.

No estágio de classificação de padrões, o conjunto de amostras foi dividido em três subconjuntos, de modo que dois grupos foram empregados durante a etapa de treinamento do classificador, e o terceiro foi utilizado para a validação. Ou seja, do conjunto total de 360 amostras por motor, 240 amostras são utilizadas na etapa de treinamento e 120 amostras são apresentadas à validação. O treinamento da rede neural artificial do tipo MLP é realizado através do algoritmo *backpropagation*, conforme descrito no Capítulo 3.

Ainda, com o intuito de obter uma topologia de RNA com desempenho satisfatório na DSP, foi realizada uma análise de cinco topologias, as quais foram definidas heurísticamente no software Matlab®. Executou-se essa análise com a finalidade de avaliar a utilidade da RNA com base em seu desempenho na etapa de validação, bem como a quantidade de memória de dados empregada em sua implementação. É importante destacar que somente houve variação no número de neurônios e no número de camadas intermediárias. Em todos os testes, definiu-se a taxa de aprendizagem para o treinamento de 0,3, o termo *momentum* de 0,2 e o número máximo de épocas para o treinamento de 500, além da utilização de funções de ativação logística para as camadas intermediárias e linear para a camada de saída. Nas Tabelas 46 e 47 são apresentados os resultados dessa análise para o Motor 1 e para o Motor 2, respectivamente.

**Tabela 46 – Resultados da viabilidade computacional de diversas topologias de RNA - Motor 1**

Topologia	Camadas (Neurônios)			Acurácia (%)	Memória (kB)
	<i>Hidden Layer 1</i>	<i>Hidden Layer 2</i>	<i>Output</i>		
1	5	-	1	96,67	3,044
2	10	-	1	97,50	6,084
3	15	-	1	95,00	9,124
4	4	2	1	97,50	2,468
5	5	2	1	98,33	3,080

**Tabela 47 – Resultados da viabilidade computacional de diversas topologias de RNA - Motor 2**

Topologia	Camadas (Neurônios)			Acurácia (%)	Memória (kB)
	<i>Hidden Layer 1</i>	<i>Hidden Layer 2</i>	<i>Output</i>		
1	5	-	1	97,50	3,044
2	10	-	1	98,33	6,084
3	15	-	1	98,33	9,124
4	4	2	1	99,17	2,468
5	5	2	1	99,17	3,080

Observa-se por meio das Tabelas 46 e 47 que a Topologia 4 (4-2-1) alcança um desempenho promissor no diagnóstico de curto-circuito entre as espiras do estator de ambos os motores, atingindo taxas de classificação corretas de 97,5% e 99,17% de todas as amostras para os Motores 1 e 2, respectivamente. Ainda, é importante destacar que essa topologia requer uma menor quantidade de memória de dados para a implementação no DSP, quando comparado com as outras topologias. Este fato ocorre devido a menor quantidade de neurônios na primeira camada escondida. Por meio das Tabelas 46 e 47, verifica-se que a Topologia 4 utiliza de 2,468 kB da memória do DSP. Assim, em virtude dessas características, principalmente baseado no critério de maior razão entre desempenho e quantidade de memória de dados, a Topologia 4 é a mais adequada a metodologia. Na próxima seção, são apresentados os resultados experimentais obtidos a partir da implementação da metodologia no DSP TMS320F28379D.

### 6.1.2 Resultados Experimentais Embarcados On-line

Após a análise dos resultados de classificação de padrões no Matlab®, implemen- tam-se as seguintes rotinas no DSP: i) aquisição de dados, ii) extração de características por meio da DMI e iii) classificação de padrões. Esta implementação em hardware embarcado tem por objetivo a identificação de curto-circuito entre as espiras do estator em MITs submetidos a condições de operação análogas a aquelas encontradas no setor industrial, tais como desbalanço de tensão e variação do torque de carga mecânica no eixo do motor de forma on-line.

Assim, 120 novos ensaios foram realizados com o objetivo de validar o sistema embarcado proposto neste trabalho. É importante destacar que esses testes foram realizados de forma on-line e que cada um dos motores estiveram sujeitos a variações no conjugado de carga no eixo das máquinas de 10% à 120% do seu valor nominal e

alterações nos níveis de desequilíbrio das tensões de alimentação de até 4%. A Tabela 48 apresenta os resultados de classificação para o Motor 1 e para o Motor 2.

**Tabela 48 – Validação da metodologia proposta em hardware dedicado para o diagnóstico de curto-circuito entre as espiras de estator em MITs - Motores 1 e 2**

Conjunto de Dados	Motor 1			Motor 2		
	≤0,5%	≤2%	≤4%	≤0.5%	≤2%	≤4%
Desequilíbrio de Tensão						
Acurácia de Todas as Amostras (%)	100	100	95,0	100	100	96,7
Acurácia das Amostras Saudáveis (%)	100	100	95,0	100	100	95,0
Acurácia das Amostras Defeituosas (%)	100	100	95,0	100	100	97,5
Estatística Kappa	1,00	1,00	0,89	1,00	1,00	0,93

Analisando a Tabela 48, verifica-se que nos testes foram atingidas taxas de acurácia global acima de 95%. Nos ensaios realizados utilizando o motor de 0,74 kW, observa-se que são classificadas corretamente 95,0% tanto das amostras sem falha quanto das amostras com curto-circuito entre as espiras do estator. É importante destacar que as 02 amostras defeituosas classificadas de forma inadequada, foram as amostras com curto-circuito de 3% entre o total de espiras do enrolamento, o qual é considerada um defeito em estágio inicial. Assim, com a evolução do defeito, o sistema prontamente identifica a sua ocorrência, mesmo em situações onde há variações no desequilíbrio das tensões de alimentação da máquina. O índice Kappa de 0,89 confirma os resultados obtidos, tendo que vista que valores acima de 0,80 indicam uma total concordância com os resultados de classificação (LANDIS; KOCH, 1977).

Já para o caso dos testes realizados utilizando o motor de 1,48 kW, a metodologia apresenta resultados similares. São identificadas de forma errônea apenas 02 amostras, sendo 01 amostra sem defeito e 01 amostra com defeito. Assim, tem-se acurácias de classificação de 95,0% e 97,5% das amostras sem falhas e com falhas, respectivamente, conforme ilustrado na Tabela 48.

Novamente, deve-se ressaltar que na situação em que as tensões de alimentação do motor estão com desequilíbrio de até 2%, todas as amostras são classificadas corretamente, independentemente do nível de conjugado de carga no eixo da máquina. Quando aumenta o desequilíbrio para até 4%, a metodologia identifica de forma inadequada 01 amostra com curto-circuito de até 3%.

Assim, quando há a progressão do defeito, o sistema já reconhece a presença da falha, auxiliando o operador de manutenção na tomada de decisão. O coeficiente Kappa de 0,93 ratifica os resultados de validação para os ensaios realizados utilizando o motor de 1,48 kW.

Os resultados apresentados nessa seção retratam o alto desempenho do sistema embarcado on-line adotado frente as adversidades que podem ser encontradas em um ambiente industrial, como variação de torque no eixo, desequilíbrio entre as tensões nas fases A e B, e variação no nível de curto-circuito entre espiras. Assim, uma das contribuições desta Tese consiste em apresentar a implementação da DMI e da RNA embarcados em hardware de relativo baixo custo para a identificação de falhas em máquinas elétricas. Em seguida, são apresentadas as conclusões do capítulo.

## 6.2 CONCLUSÃO DO CAPÍTULO

Esse capítulo avaliou a implementação da metodologia proposta em um hardware de baixo custo para a identificação de falhas de curto-circuito de estator em máquinas elétricas. Para a implementação em hardware DSP, avaliou-se, principalmente, a otimização dos algoritmos da DMI e da RNA MLP, tendo em vista o alto custo computacional da estratégia de extração características proposta, pois a mesma emprega histogramas dos sinais analisados para a estimação das PDFs.

Os resultados apresentados nesta seção confirmam a viabilidade do monitoramento on-line para o diagnóstico de curto-circuito de estator em MITs acionados diretamente pela rede elétrica, mesmo estando sujeitos a várias condições de operação como diferentes níveis de conjugado de carga e desequilíbrio da tensão de alimentação. Além disso, analisou-se o comportamento do sistema quando os MITs estão em condições incipientes de curto-circuito de estator, como é o caso do curto-circuito de 3%. Mesmo nessa situação, a metodologia apresentou resultados promissores, pois quando há a progressão do defeito, o sistema prontamente realiza o diagnóstico eficiente da condição dos MITs.

Assim, a metodologia implementada em hardware pode ser empregada como ferramenta de um sistema de diagnóstico de curto-circuito entre espiras de estator em MITs, colaborando para a tomada de decisão do operador que está num ambiente industrial. No Capítulo 7 são apresentadas as conclusões e diretrizes futuras desse trabalho.

## 7 CONCLUSÕES

Este trabalho apresentou uma abordagem alternativa para o diagnóstico de defeitos de rolamentos, barras quebradas de rotor e curto-circuito de estator em MITs independentemente do seu tipo de alimentação (senoidal ou não-senoidal), sendo baseada em medidas de associação da informação mútua e sistemas inteligentes. Os ensaios experimentais foram realizados utilizando-se um conjunto de dados composto por vários sinais do MIT sujeito a diferentes condições de operação, como variação do conjugado de carga, desequilíbrio entre as fases e variação na frequência de alimentação. Ainda, nos referidos ensaios foram emuladas situações adversas de funcionamento da máquina encontradas em ambiente industrial, tais como desgaste abrasivo de rolamentos, barras quebradas de rotor e curto-circuito de estator.

Na etapa de extração de características, utilizou-se a MI para calcular as medidas de associação entre os sinais de corrente das fases A e B do motor, a fim de extrair as características de falhas, e assim monitorar e diagnosticar a real situação da máquina. Então, calculou-se a MI para todo o conjunto de dados.

A partir das curvas características da MI das amostras do conjunto de dados, observa-se que as mesmas são similares independente da condição de operação dos motores. O aumento no nível de conjugado de carga acarreta em um aumento também do valor máximo da MI. Uma outra característica consiste na alteração no desequilíbrio negativo da tensão da fase A, a qual produz um atraso e o desequilíbrio positivo de tensão na fase B juntamente com o desequilíbrio negativo na fase C ocasiona um avanço em relação à curva com tensões equilibradas. Além disso, é importante observar que os valores máximos da MI diminuem em função do aumento do nível de desequilíbrio de tensão.

Essas análises fundamentadas na variação de carga e desequilíbrio entre as tensões, também podem ser visualizadas quando o motor está operando com defeitos, sejam falhas de rolamentos, barras quebradas de rotor ou curto-circuito de estator, não importando qual o nível de severidade do defeito e independentemente da potência do motor.

Após, realizou-se a avaliação do classificador de padrões mais adequado a esse tipo de dados. Neste trabalho, foram utilizados os classificadores de padrões RNA

MLP,  $k$ -NN e SVM. Os resultados identificaram que o classificador de padrões RNA MLP é o mais compatível para classificação de padrões com a abordagem de extração de características proposta para o tratamento dos sinais de MITs na detecção de defeitos de rolamentos, barras quebradas de rotor e curto-circuito de estator independentemente das circunstâncias de operação do motor e do tipo de alimentação empregada.

Esses resultados experimentais obtidos de forma off-line, serviram de base para a implementação da abordagem proposta em um sistema embarcado em hardware DSP, o que possibilitou o monitoramento e diagnóstico on-line de defeitos de curto-circuito de estator em MITs acionados diretamente pela rede elétrica. Assim, uma outra contribuição dessa tese de Doutorado foi a busca pela otimização das ferramentas computacionais, como o número ideal de neurônios nas camadas intermediárias, com o intuito de encontrar o sistema mais eficiente para o monitoramento e diagnóstico de defeitos em máquinas elétricas. A partir dos resultados coletados de forma on-line, a metodologia demonstrou-se promissora na identificação de defeitos no estator em MITs, podendo colaborar com a tomada de decisão do operador de manutenção em um ambiente industrial. A seguir são apresentadas as perspectivas de trabalhos futuros.

## 7.1 TRABALHOS FUTUROS

Tendo em vista que essa tese de Doutorado apresentou resultados promissores para o monitoramento e identificação de múltiplos defeitos em máquinas elétricas independentemente do seu tipo de alimentação e a possibilidade de investigação em outras vertentes, sugere-se como trabalhos futuros:

- Embarcar a metodologia proposta para o diagnóstico dos demais defeitos apresentados nessa tese, bem como para as múltiplas falhas em hardware DSP;
- Realizar os ensaios em tempo real para a validação da metodologia de diagnóstico de múltiplos defeitos de MITs independentemente do seu tipo de alimentação;
- Embarcar a metodologia em outro hardware com custo menor e comparar os resultados experimentais.

## 7.2 PRODUÇÕES CIENTÍFICAS

Durante o desenvolvimento da pesquisa de Doutorado, foram publicados trabalhos diretamente relacionados a esta Tese e outros vinculados a trabalhos correlatos desenvolvido no Laboratório de Sistemas Inteligentes da UTFPR - Campus Cornélio Procopio, conforme apresenta-se a seguir:

### 7.2.1 Artigos Apresentados em Conferências Nacionais e/ou Internacionais

- Associado ao Trabalho
  - BAZAN, G. H.; GOEDEL, A.; DURAND, F. R.; GODOY, W. F. Identificação de Defeitos em Rolamentos de Motores de Indução Trifásicos Utilizando Medidas de Informação e Ferramentas Meta-Heurísticas. **XIV Simpósio Brasileiro de Automação Inteligente (SBAI 2019)**. Ouro Preto, MG, Brasil, 2019.
- Colaboração Direta em Outras Pesquisas
  - PALACIOS, R. H. C.; SILVA, I. N.; GOEDEL, A.; GODOY, W. R. F.; SILVA, P. P. D.; BAZAN, G. H. Diagnóstico Inteligente de Falhas no Rotor, Estator e Rolamento em Motores de Indução Trifásicos. **XXI Congresso Brasileiro de Automática (CBA)**. Vitória, ES, Brasil, 2016.
  - GODOY, WAGNER F.; DA SILVA, I. N.; GOEDEL, A.; PALACIOS, R. H. C.; BAZAN, G. H.; MORÍÑIGO-SOTELO, D. An application of artificial neural networks and PCA for stator fault diagnosis in inverter-fed induction motors. **2016 XXII International Conference on Electrical Machines (ICEM)**. Lausanne, Suíça, 2016.
  - BAZAN, G. H.; CASTOLDI, M. F.; GOEDEL, A.; PEREIRA, W. C. A.; AGUIAR, M. L. Virtual Platform of Field Oriented Control of Induction Motor to Assist in Education of Undergraduate Students. **2019 IEEE 28th International Symposium on Industrial Electronics (ISIE)**. Vancouver, BC, Canadá, 2019.

- GONGORA, W. S.; SILVA, I. N.; GOEDEL, A.; SANTOS, T. H.; CASTOLDI, M. F.; BAZAN, G. H. Harmônicos de Referência Observados por Sistemas Inteligentes na Identificação de Falhas Elétricas em Motores de Indução. **XIV Simpósio Brasileiro de Automação Inteligente (SBAI 2019)**. Ouro Preto, MG, Brasil, 2019.

## 7.2.2 Artigos Publicados em Periódicos

- Associado ao Trabalho

- BAZAN, G. H.; SCALASSARA, P. R.; ENDO, W.; GOEDEL, A.; GODOY, W. F.; PALÁCIOS, R. H. C. Stator Fault Analysis of Three-phase Induction Motors Using Information Measures and Artificial Neural Networks. **Electric Power Systems Research**, v. 143, p. 347-356, 2017. DOI: 10.1016/j.epsr.2016.09.031. JCR: 3,211 - Qualis A2.
- BAZAN, G. H.; SCALASSARA, P. R.; ENDO, W.; GOEDEL, A.; PALÁCIOS, R. H. C.; GODOY, W. F. Stator Short Circuit Diagnosis in Induction Motors Using Mutual Information and Intelligent Systems. **IEEE Transactions on Industrial Electronics**, v. 66, p. 3237-3246, 2019. DOI: 10.1109/TIE.2018.2840983. JCR: 7,515 - Qualis A1.
- BAZAN, G. H.; SCALASSARA, P. R.; ENDO, W.; GOEDEL, A. Information Theoretical Measurements From Induction Motors Under Several Load and Voltage Conditions for Bearing Faults Classification. **IEEE Transactions on Industrial Informatics**, v. 16, p. 3640-3650, 2020. DOI: 10.1109/TII.2019.2939678. JCR: 9,112 - Qualis A1.
- BAZAN, G. H.; GOEDEL, A.; SCALASSARA, P. R.; ENDO, W. Rotor Fault Diagnosis of Frequency Inverter Fed or Line Connected Induction Motors Using Mutual Information. **Soft Computing**, 2020. DOI:10.1007/s00500-020-05224-9. JCR: 3,050 - Qualis A1.



### 7.2.3 Artigos Aceitos para Publicação em Periódicos

- Associado ao Trabalho
  - BAZAN, G. H.; GOEDEL, A.; CASTOLDI, M. F.; GODOY, W. F.; DUQUE-PEREZ, O.; MORÍÑIGO-SOTELO, D. Mutual Information and Meta-Heuristic Classifiers Applied to Bearing Fault Diagnosis in Three-Phase Induction Motors. **Applied Sciences**. JCR: 2,474 - Qualis A4 (Aceito para publicação em Dezembro de 2020).

### 7.2.4 Artigos Submetidos a Periódicos

- Associado ao Trabalho
  - BAZAN, G. H.; GOEDEL, A.; SCALASSARA, P. R.; ENDO, W.; NUNES, E. A.; TAKASE, V. T. F.; GUEDES, J. J.; GENTIL, M. G. An Embedded System for Stator Short-Circuit Diagnosis in Three-Phase Induction Motors Using Information Theory and Artificial Neural Networks. **IEEE Transactions on Systems, Man and Cybernetics: Systems**.

### 7.2.5 Artigo em Elaboração para Periódico

- Associado ao Trabalho
  - BAZAN, G. H.; GOEDEL, A.; DUQUE-PEREZ, O.; MORÍÑIGO-SOTELO, D. An Alternative Approach to Multi-Fault Diagnosis in Three-Phase Induction Motors using Information Measures, PCA and Intelligent Systems. **ISA Transactions**.

### 7.2.6 Certificados de Registro de Programa de Computador

- Associado ao Trabalho
  - GOEDEL, A.; TAKASE, V. T. F.; GUEDES, J. J.; BAZAN, G. H.; NUNES, E. A. Informação Mútua Deslocada para Sistemas Embarcados. **Ins-**

**tituto Nacional da Propriedade Industrial (INPI)**, Jul., 2020. Processo nº: BR512020001370-8.

- Colaboração Direta em Outras Pesquisas

- GOEDTEL, A.; CASTOLDI, M. F.; TAKASE, V. T. F.; GUEDES, J. J.; NUNES, E. A.; BAZAN, G. H. Evolução Diferencial para Sistemas Embarcados. **Instituto Nacional da Propriedade Industrial (INPI)**, Jul., 2020. Processo nº: BR512020001368-6.

## REFERÊNCIAS

ABDALLAH, H.; BENATMAN, K. Stator winding inter-turn short-circuit detection in induction motors by parameter identification. **IET Electric Power Applications**, v. 11, n. 2, p. 272–288, 2017.

ABID, F. B.; SALLEM, M.; BRAHAM, A. Robust interpretable deep learning for intelligent fault diagnosis of induction motors. **IEEE Transactions on Instrumentation and Measurement**, v. 69, n. 6, p. 3506–3515, 2020.

ABID, F. Ben; ZGARNI, S.; BRAHAM, A. Distinct bearing faults detection in induction motor by a hybrid optimized swpt and ainet-dag svm. **IEEE Transactions on Energy Conversion**, v. 33, n. 4, p. 1692–1699, 2018.

ALI, M. Z.; SHABBIR, M. N. S. K.; LIANG, X.; ZHANG, Y.; HU, T. 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**, v. 55, n. 3, p. 2378–2391, 2019.

ALI, M. Z.; SHABBIR, M. N. S. K.; ZAMAN, S. M. K.; LIANG, X. Single- and multi-fault diagnosis using machine learning for variable frequency drive-fed induction motors. **IEEE Transactions on Industry Applications**, v. 56, n. 3, p. 2324–2337, 2020.

ALONSO, J.F.; MANANAS, M.A.; HOYER, D.; TOPOR, Z.L.; BRUCE, E.N. Evaluation of respiratory muscles activity by means of cross mutual information function at different levels of ventilatory effort. **IEEE Transactions on Biomedical Engineering**, v. 54, n. 9, p. 1573–1582, 2007.

AMAR, M.; GONDAL, I.; WILSON, C. Vibration spectrum imaging: A novel bearing fault classification approach. **IEEE Transactions on Industrial Electronics**, v. 62, n. 1, p. 494–502, Jan 2015.

ANTONINO-DAVIU, J.; AVIYENTE, S.; STRANGAS, E.G.; RIERA-GUASP, M. Scale invariant feature extraction algorithm for the automatic diagnosis of rotor asymmetries in induction motors. **IEEE Transactions on Industrial Informatics**, v. 9, n. 1, p. 100–108, Feb 2013.

APPANA, Dileep K.; PROSVIRIN, Alexander; KIM, Jong-Myon. Reliable fault diagnosis of bearings with varying rotational speeds using envelope spectrum and convolution neural networks. **Soft Computing**, v. 22, n. 20, p. 6719–6729, Oct 2018.

ASFANI, D.A.; MUHAMMAD, A.K.; SYAFARUDDIN; PURNOMO, M.H.; HIYAMA, T. Temporary short circuit detection in induction motor winding using combination of wavelet transform and neural network. **Expert Systems with Applications**, v. 39, n. 5, p. 5367–5375, 2012.

AYDIN, I.; KARAKOSE, M.; AKIN, E. An adaptive artificial immune system for fault classification. **Journal of Intelligent Manufacturing**, v. 23, n. 5, p. 1489–1499, 2012.

BARZEGARAN, M.; MAZLOOMZADEH, A.; MOHAMMED, O.A. Fault diagnosis of the asynchronous machines through magnetic signature analysis using finite-element method and neural networks. **IEEE Transactions on Energy Conversion**, v. 28, n. 4, p. 1064–1071, 2013.

BAZAN, G. H. **Medidas de informação e sistemas inteligentes aplicados no diagnóstico de curto-circuito do estator de motores de indução trifásicos**. 2016. 112 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR, Brasil, 2016.

BAZAN, G. H.; GOEDEL, A.; SCALASSARA, P. R.; ENDO, W. Rotor fault diagnosis of frequency inverter fed or line-connected induction motors using mutual information. **Soft Computing**, p. 1–16, 2020.

BAZAN, Gustavo Henrique; SCALASSARA, Paulo Rogério; ENDO, Wagner; GOEDEL, Alessandro; GODOY, Wagner Fontes; PALÁCIOS, Rodrigo Henrique Cunha. Stator fault analysis of three-phase induction motors using information measures and artificial neural networks. **Electric Power Systems Research**, v. 143, p. 347 – 356, 2017.

BAZAN, G. H.; SCALASSARA, P. R.; ENDO, W.; GOEDEL, A.; PALÁCIOS, R. H. C.; GODOY, W. F. Stator short-circuit diagnosis in induction motors using mutual information and intelligent systems. **IEEE Transactions on Industrial Electronics**, v. 66, n. 4, p. 3237–3246, 2019.

BAZAN, G. H.; SCALASSARA, P. R.; ENDO, W.; GOEDEL, A. Information theoretical measurements from induction motors under several load and voltage conditions for bearing faults classification. **IEEE Transactions on Industrial Informatics**, v. 16, n. 6, p. 3640–3650, 2020.

BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G. Advances in diagnostic techniques for induction machines. **IEEE Transactions on Industrial Electronics**, v. 55, n. 12, p. 4109–4126, 2008.

BENGHERBIA, Billel; ZMIRLI, Mohamed Ould; TOUBAL, Abdelmoghni; GUESSOUM, Abderrezak. Fpga-based wireless sensor nodes for vibration monitoring system and fault diagnosis. **Measurement**, v. 101, p. 81 – 92, 2017.

BERZOY, A.; MOHAMED, A. A. S.; MOHAMMED, O. Complex-vector model of interturn failure in induction machines for fault detection and identification. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 2667–2678, May 2017.

BERZOY, A.; MOHAMMED, O. A.; RESTREPO, J. Analysis of the impact of stator interturn short-circuit faults on induction machines driven by direct torque control. **IEEE Transactions on Energy Conversion**, v. 33, n. 3, p. 1463–1474, Sep 2018.

BESSAM, B.; MENACER, A.; BOUMEHRAZ, M.; CHERIF, H. Detection of broken rotor bar faults in induction motor at low load using neural network. **ISA Transactions**, v. 64, p. 241 – 246, 2016.

BISHOP, C.M. **Pattern Recognition and Machine Learning (Information Science and Statistics)**. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006.

BONNETT, A.H.; YUNG, C. Increased efficiency versus increased reliability. **IEEE Industry Applications Magazine**, v. 14, n. 1, p. 29–36, 2008.

BOUDINAR, A. H.; BENOZZA, N.; BENDIABDELLAH, A.; KHODJA, M. E. A. Induction motor bearing fault analysis using a root-music method. **IEEE Transactions on Industry Applications**, v. 52, n. 5, p. 3851–3860, Sept 2016.

BOUZID, M.B.K.; CHAMPENOIS, G. New expressions of symmetrical components of the induction motor under stator faults. **IEEE Transactions on Industrial Electronics**, v. 60, n. 9, p. 4093–4102, 2013.

BRONIERA, P. **Diagnóstico de curto-circuito no enrolamento de estator em máquinas de indução trifásicas utilizando redes neurais artificiais**. 2014. 113 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Cornélio Procopio, PR, Brasil, 2014.

BRONIERA, P. J.; GONGORA, W. S.; GOEDEL, A.; GODOY, W. F. Diagnosis of stator winding inter-turn short circuit in three-phase induction motors by using artificial neural networks. *In: 2013 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)*. [S.l.: s.n.], 2013. p. 281–287.

CHEN, C. L. P.; LIU, Z. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture. **IEEE Transactions on Neural Networks and Learning Systems**, v. 29, n. 1, p. 10–24, 2018.

CONTRERAS-HERNANDEZ, J. L.; ALMANZA-OJEDA, D. L.; LEDESMA-OROZCO, S.; GARCIA-PEREZ, A.; ROMERO-TRONCOSO, R. J.; IBARRA-MANZANO, M. A.

Quaternion signal analysis algorithm for induction motor fault detection. **IEEE Transactions on Industrial Electronics**, v. 66, n. 11, p. 8843–8850, 2019.

COVER, T.M.; THOMAS, J.A. **Elements of Information Theory**. New York, USA: John Wiley and Sons, Inc., 2006.

DALVAND, F.; KALANTAR, A.; SAFIZADEH, M. S. A novel bearing condition monitoring method in induction motors based on instantaneous frequency of motor voltage. **IEEE Transactions on Industrial Electronics**, v. 63, n. 1, p. 364–376, Jan 2016.

DAS, S.; KOLEY, C.; PURKAIT, P.; CHAKRAVORTI, S. Wavelet aided svm classifier for stator inter-turn fault monitoring in induction motors. *In: 2010 IEEE Power & Energy Society General Meeting. [S.l.: s.n.], 2010.*

DEHGHAN, H.; HAGHJOO, F.; CRUZ, S. M. A. A flux-based differential technique for turn-to-turn fault detection and defective region identification in line-connected and inverter-fed induction motors. **IEEE Transactions on Energy Conversion**, v. 33, n. 4, p. 1876–1885, Dec 2018.

DELGADO-ARREDONDO, Paulo Antonio; MORINIGO-SOTELO, Daniel; OSORNIO-RIOS, Roque Alfredo; AVINA-CERVANTES, Juan Gabriel; ROSTRO-GONZALEZ, Horacio; ROMERO-TRONCOSO, Rene de Jesus. Methodology for fault detection in induction motors via sound and vibration signals. **Mechanical Systems and Signal Processing**, v. 83, p. 568 – 589, 2017.

DENG, Wu; YAO, Rui; ZHAO, Huimin; YANG, Xinhua; LI, Guangyu. A novel intelligent diagnosis method using optimal LS-SVM with improved PSO algorithm. **Soft Computing**, v. 23, n. 7, p. 2445–2462, Apr 2019.

DEVI, N.R.; SARMA, D.V.S.S. Siva; RAO, P.V. Ramana. Detection of stator incipient faults and identification of faulty phase in three-phase induction motor - simulation and experimental verification. **IET Electric Power Applications**, v. 9, n. 8, p. 540–548, 2015.

DIAS, C. G.; PEREIRA, F. H. Broken rotor bars detection in induction motors running at very low slip using a hall effect sensor. **IEEE Sensors Journal**, v. 18, n. 11, p. 4602–4613, 2018.

DING, Rui; LI, Shunming; LU, Jiantao; XU, Kun; WANG, Jinrui. A novel stacked auto encoders sparse filter rotating component comprehensive diagnosis network for extracting domain invariant features. **Applied Sciences**, v. 10, n. 17, 2020.

DRIF, M.; CARDOSO, A.J.M. Stator fault diagnostics in squirrel cage three-phase induction motor drives using the instantaneous active and reactive power signature analyses. **IEEE Transactions on Industrial Informatics**, v. 10, n. 2, p. 1348–1360, 2014.

DRIF, M.; KIM, H.; KIM, J.; LEE, S. B.; CARDOSO, A. J. M. Active and reactive power spectra-based detection and separation of rotor faults and low-frequency load torque oscillations. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 2702–2710, May 2017.

DUAN, F.; ŽIVANOVIĆ, R. Condition monitoring of an induction motor stator windings via global optimization based on the hyperbolic cross points. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1826–1834, Mar. 2015.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2nd. ed. New York, USA: J. Willey and Sons, Inc., 2001.

EFTEKHARI, M.; MOALLEM, M.; SADRI, S.; HSIEH, M. Online detection of induction motor's stator winding short-circuit faults. **IEEE Systems Journal**, v. 8, n. 4, p. 1272–1282, 2014.

ELBOUCHIKHI, E.; AMIRAT, Y.; FELD, G.; BENBOUZID, M. Generalized likelihood ratio test based approach for stator-fault detection in a pwm inverter-fed induction motor drive. **IEEE Transactions on Industrial Electronics**, v. 66, n. 8, p. 6343–6353, Aug 2019.

ELBOUCHIKHI, Elhoussin; CHOQUEUSE, Vincent; BENBOUZID, Mohamed. Induction machine bearing faults detection based on a multi-dimensional music algorithm and maximum likelihood estimation. **ISA Transactions**, v. 63, p. 413 – 424, 2016.

ENDO, W. **Sistema Neuromotor e Proprioceptor de Insetos com o Uso de Transferência de Informação entre Conexões Neurais**. 2014. 153 p. Tese (Doutorado) — Universidade de São Paulo, São Carlos, SP, Brasil, 2014.

ENDO, W.; SANTOS, F.P.; SIMPSON, D.; MACIEL, C.D.; NEWLAND, P.L. Delayed mutual information infers patterns of synaptic connectivity in a proprioceptive neural network. **Journal of Computational Neuroscience**, v. 38, n. 2, p. 427–438, 2015.

EPE, Empresa de Pesquisa Energetica. **Balanco Energético Nacional 2020 - Ano Base 2019 - Relatório Final**. 2020. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2020>.

ESFAHANI, E. T.; WANG, S.; SUNDARARAJAN, V. Multisensor wireless system for eccentricity and bearing fault detection in induction motors. **IEEE/ASME Transactions on Mechatronics**, v. 19, n. 3, p. 818–826, June 2014.

ESTÉVEZ, P.A.; TESMER, M.; PEREZ, C.A.; ZURADA, J.M. Normalized mutual information feature selection. **IEEE Transactions on Neural Networks**, v. 20, n. 2, p. 189–201, 2009.

FAIZ, J.; EBRAHIMI, B.M.; AKIN, B.; TOLIYAT, H.A. Dynamic analysis of mixed eccentricity signatures at various operating points and scrutiny of related indices for induction motors. **IET Electric Power Applications**, v. 4, n. 1, p. 1–16, 2010.

FROSINI, L.; HARLIŞÇA, C.; SZABÓ, L. Induction machine bearing fault detection by means of statistical processing of the stray flux measurement. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1846–1854, March 2015.

GANDHI, A.; CORRIGAN, T.; PARSA, L. Recent advances in modeling and online detection of stator interturn faults in electrical motors. **IEEE Transactions on Industrial Electronics**, v. 58, n. 5, p. 1564–1575, 2011.

GANGSAR, Purushottam; TIWARI, Rajiv. Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. **Mechanical Systems and Signal Processing**, v. 144, p. 106908, 2020.

GARCIA-CALVA, T. A.; MORÍÑIGO-SOTELO, D.; ROMERO-TRONCOSO, R. de Jesus. Non-uniform time resampling for diagnosing broken rotor bars in inverter-fed induction motors. **IEEE Transactions on Industrial Electronics**, v. 64, n. 3, p. 2306–2315, March 2017.

GARCÍA-ESCUADERO, L. A.; DUQUE-PEREZ, O.; FERNANDEZ-TEMPRANO, M.; MORINIGO-SOTELO, D. Robust detection of incipient faults in vsi-fed induction motors using quality control charts. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 3076–3085, May 2017.

GARCIA-PEREZ, A.; ROMERO-TRONCOSO, R. d. J.; CABAL-YEPEZ, E.; OSORNIO-RIOS, R. A. The application of high-resolution spectral analysis for identifying multiple combined faults in induction motors. **IEEE Transactions on Industrial Electronics**, v. 58, n. 5, p. 2002–2010, May 2011.

GHATE, V.N.; DUDUL, S.V. Optimal mlp neural network classifier for fault detection of three phase induction motor. **Expert Systems with Applications**, v. 37, n. 4, p. 3468–3481, 2010.



GHATE, V.N.; DUDUL, S.V. Cascade neural-network-based fault classifier for three-phase induction motor. **IEEE Transactions on Industrial Electronics**, v. 58, n. 5, p. 1555–1563, 2011.

GODOY, W.F.; SILVA, I.N. Da; GOEDEL, A.; PALÁCIOS, R.H. Cunha. Evaluation of stator winding faults severity in inverter-fed induction motors. **Applied Soft Computing Journal**, v. 32, p. 420–431, 2015.

GODOY, W. F. **Multiclassificador Inteligente de Falhas no Domínio do Tempo em Motores de Indução Trifásicos Alimentados por Inversores de Frequência**. 2016. 162 p. Tese (Doutorado) — Universidade de São Paulo, São Carlos, SP, Brasil, 2016.

GODOY, W. F.; SILVA, I. N. da; GOEDEL, A.; PALÁCIOS, R. H. C.; LOPES, T. D. Application of intelligent tools to detect and classify broken rotor bars in three-phase induction motors fed by an inverter. **IET Electric Power Applications**, v. 10, n. 5, p. 430–439, 2016.

GOEDEL, A. **Estimador Neural de Velocidade para Motores de Indução Trifásicos**. 2007. 133 p. Tese (Doutorado) — Universidade de São Paulo, São Carlos, SP, Brasil, 2007.

GONGORA, W. S. **Uma Abordagem Neural no Diagnóstico de Falhas em Rolamentos de Motores de Indução Trifásicos**. 2013. 95 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Cornélio Procopio, PR, Brasil, 2013.

GONGORA, W. Salviano; GOEDEL, A.; SILVA, S. Augusto Oliveira da; GRACIOLA, C. Luiz. Neural approach to fault detection in three-phase induction motors. **IEEE Latin America Transactions**, v. 14, n. 3, p. 1279–1288, 2016.

GRACIOLA, C. L.; GOEDEL, A.; SUETAKE, M.; SUMAR, R. R. Neural speed estimator for line-connected induction motor embedded in a digital processor. **Applied Soft Computing**, v. 40, p. 616–623, 2016.

GUEDES, Armando Souza; SILVA, Sidelmo Magalhães; FILHO, Braz de Jesus Cardoso; CONCEIÇÃO, Cláudio Alvares. Evaluation of electrical insulation in three-phase induction motors and classification of failures using neural networks. **Electric Power Systems Research**, v. 140, p. 263 – 273, 2016.

GUEDES, J. J. **Identificação de falhas de curto-circuito de estator em motores de indução trifásicos utilizando evolução diferencial**. 2016. 69 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Cornélio Procopio, PR, Brasil, 2016.

GUEDES, Jacqueline Jordan; CASTOLDI, Marcelo Favoretto; GOEDTEL, Alessandro; AGULHARI, Cristiano Marcos; SANCHES, Danilo Sipoli. Differential evolution applied to line-connected induction motors stator fault identification. **Soft Computing**, v. 23, n. 21, p. 11217–11226, 2019.

GUVEN, Yilmaz; ATIS, Selcuk. Implementation of an embedded system for real-time detection of rotor bar failures in induction motors. **ISA Transactions**, v. 81, p. 210 – 221, 2018.

GYFTAKIS, K. N.; ANTONINO-DAVIU, J. A.; GARCIA-HERNANDEZ, R.; MCCULLOCH, M. D.; HOWEY, D. A.; CARDOSO, A. J. Marques. Comparative experimental investigation of broken bar fault detectability in induction motors. **IEEE Transactions on Industry Applications**, v. 52, n. 2, p. 1452–1459, March 2016.

HALL, Mark; FRANK, Eibe; HOLMES, Geoffrey; PFAHRINGER, Bernhard; REUTEMANN, Peter; WITTEN, Ian H. The weka data mining software: An update. **SIGKDD Explor. Newsl.**, ACM, New York, NY, USA, v. 11, n. 1, p. 10–18, nov. 2009. ISSN 1931-0145.

HARMOUCHE, J.; DELPHA, C.; DIALLO, D. Improved fault diagnosis of ball bearings based on the global spectrum of vibration signals. **IEEE Transactions on Energy Conversion**, v. 30, n. 1, p. 376–383, March 2015.

HAROUN, S.; SEGHIR, A. N.; TOUATI, S. Multiple features extraction and selection for detection and classification of stator winding faults. **IET Electric Power Applications**, v. 12, n. 3, p. 339–346, 2018.

HAYKIN, S. **Neural Networks and Learning Machines**. 3rd. ed. New Jersey: Prentice Hall, 2008.

HENAO, H.; CAPOLINO, G.-A.; FERNANDEZ-CABANAS, M.; FILIPPETTI, F.; BRUZZESE, C.; STRANGAS, E.; PUSCA, R.; ESTIMA, J.; RIERA-GUASP, M.; HEDAYATI-KIA, S. Trends in fault diagnosis for electrical machines: A review of diagnostic techniques. **IEEE Industrial Electronics Magazine**, v. 8, n. 2, p. 31–42, 2014.

HERMAN, G.; ZHANG, B.; WANG, Y.; YE, G.; CHEN, F. Mutual information-based method for selecting informative feature sets. **Pattern Recognition**, v. 46, n. 12, p. 3315–3327, 2013.

HMIDA, M.A.; BRAHAM, A. Arm based rswpt implementation for embedded condition monitoring of induction motor. *In: IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*. [S.l.: s.n.], 2016. p. 1464–1469.

HOU, Z.; HUANG, J.; LIU, H.; WANG, T.; ZHAO, L. Quantitative broken rotor bar fault detection for closed-loop controlled induction motors. **IET Electric Power Applications**, v. 10, n. 5, p. 403–410, 2016.

HUANG, Qingqing; TANG, Baoping; DENG, Lei; WANG, Jiaxu. A divide-and-compress lossless compression scheme for bearing vibration signals in wireless sensor networks. **Measurement**, v. 67, p. 51 – 60, 2015.

IRHOUMAH, M.; PUSCA, R.; LEFEVRE, E.; MERCIER, D.; ROMARY, R.; DEMIAN, C. Information fusion with belief functions for detection of interturn short-circuit faults in electrical machines using external flux sensors. **IEEE Transactions on Industrial Electronics**, v. 65, n. 3, p. 2642–2652, March 2018.

JERKAN, D. G.; RELJIĆ, D. D.; MARČETIĆ, D. P. Broken rotor bar fault detection of im based on the counter-current braking method. **IEEE Transactions on Energy Conversion**, v. 32, n. 4, p. 1356–1366, Dec 2017.

JIANG, S. B.; WONG, P. K.; LIANG, Y. C. A fault diagnostic method for induction motors based on feature incremental broad learning and singular value decomposition. **IEEE Access**, v. 7, p. 157796–157806, 2019.

JIN, X.; ZHAO, M.; CHOW, T. W. S.; PECHT, M. Motor bearing fault diagnosis using trace ratio linear discriminant analysis. **IEEE Transactions on Industrial Electronics**, v. 61, n. 5, p. 2441–2451, May 2014.

JUKIC, A.; FILIPOVIC, M. Supervised feature extraction for tensor objects based on maximization of mutual information. **Pattern Recognition Letters**, v. 34, n. 13, p. 1476–1484, 2013.

KIM, Y. H.; YOUN, Y. W.; HWANG, D. H.; SUN, J. H.; KANG, D. S. High-resolution parameter estimation method to identify broken rotor bar faults in induction motors. **IEEE Transactions on Industrial Electronics**, v. 60, n. 9, p. 4103–4117, Sept 2013.

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

KUMAR, Anil; ZHOU, Yuqing; XIANG, Jiawei. Optimization of vmd using kernel-based mutual information for the extraction of weak features to detect bearing defects. **Measurement**, v. 168, p. 108402, 2021.

LAMIM, P.C.M.; PEDERIVA, R.; BRITO, J.N. Detection of stator winding faults in induction machines using flux and vibration analysis. **Mechanical Systems and Signal Processing**, v. 42, n. 1-2, p. 377–387, 2014.

LANDIS, J. Richard; KOCH, Gary G. The measurement of observer agreement for categorical data. **Biometrics**, International Biometric Society, v. 33, n. 1, p. 159–174, 1977.

LEITE, V.C.M.N.; SILVA, J.G. Borges da; VELOSO, G.F. Cintra; SILVA, L.E. Borges da; LAMBERT-TORRES, G.; BONALDI, E.L.; OLIVEIRA, L.E. De Lacerda de. Detection of localized bearing faults in induction machines by spectral kurtosis and envelope analysis of stator current. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1855–1865, March 2015.

LEIVA-MURILLO, J.M.; ARTÉS-RODRÍGUEZ, A. Information-theoretic linear feature extraction based on kernel density estimators: A review. **IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews**, v. 42, n. 6, p. 1180–1189, 2012.

LI, B.; ZHANG, P.-L.; TIAN, H.; MI, S.-S.; LIU, D.-S.; REN, G.-Q. A new feature extraction and selection scheme for hybrid fault diagnosis of gearbox. **Expert Systems with Applications**, v. 38, n. 8, p. 10000–10009, 2011.

LIBONI, Luisa H.B.; FLAUZINO, Rogério Andrade; SILVA, Ivan Nunes da; COSTA, Eduardo C. Marques. Efficient feature extraction technique for diagnosing broken bars in three-phase induction machines. **Measurement**, v. 134, p. 825 – 834, 2019.

LIU, Yiqi; BAZZI, Ali M. A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art. **ISA Transactions**, v. 70, p. 400 – 409, 2017.

LOECKX, D.; SLAGMOLEN, P.; MAES, F.; VANDERMEULEN, D.; SUETENS, P. Nonrigid image registration using conditional mutual information. **IEEE Transactions on Medical Imaging**, v. 29, n. 1, p. 19–29, 2010.

LOPES, T. D. **Multiclassificação de Falhas em Motores de Indução Trifásicos Utilizando Um Único Transformador de Corrente e Redes Neurais Artificiais**. 2016. 99 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR, Brasil, 2016.

LOPES, Tiago Drummond; GOEDEL, Alessandro; PALÁCIOS, Rodrigo; GODOY, Wagner Fontes; SOUZA, Roberto. Bearing fault identification of three-phase induction motors bases on two current sensor strategy. **Soft Computing**, v. 21, p. 6673–6685, 2017.

LU, S.; HE, Q.; YUAN, T.; KONG, F. Online fault diagnosis of motor bearing via stochastic-resonance-based adaptive filter in an embedded system. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 47, n. 7, p. 1111–1122, July 2017.

LU, Siliang; HE, Qingbo; ZHAO, Jiwen. Bearing fault diagnosis of a permanent magnet synchronous motor via a fast and online order analysis method in an embedded system. **Mechanical Systems and Signal Processing**, v. 113, p. 36–49, 2018.

LU, S.; QIAN, G.; HE, Q.; LIU, F.; LIU, Y.; WANG, Q. In situ motor fault diagnosis using enhanced convolutional neural network in an embedded system. **IEEE Sensors Journal**, v. 20, n. 15, p. 8287–8296, 2020.

MALEK, Mina Abd el; ABDELSALAM, Ahmed K.; HASSAN, Ola E. Induction motor broken rotor bar fault location detection through envelope analysis of start-up current using hilbert transform. **Mechanical Systems and Signal Processing**, v. 93, p. 332 – 350, 2017.

MARTIN-DIAZ, I.; MORINIGO-SOTELO, D.; DUQUE-PEREZ, O.; ARREDONDO-DELGADO, P.A.; CAMARENA-MARTINEZ, D.; ROMERO-TRONCOSO, R.J. Analysis of various inverters feeding induction motors with incipient rotor fault using high-resolution spectral analysis. **Electric Power Systems Research**, v. 152, n. Supplement C, p. 18 – 26, 2017.

MARTINEZ, J.; BELAHCEN, A.; MUETZE, A. Analysis of the vibration magnitude of an induction motor with different numbers of broken bars. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 2711–2720, May 2017.

MELIA, U.; GUAITA, M.; VALLVERDÚ, M.; EMBID C.; VILASECA, I.; SALAMERO, M.; SANTAMARIA, J. Mutual information measures applied to eeg signals for sleepiness characterization. **Medical Engineering & Physics**, v. 37, n. 3, p. 297–308, 2015.

MIRZAEVA, G.; SAAD, K. I.; JAHROMI, M. G. Comprehensive diagnostics of induction motor faults based on measurement of space and time dependencies of air gap flux. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 2657–2666, May 2017.

MORALES-PEREZ, C.; RANGEL-MAGDALENO, J.; PEREGRINA-BARRETO, H.; AMEZQUITA-SANCHEZ, J. P.; VALTIERRA-RODRIGUEZ, M. Incipient broken rotor bar detection in induction motors using vibration signals and the orthogonal matching pursuit algorithm. **IEEE Transactions on Instrumentation and Measurement**, v. 67, n. 9, p. 2058–2068, 2018.

MOUSSA, M. A.; BOUCHERMA, M.; KHEZZAR, A. A detection method for induction motor bar fault using sidelobes leakage phenomenon of the sliding discrete fourier

transform. **IEEE Transactions on Power Electronics**, v. 32, n. 7, p. 5560–5572, July 2017.

NAHA, A.; SAMANTA, A. K.; ROUSTRAY, A.; DEB, A. K. A method for detecting half-broken rotor bar in lightly loaded induction motors using current. **IEEE Transactions on Instrumentation and Measurement**, v. 65, n. 7, p. 1614–1625, July 2016.

NAHA, A.; THAMMAYYABBABU, K. R.; SAMANTA, A. K.; ROUSTRAY, A.; DEB, A. K. Mobile application to detect induction motor faults. **IEEE Embedded Systems Letters**, v. 9, n. 4, p. 117–120, Dec 2017.

NAYANA, B. R.; GEETHANJALI, P. Analysis of statistical time-domain features effectiveness in identification of bearing faults from vibration signal. **IEEE Sensors Journal**, v. 17, n. 17, p. 5618–5625, 2017.

NAYANA, B. R.; GEETHANJALI, P. Improved identification of various conditions of induction motor bearing faults. **IEEE Transactions on Instrumentation and Measurement**, v. 69, n. 5, p. 1908–1919, 2020.

NICHOLS, J.M. Examining structural dynamics using information flow. **Probabilistic Engineering Mechanics**, v. 21, n. 4, p. 420–433, 2006.

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**, v. 54, n. 11, p. 1–5, 2018.

ONG, J.L.; SEGHOUANE, A. Feature selection using mutual information in ct colonography. **Pattern Recognition Letters**, v. 32, n. 2, p. 337–341, 2011.

PALÁCIOS, R.H.C.; SILVA, I.N. Da; GOEDEL, A.; GODOY, W.F. A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. **Electric Power Systems Research**, v. 127, p. 249–258, 2015.

PALÁCIOS, R. H. C. **Aplicação de técnicas inteligentes com análise no domínio do tempo para reconhecimento de defeitos em motores de indução trifásicos**. 2016. 187 p. Tese (Doutorado) — Universidade de São Paulo, São Carlos, SP, Brasil, 2016.

PALÁCIOS, Rodrigo Henrique Cunha; SILVA, Ivan Nunes da; GOEDEL, Alessandro; GODOY, Wagner Fontes; OLESKOVICZ, Mário. A robust neural method to estimate torque in three-phase induction motor. **Journal of Control, Automation and Electrical Systems**, Springer US, v. 25, n. 4, p. 493–502, March 2014.

PALÁCIOS, R. H. C.; SILVA, I. N. da; GOEDEL, A.; GODOY, W. F. A novel multi-agent approach to identify faults in line connected three-phase induction motors. **Applied Soft Computing**, v. 45, p. 1–10, 2016.

PANAGIOTOU, P. A.; ARVANITAKIS, I.; LOPHITIS, N.; ANTONINO-DAVIU, J. A.; GYFTAKIS, K. N. A new approach for broken rotor bar detection in induction motors using frequency extraction in stray flux signals. **IEEE Transactions on Industry Applications**, v. 55, n. 4, p. 3501–3511, 2019.

PANDARAKONE, S. E.; MIZUNO, Y.; NAKAMURA, H. Distinct fault analysis of induction motor bearing using frequency spectrum determination and support vector machine. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 3049–3056, May 2017.

PANIGRAHY, P. S.; MITRA, S.; KONAR, P.; CHATTOPADHYAY, P. Fpga friendly fault detection technique for drive fed induction motor. *In: 2016 2nd International Conference on Control, Instrumentation, Energy Communication (CIEC). [S.l.: s.n.], 2016. p. 299–303.*

PATEL, D. C.; CHANDORKAR, M. C. Modeling and analysis of stator interturn fault location effects on induction machines. **IEEE Transactions on Industrial Electronics**, v. 61, n. 9, p. 4552–4564, Sept 2014.

PICAZO-RÓDENAS, M. J.; ANTONINO-DAVIU, J.; CLIMENTE-ALARCON, V.; ROYO-PASTOR, R.; MOTA-VILLAR, A. Combination of noninvasive approaches for general assessment of induction motors. **IEEE Transactions on Industry Applications**, v. 51, n. 3, p. 2172–2180, May 2015.

PLATT, J. **Fast training of support vector machines using sequential minimal optimization**, in: B. Schoelkopf, C. Burges, A. Smola (Eds.), **Advances in Kernel Methods – Support Vector Learning**. Boston, MA, USA: MIT Press, 1998.

PRIETO, M. D.; CIRRINCIONE, G.; ESPINOSA, A. G.; ORTEGA, J. A.; HENAO, H. Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks. **IEEE Transactions on Industrial Electronics**, v. 60, n. 8, p. 3398–3407, 2013.

PRUDHOM, Aurelien; ANTONINO-DAVIU, Jose; RAZIK, Hubert; CLIMENTE-ALARCON, Vicente. Time-frequency vibration analysis for the detection of motor damages caused by bearing currents. **Mechanical Systems and Signal Processing**, v. 84, p. 747 – 762, 2017.

RIERA-GUASP, M.; ANTONINO-DAVIU, J. A.; CAPOLINO, G. A. Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: State

of the art. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1746–1759, March 2015.

ROMERO-TRONCOSO, R.J.; GARCIA-PEREZ, A.; MORINIGO-SOTELO, D.; DUQUE-PEREZ, O.; OSORNIO-RIOS, R.A.; IBARRA-MANZANO, M.A. Rotor unbalance and broken rotor bar detection in inverter-fed induction motors at start-up and steady-state regimes by high-resolution spectral analysis. **Electric Power Systems Research**, v. 133, p. 142 – 148, 2016.

ROMERO-TRONCOSO, R. J.; SAUCEDO-GALLAGA, R.; CABAL-YEPEZ, E.; GARCIA-PEREZ, A.; OSORNIO-RIOS, R. A.; ALVAREZ-SALAS, R.; MIRANDA-VIDALES, H.; HUBER, N. FPGA-based online detection of multiple combined faults in induction motors through information entropy and fuzzy inference. **IEEE Transactions on Industrial Electronics**, v. 58, n. 11, p. 5263–5270, Nov. 2011.

S., M. 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**, v. 16, n. 1, p. 145–152, Jan 2016.

SABOURI, M.; OJAGHI, M.; FAIZ, J.; CARDOSO, A. J. Marques. Model-based unified technique for identifying severities of stator inter-turn and rotor broken bar faults in scims. **IET Electric Power Applications**, v. 14, n. 2, p. 204–211, 2020.

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**, v. 15, n. 8, p. 4506–4515, 2019.

SAMANTA, Anik Kumar; NAHA, Arunava; ROUSTRAY, Aurobinda; DEB, Alok Kanti. Fast and accurate spectral estimation for online detection of partial broken bar in induction motors. **Mechanical Systems and Signal Processing**, v. 98, p. 63 – 77, 2018.

SANTOS, T.H. Dos; GOEDEL, A.; SILVA, S.A.O. Da; SUETAKE, M. Scalar control of an induction motor using a neural sensorless technique. **Electric Power Systems Research**, v. 108, p. 322–330, 2014.

SAUCEDO-DORANTES, J. J.; DELGADO-PRIETO, M.; OSORNIO-RIOS, R. A.; ROMERO-TRONCOSO, R. J. Multifault diagnosis method applied to an electric machine based on high-dimensional feature reduction. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 3086–3097, 2017.

SCHMITT, H.L.; SCALASSARA, P.R.; GOEDEL, A.; ENDO, W. Detecting bearing faults in line-connected induction motors using information theory measures and neural networks. **Journal of Control, Automation and Electrical Systems**, v. 26, n. 5, p. 535–544, 2015.



SCHMITT, H.L.; SILVA, L.R.B.; SCALASSARA, P.R.; GOEDEL, A. Bearing fault detection using relative entropy of wavelet components and artificial neural networks. *In: 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)*. [S.l.: s.n.], 2013. p. 538–543.

SEERA, M.; LIM, C.P.; ISHAK, D.; SINGH, H. Fault detection and diagnosis of induction motors using motor current signature analysis and a hybrid fmm-cart model. **IEEE Transactions on Neural Networks and Learning Systems**, v. 23, n. 1, p. 97–108, 2012.

SEERA, M.; LIM, C.P.; ISHAK, D.; SINGH, H. Offline and online fault detection and diagnosis of induction motors using a hybrid soft computing model. **Applied Soft Computing Journal**, v. 13, n. 12, p. 4493–4507, 2013.

SEERA, M.; LIM, C. P. Online motor fault detection and diagnosis using a hybrid FMM-CART model. **IEEE Transactions on Neural Networks and Learning Systems**, v. 25, n. 4, p. 806–812, 2014.

SESHADRINATH, J.; SINGH, B.; PANIGRAHI, B.K. Investigation of vibration signatures for multiple fault diagnosis in variable frequency drives using complex wavelets. **IEEE Transactions on Power Electronics**, v. 29, n. 2, p. 936–945, 2014.

SESHADRINATH, J.; SINGH, B.; PANIGRAHI, B. K. Incipient turn fault detection and condition monitoring of induction machine using analytical wavelet transform. **IEEE Transactions on Industry Applications**, v. 50, n. 3, p. 2235–2242, May 2014.

SHAO, S.; YAN, R.; LU, Y.; WANG, P.; GAO, R. X. Dcnn-based multi-signal induction motor fault diagnosis. **IEEE Transactions on Instrumentation and Measurement**, v. 69, n. 6, p. 2658–2669, 2020.

SHIMAZAKI, Hideaki; SHINOMOTO, Shigeru. A method for selecting the bin size of a time histogram. **Neural Computation**, MIT Press, Cambridge, MA, USA, v. 19, n. 6, p. 1503–1527, jun. 2007. ISSN 0899-7667.

SILJAK, Harun; SUBASI, Abdulhamit; UPADHYAYA, Belle R. Hardware implementation of auto-mutual information function for condition monitoring. **Computers & Electrical Engineering**, v. 66, p. 30 – 39, 2018.

SILVA, A.M. da; POVINELLI, R.J.; DEMERDASH, N.A.O. Rotor bar fault monitoring method based on analysis of air-gap torques of induction motors. **IEEE Transactions on Industrial Informatics**, v. 9, n. 4, p. 2274–2283, Nov 2013.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.; LIBONI, L. H. B.; ALVES, S. F. Reis. **Artificial Neural Networks: A Practical Course**. 2nd. ed. New York, USA: Springer, 2017.

SINGH, S.; KUMAR, N. Detection of bearing faults in mechanical systems using stator current monitoring. **IEEE Transactions on Industrial Informatics**, v. 13, n. 3, p. 1341–1349, June 2017.

SOHAIB, M.; KIM, J. Fault diagnosis of rotary machine bearings under inconsistent working conditions. **IEEE Transactions on Instrumentation and Measurement**, v. 69, n. 6, p. 3334–3347, 2020.

SOUSA, K. M.; COSTA, I. Brutkowski Vieira da; MACIEL, E. S.; ROCHA, J. E.; MARTELLI, C.; SILVA, J. C. Cardozo da. Broken bar fault detection in induction motor by using optical fiber strain sensors. **IEEE Sensors Journal**, v. 17, n. 12, p. 3669–3676, June 2017.

STIEF, A.; OTTEWILL, J. R.; BARANOWSKI, J.; ORKISZ, M. A pca and two-stage bayesian sensor fusion approach for diagnosing electrical and mechanical faults in induction motors. **IEEE Transactions on Industrial Electronics**, v. 66, n. 12, p. 9510–9520, 2019.

SURYA, G. N. *et al.* A simplified frequency-domain detection of stator turn fault in squirrel-cage induction motors using an observer coil technique. **IEEE Transactions on Industrial Electronics**, v. 64, n. 2, p. 1495–1506, Feb. 2017.

THORSEN, O.V.; DALVA, M. A survey of faults on induction motors in offshore oil industry, petrochemical industry, gas terminals, and oil refineries. **IEEE Transactions on Industry Applications**, v. 31, n. 5, p. 1186–1196, 1995.

TIAN, J.; MORILLO, C.; AZARIAN, M. H.; PECHT, M. Motor bearing fault detection using spectral kurtosis-based feature extraction coupled with k-nearest neighbor distance analysis. **IEEE Transactions on Industrial Electronics**, v. 63, n. 3, p. 1793–1803, March 2016.

TRACHI, Y.; ELBOUCHIKHI, E.; CHOQUEUSE, V.; BENBOUZID, M. E. H. Induction machines fault detection based on subspace spectral estimation. **IEEE Transactions on Industrial Electronics**, v. 63, n. 9, p. 5641–5651, Sept 2016.

TRACHI, Y.; ELBOUCHIKHI, E.; CHOQUEUSE, V.; BENBOUZID, M. E. H.; WANG, T. A novel induction machine fault detector based on hypothesis testing. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 3039–3048, May 2017.

TRAN, V.T.; ALTHOBIANI, F.; BALL, A.; CHOI, B. An application to transient current signal based induction motor fault diagnosis of fourier-bessel expansion and simplified fuzzy artmap. **Expert Systems with Applications**, v. 40, n. 13, p. 5372–5384, 2013.

TRUJILLO-GUAJARDO, L. A.; RODRIGUEZ-MALDONADO, J.; MOONEM, M. A.; PLATAS-GARZA, M. A. A multiresolution Taylor–Kalman approach for broken rotor bar detection in cage induction motors. **IEEE Transactions on Instrumentation and Measurement**, v. 67, n. 6, p. 1317–1328, 2018.

VERMA, A.; SARANGI, S.; KOLEKAR, M.H. Stator winding fault prediction of induction motors using multiscale entropy and grey fuzzy optimization methods. **Computers and Electrical Engineering**, v. 40, n. 7, p. 2246–2258, 2014.

VINAYAK, B. Akhil; ANAND, K. Anjali; JAGADANAND, G. Wavelet-based real-time stator fault detection of inverter-fed induction motor. **IET Electric Power Applications**, v. 14, n. 1, p. 82–90, 2020.

WANG, B.; SHEN, C.; XU, K.; ZHENG, T. Turn-to-turn short circuit of motor stator fault diagnosis in continuous state based on deep auto-encoder. **IET Electric Power Applications**, v. 13, n. 10, p. 1598–1606, 2019.

WANG, J.; FU, P.; ZHANG, L.; GAO, R. X.; ZHAO, R. Multilevel information fusion for induction motor fault diagnosis. **IEEE/ASME Transactions on Mechatronics**, v. 24, n. 5, p. 2139–2150, 2019.

WANG, Zhenya; YAO, Ligang; CAI, Yongwu. Rolling bearing fault diagnosis using generalized refined composite multiscale sample entropy and optimized support vector machine. **Measurement**, v. 156, p. 107574, 2020.

XU, B.; SUN, L.; XU, L.; XU, G. An esprit-saa-based detection method for broken rotor bar fault in induction motors. **IEEE Transactions on Energy Conversion**, v. 27, n. 3, p. 654–660, Sept 2012.

XUE, Yan; DOU, Dongyang; YANG, Jianguo. Multi-fault diagnosis of rotating machinery based on deep convolution neural network and support vector machine. **Measurement**, v. 156, p. 107571, 2020.

YAGAMI, Y.; ARAKI, C.; MIZUNO, Y.; NAKAMURA, H. Turn-to-turn insulation failure diagnosis of stator winding of low voltage induction motor with the aid of support vector machine. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 22, n. 6, p. 3099–3106, 2015.

ZAREI, J.; TAJEDDINI, M.A.; KARIMI, H.R. Vibration analysis for bearing fault detection and classification using an intelligent filter. **Mechatronics**, v. 24, n. 2, p. 151–157, 2014.

ZHANG, L.; XIONG, G.; LIU, H.; ZOU, H.; GUO, W. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference. **Expert Systems with Applications**, v. 37, n. 8, p. 6077–6085, 2010.

ZHANG, Qing; GAO, Junwei; DONG, Honghui; MAO, Yunlong. Wpd and de/bbo-rbfnn for solution of rolling bearing fault diagnosis. **Neurocomputing**, v. 312, p. 27 – 33, 2018.

ZHANG, Shen; ZHANG, Shibo; WANG, B.; HABETLER, T. G. Deep learning algorithms for bearing fault diagnostics - a comprehensive review. **IEEE Access**, v. 8, p. 29857–29881, 2020.

ZHAO, H.; ZHENG, J.; XU, J.; DENG, W. Fault diagnosis method based on principal component analysis and broad learning system. **IEEE Access**, v. 7, p. 99263–99272, 2019.

ZHAO, M.; JIN, X.; ZHANG, Z.; LI, B. Fault diagnosis of rolling element bearings via discriminative subspace learning: Visualization and classification. **Expert Systems with Applications**, v. 41, n. 7, p. 3391–3401, 2014.

ZHAO, W.; WANG, L. Multiple-kernel mrvm with lbfo algorithm for fault diagnosis of broken rotor bar in induction motor. **IEEE Access**, v. 7, p. 182173–182184, 2019.

ZHENG, L.; LI, Y.; CHEN, W.; WANG, Q.; JIANG, Q.; LIU, G. Detection of respiration movement asymmetry between the left and right lungs using mutual information and transfer entropy. **IEEE Access**, v. 6, p. 605–613, 2018.

ZHU, K.; SONG, X.; XUE, D. A roller bearing fault diagnosis method based on hierarchical entropy and support vector machine with particle swarm optimization algorithm. **Measurement: Journal of the International Measurement Confederation**, v. 47, n. 1, p. 669–675, 2014.