UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ CÂMPUS CORNÉLIO PROCÓPIO DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA MESTRADO EM ENGENHARIA ELÉTRICA

GUSTAVO HENRIQUE BAZAN

MEDIDAS DE INFORMAÇÃO E SISTEMAS INTELIGENTES APLICADOS NO DIAGNÓSTICO DE CURTO-CIRCUITO DO ESTATOR DE MOTORES DE INDUÇÃO TRIFÁSICOS

DISSERTAÇÃO

CORNÉLIO PROCÓPIO 2016

GUSTAVO HENRIQUE BAZAN

MEDIDAS DE INFORMAÇÃO E SISTEMAS INTELIGENTES APLICADOS NO DIAGNÓSTICO DE CURTO-CIRCUITO DO ESTATOR DE MOTORES DE INDUÇÃO TRIFÁSICOS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de "Mestre em Engenharia Elétrica".

Orientador: Prof. Dr. Paulo Rogério Scalassara

CORNÉLIO PROCÓPIO 2016

Dados Internacionais de Catalogação na Publicação

B362 Bazan, Gustavo Henrique

Medidas de informação e sistemas inteligentes aplicados no diagnóstico de curto-circuito do estator de motores de indução trifásicos. – 2016.

112 f. : il. color. ; 30 cm

Orientador: Paulo Rogério Scalassara.

Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pósgraduação em Engenharia Elétrica. Cornélio Procópio, 2016.

Bibliografia: p. 105-112.

1. Motores elétricos de indução. 2. Curtos-circuitos. 3. Redes neurais (Computação). 4. Engenharia elétrica – Dissertações. I. Scalassara, Paulo Rogério, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

CDD (22. ed.) 621.3

Biblioteca da UTFPR - Câmpus Cornélio Procópio



Ministério da Educação Universidade Tecnológica Federal do Paraná Câmpus Cornélio Procópio Programa de Pós-Graduação em Engenharia Elétrica



TERMO DE APROVAÇÃO

Título da Dissertação Nº 030:

"Medidas de Informação e Sistemas Inteligentes Aplicados no Diagnóstico de Curto-Circuito do Estator de Motores de Indução Trifásicos".

por

Gustavo Henrique Bazan

Orientador: Prof. Dr. Paulo Rogerio Scalassara

Esta dissertação foi apresentada como requisito parcial à obtenção do grau de MESTRE EM ENGENHARIA ELÉTRICA – Área de Concentração: Sistemas Eletrônicos Industriais, pelo Programa de Pós-Graduação em Engenharia Elétrica – PPGEE – da Universidade Tecnológica Federal do Paraná – UTFPR – Câmpus Cornélio Procópio, às **10 horas** do dia **08 de julho de 2016**. O trabalho foi aprovado pela Banca Examinadora, composta pelos professores:

Prof. Dr. Alessandro Goedtel (Presidente – UTFPR-CP) Prof. Dr. Bruno Augusto Angélico (EPUSP)

Prof. Dr. Wagner Endo (UTFPR-CP)

Visto da coordenação:

Prof. Dr. Alessandro do Nascimento Vargas Coordenador do Programa de Pós-Graduação em Engenharia Elétrica UTFPR Câmpus Cornélio Procópio

A Folha de Aprovação assinada encontra-se na Coordenação do Programa.

AGRADECIMENTOS

A Deus por estar sempre ao meu lado.

A minha família, pelo apoio, dedicação, esforço e a oportunidade dada para realização deste sonho.

Ao meu orientador Prof. Dr. Paulo Rogério Scalassara e ao meu coorientador Prof. Dr. Wagner Endo, pelos inúmeros e inestimáveis conselhos sobre a condução deste trabalho.

Ao Prof. Dr. Alessando Goedtel, pelas valiosas contribuições e pela disponibilização do banco de dados utilizado neste trabalho.

Aos colegas de pós-graduação, do Laboratório de Processamento de Sinais e Aplicações (LPSA), e do Laboratório de Sistemas Inteligentes (LSI), pela amizade e auxílio no desenvolvimento deste projeto.

A Universidade Tecnológica Federal do Paraná, por disponibilizar a estrutura necessária para a conclusão desta dissertação de mestrado.

Ao suporte financeiro da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná (Processos Nº 338/2012), do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Processos Nº 474290/2008-5, 473576/2011-2, 552269/2011-5, 201902/2015-0) e bolsa de estudos DS/CAPES.

"E ainda que tivesse o dom da profecia, e conhecesse todos os mistérios e toda a ciência, e ainda que tivesse toda fé de maneira tal que transportasse os montes, e não tivesse amor, nada seria." (1° Cor 12, 2).

RESUMO

BAZAN, G.H. **MEDIDAS DE INFORMAÇÃO E SISTEMAS INTELIGENTES APLICADOS NO DIAGNÓSTICO DE CURTO-CIRCUITO DO ESTATOR DE MOTORES DE INDUÇÃO TRIFÁSICOS**. 2015. 112 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

Este trabalho propõe o estudo e desenvolvimento de uma metodologia alternativa de identificação de falhas nos enrolamentos do estator de motores de indução trifásicos conectados diretamente à rede elétrica. A fim de reduzir a dimensão e complexidade destes tipos de sistemas, são utilizadas duas ferramentas de processamento de sinais, extração e seleção de características. Na etapa de extração, calcula-se a informação mútua atrasada dos sinais de correntes das fases A e B da máquina e na seleção, os algoritmos árvore de decisão C4.5 e rede neural artificial MLP são utilizados para a predição das classes, a fim de se obter um sistema de diagnóstico de falhas de estator eficaz. Os resultados experimentais *offline* e *online* consideram problemas de qualidade de energia, uma ampla faixa de conjugado de carga e curto-circuito entre as espiras do enrolamento de estator da ordem de 1% à 20%, os quais são apresentados para validar a abordagem desenvolvida neste trabalho. Os resultados obtidos indiciam que esta aboradagem pode ser empregada para classificar falhas de curto-circuito entre as espiras do stator.

Palavras-chave: Atraso da Informação Mútua, Árvore de Decisão C4.5, Rede Neural Artificial MLP, Motor de Indução Trifásico, Identificação de Falhas

ABSTRACT

BAZAN, G.H. **INFORMATION MEASURES AND INTELLIGENT SYSTEMS APPLIED TO THE STATOR SHORT-CIRCUIT DIAGNOSIS IN THREE-PHASE INDUCTION MOTORS.** 2015. 112 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

This work proposes the study and development of an alternative approach to diagnose stator short-circuit faults in induction motors driven directly from a supply line. In order to reduce the size and complexity in these types of systems, signal processing techniques of extraction and feature selection are used. In the extraction step, the mutual information of the delayed phases of current signals, i_a and i_b , are computed and in the selection procedure, the algorithms C4.5 decision tree and multilayer perceptron neural network are employed in order to obtain an effective diagnostic of stator short-circuit faults. To assess the classification accuracy across the various levels of stator short-circuit fault severity (from 1% to 20%), offline and online experimental tests also considered a wide range of load conditions and voltage unbalance in the power supply. The obtained results indicate that this approach can be employed to classify stator short-circuit faults.

Keywords: Delayed Mutual Information, C4.5 Decision Tree, MLP Artificial Neural Network, Three-Phase Induction Motors, Fault Identification

LISTA DE FIGURAS

FIGURA 1	- Tipos de falhas presentes nos MITs	20
FIGURA 2	- Tipos de falhas de estator presentes nos MITs	22
FIGURA 3	- Diagrama de Venn representando as relações existentes entre as me-	
	didas de informação, como entropia, entropias condicionais e informação	
	mútua	29
FIGURA 4	- Exemplo de uma árvore de decisão	32
FIGURA 5	– Exemplo de uma rede neural artificial MLP	36
FIGURA 6	- Estrutura geral da metodologia utilizada no trabalho	39
FIGURA 7	- Bancada de Ensaios Experimentais	40
FIGURA 8	- Sinais de correntes das fases A e B do Motor 1 operando sem falhas	
	e coniugado de carga em seu eixo de 0.7 N.m	43
FIGURA 9	 Fluxograma geral do processo de cálculo da DMI 	45
FIGURA 10	- Exemplos das PDFs marginais e conjunta das correntes, $i_a \in i_b$, para	
	o Motor 1 operando sem falhas, com torque em seu eixo de 0.7 N.m e	
	tensões equilibradas	46
FIGURA 11	 Exemplo da informação mútua deslocada em uma faixa de 150 amos- 	-
	tras para o caso do Motor 1 operando sem falhas, com conjugado de	
	carga em seu eixo de 0.7 N.m e tensões equilibradas	47
FIGURA 12	 Assinaturas da DMI para o Motor 1 operando sem falhas 	48
FIGURA 13	 Assinaturas da DMI para o Motor 1 operando com 1% de curto-circuito 	
	entre espiras do estator	48
FIGURA 14	 Assinaturas da DMI para o Motor 1 operando com 3% de curto-circuito 	
	entre espiras do estator	49
FIGURA 15	 Assinaturas da DMI para o Motor 1 operando com 5% de curto-circuito 	
	entre espiras do estator	50
FIGURA 16	- Assinaturas da DMI para o Motor 1 operando com 10% de curto-	
	circuito entre espiras do estator	51
FIGURA 17	 Curvas características da DMI com variação do nível de curto-circuito 	•
	- Motor 1 com carga nominal e tensões equilibradas	51
FIGURA 18	 Assinaturas da DMI para o Motor 2 operando sem falhas 	52
FIGURA 19	- Assinaturas da DMI para o Motor 2 operando com 10% de curto-	-
	circuito entre espiras do estator	53
FIGURA 20	 Curvas características da DMI com variação do nível de curto-circuito 	
	- Motor 2 com carga nominal e tensões equilibradas	54
FIGURA 21	 Assinaturas da DMI para o Motor 3 operando sem falhas 	54
FIGURA 22	- Assinaturas da DMI para o Motor 3 operando com 10% de curto-	•
	circuito entre espiras do estator	55
FIGURA 23	 Curvas características da DMI com variação do nível de curto-circuito 	
110010120	- Motor 3 com carga nominal e tensões equilibradas	56
FIGURA 24	 Assinaturas da DMI para o Motor 1 operando sem falhas, com torque 	
	em seu eixo de 0.7 N m e tensões equilibradas	56
FIGURA 25	 Exemplo de uma análise da resolução da informação mútua 	57
FIGURA 26	 – Eluxograma geral para a criação da árvore de decisão C4.5 	61
FIGURA 27	 – Fluxograma geral para o treinamento da RNA do tipo MI P 	64
		- · ·

FIGURA 28	- Resultados experimentais offline - Análise da DMI em função do des-	
	locamento - Motor 1	67
FIGURA 29	locamento - Motor 2	68
FIGURA 30	 Resultados experimentais offline - Análise da DMI em função do des- 	
	locamento - Motor 2 - Curto-circuito entre espiras do estator maior ou	
	igual a 3%	69
FIGURA 31	- Resultados experimentais offline - Análise da DMI em função do des-	
	locamento - Motor 3	70
FIGURA 32	- Resultados experimentais offline - Análise da DMI em função do des-	
	locamento - Motor 3 - Curto-circuito entre espiras do estator maior ou	70
	Igual a 3%	72
FIGURA 33	- Resultados experimentais offline - Analise da Divil em função do des-	70
	Posultados experimentais offline Análice de DMI em função de dos	/3
FIGURA 34	locamento - Motores 2 e 3 - Curto-circuito entre espiras do estator maior	
	ou iqual a 3%	74
FIGURA 35	 Resultados experimentais offline - Análise da resolução da DMI - Mo- 	<i>,</i> ,
	tor 1	75
FIGURA 36	- Resultados experimentais offline - Análise da resolução da DMI - Mo-	
	tor 2	76
FIGURA 37	- Resultados experimentais offline - Análise da resolução da DMI - Mo-	
	tor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%	77
FIGURA 38	- Resultados experimentais offline - Análise da resolução da DMI - Mo-	
	tor 3	78
FIGURA 39	- Resultados experimentais offline - Análise da resolução da DMI - Mo-	~~
	tor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%	80
FIGURA 40	- Resultados experimentais onnine - Analise da resolução da Divil - Mo-	80
FIGURA 41	- Resultados experimentais offline - Análise da resolução da DMI - Mo-	00
110010741	tores 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a 3%	81
FIGURA 42	 Resultados experimentais online - Motor 2 - Curto-circuito entre espi- 	0.
	ras do estator maior ou igual a 3%	84
FIGURA 43	- Resultados experimentais online - Motor 3 - Curto-circuito entre espi-	
	ras do estator maior ou igual a 3%	85
FIGURA 44	- Resultados experimentais <i>online</i> - Motores 2 e 3 - Curto-circuito entre	
	espiras do estator maior ou igual a 3%	86
FIGURA 45	- Resultados experimentais offline utilizando a rede neural MLP - Motor	
	2 - Curto-circuito entre espiras do estator maior ou igual a 1%	88
FIGURA 46	- Resultados experimentais <i>offline</i> utilizando a rede neural MLP - Motor	00
	2 - Curto-circuito entre espiras do estator maior ou igual a 3%	89
	3 - Curto-circuito entre espiras do estator major ou igual a 1%	۹N
FIGURA 48	 – Resultados experimentais offline utilizando a rede neural MLP - Motor 	50
	3 - Curto-circuito entre espiras do estator maior ou ioual a 3%	91
FIGURA 49	- Resultados experimentais offline utilizando a rede neural MLP - Moto-	
	res 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a 1%	92
FIGURA 50	- Resultados experimentais offline utilizando a rede neural MLP - Moto-	

	res 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a 3%	93
FIGURA 51	- Resultados experimentais <i>online</i> utilizando a rede neural MLP - Motor	
	2 - Curto-circuito entre espiras do estator maior ou igual a 1%	94
FIGURA 52	- Resultados experimentais <i>online</i> utilizando a rede neural MLP - Motor	
	2 - Curto-circuito entre espiras do estator maior ou igual a 3%	95
FIGURA 53	- Resultados experimentais <i>online</i> utilizando a rede neural MLP - Motor	
	3 - Curto-circuito entre espiras do estator maior ou igual a 1%	96
FIGURA 54	- Resultados experimentais <i>online</i> utilizando a rede neural MLP - Motor	
	3 - Curto-circuito entre espiras do estator maior ou igual a 3%	97
FIGURA 55	- Resultados experimentais online utilizando a rede neural MLP - Moto-	
	res 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a 1%	98
FIGURA 56	- Resultados experimentais online utilizando a rede neural MLP - Moto-	
	res 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a 3%	98
FIGURA 57	- Resumo dos resultados obtidos neste trabalho para uma matriz de	
	entrada de 25 pontos da DMI	101

LISTA DE TABELAS

TABELA	2	- Parâmetros de Especificação dos Motores de Indução	41
TABELA	3	- Limites de tensão e torque de carga na aquisição dos dados experi-	
		mentais para o Motor 1	42
TABELA	4	- Limites de tensão e torque de carga na aquisição dos dados experi-	
		mentais para o Motor 2	42
TABELA	5	- Limites de tensão e torque de carga na aquisição dos dados experi-	
		mentais para o Motor 3	42
TABELA	6	 Caracterização do coeficiente Kappa 	65
TABELA	7	- Matriz de confusão para o cálculo do coeficiente Kappa	65
TABELA	8	- Matriz de Confusão - Análise da DMI em função do deslocamento -	
		Motor 1	67
TABELA	9	- Matriz de confusão - Análise da DMI em função do deslocamento -	
		Motor 2	68
TABELA	10	- Matriz de confusão - Análise da DMI em função do deslocamento -	
		Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%	70
TABELA	11	- Matriz de confusão - Análise da DMI em função do deslocamento -	
		Motor 3	71
TABELA	12	- Matriz de confusão - Análise da DMI em função do deslocamento -	
		Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%	71
TABELA	13	- Matriz de confusão - Análise da DMI em função do deslocamento -	
		Motores 2 e 3	73
TABELA	14	- Matriz de confusão - Análise da DMI em função do deslocamento -	
		Motores 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a	
		3%	73
TABELA	15	 Matriz de Confusão - Análise da resolução da DMI - Motor 1 	75
TABELA	16	 Matriz de confusão - Análise da resolução da DMI - Motor 2 	76
TABELA	17	 Matriz de confusão - Análise da resolução da DMI - Motor 2 - Curto- 	
		circuito entre espiras do estator maior ou igual a 3%	78
TABELA	18	- Matriz de confusão - Análise da resolução da DMI - Motor 3	79
TABELA	19	 Matriz de confusão - Análise da resolução da DMI - Motor 3 - Curto- 	
		circuito entre espiras do estator maior ou igual a 3%	79
TABELA	20	 Matriz de Confusão - Análise da resolução da DMI - Motores 2 e 3 … 	80
TABELA	21	- Matriz de Confusão - Análise da resolução da DMI - Motores 2 e 3 -	
		Curto-circuito entre espiras do estator maior ou igual a 3%	81
TABELA	22	- Limites de tensão e torque de carga nos testes <i>online</i> para o Motor 2	83
TABELA	23	- Matriz de Confusão - Testes online - Motor 2 - Curto-circuito entre	
		espiras do estator maior ou igual a 3%	84
IABELA	24	- Limites de tensão e torque de carga nos testes <i>online</i> para o Motor 3	84
IABELA	25	- Matriz de Confusão - Testes online - Motor 3 - Curto-circuito entre	
		espiras do estator maior ou igual a 3%	85
IABELA	26	- Matriz de Contusão - Testes online - Motores 2 e 3 - Curto-circuito	
		entre espiras do estator maior ou igual a 3%	86
IABELA	27	- Matriz de Contusão - Testes ottline utilizando a rede neural MLP -	
		Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 1%	88

TABELA 28	- Matriz de Confusão - Testes offline utilizando a rede neural MLP -	
TARELA 29	Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3% – Matriz de Confusão - Testes <i>offline</i> utilizando a rede neural MLP -	90
	Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 1%	90
TABELA 30	- Matriz de Confusão - Testes offline utilizando a rede neural MLP -	~ .
TABELA 31	Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%	91
	Motores 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a	
	1%	92
TABELA 32	 Matriz de Contusao - Testes offline utilizando a rede neural MLP - Motores 2 e 3 - Curto-circuito entre espiras do estator major ou igual a 	
	3%	93
TABELA 33	- Matriz de Confusão - Testes online utilizando a rede neural MLP -	~ .
TABELA 34	Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 1% – Matriz de Confusão - Testes <i>online</i> utilizando a rede neural MIP -	94
	Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%	95
TABELA 35	- Matriz de Confusão - Testes <i>online</i> utilizando a rede neural MLP -	~~
TABELA 36	Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 1%	96
	Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%	96
TABELA 37	- Matriz de Confusão - Testes <i>online</i> utilizando a rede neural MLP -	
	1%	98
TABELA 38	- Matriz de Confusão - Testes <i>online</i> utilizando a rede neural MLP -	00
	Motores 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a	~ ~
	3%	99
	estator	100

LISTA DE SIGLAS E ABREVIATURAS

T_n	Torque nominal.
<i>k</i> -NN	k-Nearest Neighbor.
AD	Árvores de Decisão.
AG	Algoritmos Genéticos.
AMIF	Auto-Mutual Information Function.
ANFIS	Adaptive Neuro-Fuzzy Inference System.
CART	Classification and Regression Tree.
CMIF	Cross-Mutual Information Function.
DI	Divisão de Informação.
DMI	Delayed Mutual Information.
EEG	Eletroencefalograma.
FMM	Fuzzy Min-Max.
GI	Ganho de Informação.
н	Entropia.
HE	Hierarchical Entropy.
K	Kappa.
LAIPS	Laboratório de Automação Inteligente de Processos e Sistemas.
LF	Lógica Fuzzy.
LSI	Laboratório de Sistemas Inteligentes.
MCSA	Motor Current Signal Analysis.
MI	Mutual Information.
MIT	Motor de Indução Trifásico.
MLP	Multi-Layer Perceptron.
MSE	Multi-Scalar Entropy.
PCA	Principal Component Analysis.
PDF	Probability Density Function.
RBF	Radial Basis Function.
RG	Razão de Ganho.
RNA	Redes Neurais Artificiais.
SI	Sistemas Inteligentes.
SVM	Support Vector Machines.
TF	Transformada de <i>Fourier</i> .

- TH Transformada *Hilbert*.
- TW Transformada Wavelet.
- TWC Transformada *Wavelet* Contínua.
- TWD Transformada *Wavelet* Discreta.
- WEKA Waikato Environment for Knowledge Analysis.

LISTA DE ALGORITMOS

ALGORITMO 1	-	Algoritmo para o cálculo da informação mútua atrasada .	44
ALGORITMO 2	_	Algoritmo para a obtenção da árvore de decisão C4.5	59
ALGORITMO 3	-	Algoritmo para a poda da árvore de decisão	60
ALGORITMO 4	-	Algoritmo para o treinamento da RNA do tipo MLP	62

SUMÁRIO

1 INTRODUÇÃO	16
1.1 JUSTIFICATIVA	18
1.2 OBJETIVOS	18
1.3 ORGANIZAÇÃO DO TRABALHO	19
2 ESTUDO DAS FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS	20
2.1 FALHAS EM MITS	20
2.2 METODOLOGIAS PARA O DIAGNÓSTICO DE FALHAS EM MITS	22
2.3 CONCLUSÃO DO CAPÍTULO	25
3 ESTUDO DAS FERRAMENTAS DE RECONHECIMENTO DE PADRÕES	26
3.1 EXTRAÇÃO DAS CARACTERÍSTICAS UTILIZANDO MEDIDAS DE INFORMA-	
CÃO	26
3.2 CLASSIFICAÇÃO DE PADRÕES LITILIZANDO ÁRVORES DE DECISÃO	30
3 2 1 Árvore de Decisão	31
3 2 2 Árvore de Decisão C4 5	32
3 2 3 Medidas Estatísticas Utilizadas para a Construção da Árvore de Decisão	33
3.2.4 Método de Poda Pessimista	35
3.3 CLASSIFICAÇÃO DE PADRÕES UTILIZANDO REDES NEURAIS ARTIFICIAIS	36
3.4 CONCLUSÃO DO CAPÍTULO	38
4 MATERIAIS E MÉTODOS	39
4.1 BANCO DE DADOS	40
4.2 EXTRAÇÃO DE CARACTERÍSTICAS PELA INFORMAÇÃO MÚTUA ATRASADA	43
4.3 CLASSIFICAÇÃO DE PADRÕES POR SISTEMAS INTELIGENTES	57
4.3.1 Árvore de Decisão	58
4.3.2 Rede Neural Artificial	60
4.4 VALIDAÇÃO CRUZADA	63
4.5 CONCLUSÃO DO CAPÍTULO	63
5 RESULTADOS E DISCUSSÕES	65
5.1 RESULTADOS - TESTES EXPERIMENTAIS OFFLINE	66
5.1.1 Resultados da Análise da DMI em Função do Deslocamento $ au$	66
5.1.2 Resultados da Análise da Resolução da DMI	74
5.2 RESULTADOS - TESTES EXPERIMENTAIS ONLINE	82
5.3 COMPORTAMENTO DOS PADRÕES DA DMI EM UM CLASSIFICADOR BASE-	
ADO EM RNA	87
5.3.1 Testes Experimentais <i>Offline</i> Utilizando a Rede Neural MLP	87
5.3.2 Testes Experimentais <i>Online</i> Utilizando a Rede Neural MLP	94
5.4 COMPARAÇÃO COM OUTROS TRABALHOS ENCONTRADOS NA LITERATURA	01
	100
	102
	103
	105

1 INTRODUÇÃO

O reconhecimento de padrões busca a classificação de objetos como imagens, formas de onda ou qualquer tipo de medidas com um determinado número de categorias ou classes (THEODORIDIS; KOUTROUMBAS, 2009). Com o avanço da tecnologia, aumentou a quantidade de dados disponíveis destes objetos. Assim, os métodos para redução da dimensão dos dados tornaram-se importantes no campo de reconhecimento de padrões, pois podem levar a um custo computacional menor em processamentos posteriores e, também, a uma melhor generalização e interpretação de um número menor de características (JUKIC; FILIPOVIC, 2013).

Além disso, existem muitos benefícios potenciais no emprego destes métodos, pois estes podem facilitar o entendimento na visualização dos dados, bem como reduzir a coleta dos mesmos, o custo de armazenamento e o tempo de processamento, resultando assim em uma melhoria de desempenho (CHOI et al., 2012; PALANICHAMY; RAMASAMY, 2013; ZHAO et al., 2014).

As duas principais abordagens de redução de dimensão tipicamente utilizadas são a extração e a seleção de características. Os métodos de extração criam novas características por meio de transformações ou combinações do conjunto de dados original (ESTÉVEZ et al., 2009; JAIN; DUIN; MAO, 2000). Já a seleção, é o processo de selecionar um subconjunto de características que contenha as informações relevantes do conjunto original, para que seja possível uma distinção de uma classe das outras, visando aumentar a qualidade dos dados e o desempenho dos classificadores (ESTÉVEZ et al., 2009; CHOI et al., 2012; HERMAN et al., 2013; PALANICHAMY; RAMASAMY, 2013). Em recentes pesquisas, empregam-se técnicas de processamento de sinais para a extração e seleção de características do Motor de Indução Trifásico (MIT), a fim de diagnosticar as falhas presentes nesta máquina (HENAO et al., 2014).

Algumas características fizeram com que estes MITs tornassem presentes nos mais diversos processos produtivos industriais, como baixo custo de aquisição, manutenção e adaptação frente a diversas condições de cargas mecânicas, além de sua robustez para aplicações em ambientes agressivos (BOUZID; CHAMPENOIS, 2013; SANTOS et al., 2014; SUETAKE; SILVA; GOEDTEL, 2011; WANG, 2001). De acordo com o Balanço Energético Nacional apresentado em 2015, estima-se que no ano de 2014 foram destinados cerca de 205,90 TWh às indústrias, sendo este valor 32,9% de toda a energia elétrica consumida no Brasil (ELETROBRÁS-PROCEL, 2015).

Apesar destes motores apresentarem características que demonstram sua confiabilidade e robustez, os mesmos estão sujeitos à falhas elétricas e mecânicas que podem ocorrer devido ao seu tempo e modo de operação, pelas condições onde estão instalados, por desequilíbrio das tensões de alimentação, dentre outros fatores. Dentre as falhas elétricas destacam-se as falhas de curto-circuito entre as espiras do estator, sendo responsáveis entre 20% a 40% das paradas indesejadas dos motores (THORSEN; DALVA, 1995; BONNETT; YUNG, 2008; BELLINI et al., 2008; BARZEGARAN; MAZLOOMZADEH; MOHAMMED, 2013; ZAREI; TAJEDDINI; KARIMI, 2014; DRIF; CARDOSO, 2014).

Os defeitos incipientes dentro da máquina geralmente afetam a sua performance antes mesmo que falhas significativas venham a ocorrer, acarretando assim em prejuízos ao processo industrial (BRITO, 2002; LAMIM, 2003; BELLINI et al., 2008; SANTOS; SILVA; SUETAKE, 2012). Essas falhas podem ser identificadas por sistemas de diagnósticos não invasivos, que realizam as leituras de valores das variáveis elétricas e mecânicas do motor tais como: corrente, tensão, temperatura, vibração, torque, dentre outras, para reconhecer os padrões de comportamento defeituoso da máquina (BELLINI et al., 2008; SANTOS; SILVA; SUETAKE, 2012).

A teoria da informação é utilizada com frequência em problemas relativos ao reconhecimento de padrões, a aprendizagem de máquina e na detecção de falhas. Esta metodologia fornece um conjunto de ferramentas para medir a redundância entre as variáveis envolvidas no problema (LEIVA-MURILLO; ARTÉS-RODRÍGUEZ, 2012). Segundo Melia et al. (2015), a informação mútua é capaz de detectar as dependências lineares e nãolineares entre as séries temporais. Visto que as falhas dos MITs possuem características não-lineares, neste trabalho utiliza-se a informação mútua como medida de similaridade entre as correntes de estator, visando extrair informações relevantes que possibilitem o eficiente diagnóstico das falhas de curto-circuito de estator do motor de indução trifásico.

Além das ferramentas de processamento de sinais, os Sistemas Inteligentes (SI) vêm destacando-se na identificação de falhas em máquinas elétricas, pois são capazes de determinar o tipo de falha sem necessitar de modelos matemáticos complexos, tornando a sua implementação computacional mais simples (SANTOS; SILVA; SUETAKE, 2012). Além disso, os SI podem classificar e determinar a origem das falhas, contribuindo para que não haja uma parada indesejada no processo produtivo. Dentre eles, podem-se citar as Árvores de Decisão (AD), as Redes Neurais Artificiais (RNA), a Lógica Fuzzy (LF), os Algoritmos Genéticos (AG) e os Sistemas Híbridos (NGUYEN; LEE; KWON, 2008; AYDIN; KARAKOSE; AKIN, 2014; CHOW; YEE, 1991; CHOW; SHARP; HUNG, 1993; CHOW; SHARPE; HUNG, 1993; ZIDANI et al., 2003; KOLLA; ALTMAN, 2007; BOUZID et al., 2007; GHATE; DUDUL, 2009; SEERA et al., 2012; PALÁCIOS et al., 2015; GODOY et al., 2015).

As AD são amplamente aplicadas em pesquisas recentes na área de mineração de dados, reconhecimento de padrões e classificação de falhas em máquinas elétricas, pois

trabalham dividindo o conjunto total de dados de treinamento em subconjuntos, de maneira recursiva, utilizando-se de dados estatísticos como critérios de seleção (NGUYEN; LEE; KWON, 2008; SUGUMARAN; MURALIDHARAN; RAMACHANDRAN, 2007; SEERA et al., 2012; SEERA et al., 2013; AYDIN; KARAKOSE; AKIN, 2014; PALÁCIOS et al., 2015). Esta ferramenta seleciona do conjunto de dados original, os atributos mais relevantes para a construção do seu modelo classificador com o intuito de identificar as falhas presentes na máquina.

Assim, a proposta deste trabalho consiste em apresentar uma estratégia para o diagnóstico de falhas de curto-circuito no enrolamento de estator baseada em medidas de similaridade entre os sinais das correntes de estator no domínio do tempo. Ainda, utilizamse as estratégias de classificação de padrões baseadas em sistemas inteligentes como ferramenta de seleção de características e classificação das amostras.

1.1 JUSTIFICATIVA

Diante do fato que as indústrias consomem boa parte da energia elétrica produzida no Brasil, cujos MITs são os maiores responsáveis por este consumo, torna-se evidente a importância destas máquinas nas diversas aplicações industriais.

Um sistema de diagnóstico de falhas de máquinas elétricas pode auxiliar a manutenção destas máquinas, pois tem a possibilidade de se detectar a falha em seu estágio incipiente. Assim, objetiva-se eliminar as paradas não programadas do processo e, consequentemente, reduzir os prejuízos da empresa.

Uma forma de minimizar estas perdas indesejadas consiste na utilização de sistemas eficazes que associem técnicas adequadas de processamento de sinais, como métodos de extração e seleção de características e de classificação de padrões, tais como as árvores de decisão. As AD modelam o conhecimento das anomalias dos sinais de corrente, aumentando assim a performance do diagnóstico das falhas presentes nas máquinas e possibilitando a sua identificação em estágio inicial (HENAO et al., 2014). A busca por métodos de diagnósticos adequados vem despertando a motivação de diversos pesquisadores nos últimos anos (BELLINI et al., 2008; AYDIN; KARAKOSE; AKIN, 2012; HENAO et al., 2014).

1.2 OBJETIVOS

O objetivo geral deste presente trabalho consiste no desenvolvimento de um método de reconhecimento de padrões utilizando medidas de informação mútua e sistemas inteligentes aplicados no diagnóstico de falhas de curto-circuito entre as espiras do enrolamento de estator em motores de indução trifásicos acionados diretamente da rede de alimentação.

Deste modo, os objetivos específicos do trabalho são apresentados a seguir:

- Analisar os sinais das correntes de linha das máquinas elétricas operando sem falhas e com falhas;
- Aplicar a informação mútua atrasada conforme Nichols (2006), Alonso et al. (2007)
 e Melia et al. (2015), a fim de obter medidas de associação entre os sinais das correntes de fases A e B dos MITs;
- Utilizar a árvore de decisão para selecionar os atributos mais relevantes do conjunto de dados e classificar os padrões, avaliando assim as medidas de informação mútua obtidas na etapa de extração de características;
- Avaliar a capacidade do sistema proposto para o diagnóstico de falhas de curtocircuito entre as espiras de estator a partir de testes de generalização;
- Validar a metodologia proposta em testes online;
- Utilizar a rede neural artificial de múltipas camadas, afim de avaliar os padrões extraídos na etapa de processamento de sinais como uma ferramenta alternativa de classificação de padrões.

1.3 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado conforme descrito a seguir. No Capítulo 2 é apresentado um estudo sobre as falhas presentes nos MITs, bem como os principais trabalhos relacionados aos métodos para o diagnóstico e identificação destas falhas.

No Capítulo 3, apresentam-se os conceitos fundamentais do modelo de extração de características baseado na teoria da informação, bem como dos classificadores baseados em árvores de decisão e redes neurais artificiais. No Capítulo 4 é apresentada a metodologia utilizada para o diagnóstico de falhas de curto-circuito entre as espiras do estator no sistema proposto. No Capítulo 5, apresentam-se os resultados experimentais obtidos a partir dos testes realizados, a fim de validar a proposta. Finalmente, no Capítulo 6 são descritas as conclusões finais do trabalho bem como as perspectivas futuras.

2 ESTUDO DAS FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

Neste capítulo são apresentados os aspectos relacionados às falhas em MITs, bem como as pesquisas que tratam a correta identificação e diagnóstico destas falhas ainda em um estágio inicial de evolução, evitando assim paradas não-programadas e reduzindo custos com manutenção.

2.1 FALHAS EM MITS

Grande parte dos equipamentos utilizados nos processos industriais são movidos por motores elétricos que podem, com o passar do tempo, apresentar algum tipo de falha. Estas falhas podem ser classificadas em dois grupos: falhas elétricas e falhas mecânicas. As falhas elétricas podem ocorrer devido a problemas relativos aos enrolamentos de estator e de rotor, às barras e anéis quebrados no rotor e suas conexões. As falhas mecânicas, por sua vez, podem ser provenientes de problemas de rolamentos, excentricidade, desgaste de acoplamento e desalinhamento (BELLINI et al., 2008; HENAO et al., 2014), conforme é ilustrado na Figura 1.



Figura 1 – Tipos de falhas presentes nos MITs Fonte: Autoria própria

Dentre as falhas mecânicas presentes nos MITs, as falhas de rolamentos são as maiores responsáveis por paradas indesejadas nos processos industriais, representado entre 50 e 70% das causas associadas a estas paradas (THORSEN; DALVA, 1995; BON-NETT; YUNG, 2008; BELLINI et al., 2008). Suas origens estão associadas às assimetrias do rotor, mas também podem ser provenientes dos anéis internos, dos anéis externos ou dos elementos girantes do rolamento (SUETAKE, 2012). Já o desenvolvimento e a progressão destas falhas ocorrem em função da vibração, desgaste interno, desalinhamento do eixo, excentricidade, corrente no rolamento, corrosão, poeira, lubrificação inadequada, além de uma incorreta montagem do rolamento (BACCARINI, 2005; SANTOS; SILVA; SU-ETAKE, 2012).

As falhas relacionadas ao rotor correspondem de 6 a 10% do total de problemas associados aos MITs (THORSEN; DALVA, 1995; BONNETT; YUNG, 2008; BELLINI et al., 2008). As principais falhas de rotor são oriundas da quebra da barra ou por meio de rachaduras nos anéis terminais. Tais falhas tem como características: vibração excessiva, ruídos e faiscamento durante a partida do MIT. Além disso, este tipo de falha não provoca uma parada imediata na máquina, podendo o dispositivo continuar a sua operação mesmo com a presença de barras quebradas ou trincadas. No entanto, deve-se analisar o estado e a gravidade do problema, pois a barra pode atingir o enrolamento do estator, causando o rompimento do seu isolamento e, consequentemente, provocar um curto-circuito entre as espiras ou até mesmo entre as fases do estator (MERTENS, 2008).

Já as falhas presentes no estator das máquinas elétricas, as quais são objeto de estudo deste trabalho, representam entre 20 e 40% do total, sendo destacadas como um dos principais problemas encontrados em motores elétricos (THORSEN; DALVA, 1995; BONNETT; YUNG, 2008; BELLINI et al., 2008; BARZEGARAN; MAZLOOMZADEH; MOHAM-MED, 2013; ZAREI; TAJEDDINI; KARIMI, 2014; DRIF; CARDOSO, 2014).

Os defeitos mais comuns associados a falhas de estator são: curto-circuito entre fase-terra, fase-fase, curto-circuito entre as bobinas de um mesmo enrolamento ou de diferentes fases (TRAN et al., 2013; EFTEKHARI et al., 2014). O isolamento do estator começa a se deteriorar pelo rompimento do isolamento de poucas espiras, contudo, sua evolução é rápida e pode prejudicar o funcionamento do motor (BELLINI et al., 2008; GANDHI; CORRIGAN; PARSA, 2011; DRIF; CARDOSO, 2014; GODOY et al., 2015). Na Figura 2 são apresentados os tipos de falhas no enrolamento do estator.

Para o monitoramento das condições de operação, bem como para o diagnóstico e identificação das falhas presentes nos MITs, os pesquisadores utilizam-se de ferramentas de processamento de sinais para a extração e seleção de características relevantes dos sinais. Além disso, os SI devido a sua capacidade em auxiliar na identificação das falhas sem a necessidade de modelos matemáticos complexos, também estão sendo alvo de estudo em pesquisas relacionadas às falhas de máquinas elétricas (SANTOS; SILVA; SUETAKE, 2012). Na sequência são abordadas os trabalhos relacionados as diversas metodologias propostas para o diagnóstico destas falhas.



Figura 2 – Tipos de falhas de estator presentes nos MITs Fonte: Autoria própria

2.2 METODOLOGIAS PARA O DIAGNÓSTICO DE FALHAS EM MITS

Na literatura podem ser encontrados diversos métodos que utilizam a análise dos sinais de correntes do motor, do termo em inglês *Motor Current Signal Analysis* (MCSA), para a detecção de falhas presentes nos motores de indução. Esta metodologia foca os seus esforços na análise espectral da corrente do estator e tem sido utilizada no diagnóstico de diferentes tipos de falhas tais como de estator, barras quebradas de rotor, rolamentos e excentricidade. Pode-se citar alguns exemplos de técnicas de processamento de sinais que utilizam a decomposição espectral dos sinais. Dentre estas, encontra-se a Transformada de *Fourier* (TF) (SHARIFI; EBRAHIMI, 2011; PONS-LLINARES et al., 2015), a Transformada *Wavelet* (TW) (ASFANI et al., 2012; DEVI; SARMA; RAO, 2015; PONS-LLINARES et al., 2015; DAS et al., 2010; ANTONINO-DAVIU et al., 2013; SHI et al., 2014), a Transformada *Hilbert* (TH) (SAHRAOUI et al., 2014; KONAR; CHATTOPADHYAY, 2015), além de outras.

O artigo de Das et al. (2010) apresenta resultados experimentais para o monitoramento de falhas de curto-circuito no enrolamento do estator do MIT. Para a análise da corrente de linha do motor, a metodologia apresentada utilizou de técnicas de processamento de sinais e ferramentas de redução de dados, combinando a Transformada de *Park* e a Transformada *Wavelet* Contínua (TWC). As máquinas de vetores de suporte, do termo em inglês *Support Vector Machines* (SVM) foram utilizadas para a classificação das falhas com base nas características de falhas extraídas.

Nos trabalhos de Ghate e Dudul (2010) e Ghate e Dudul (2011), variáveis estatísticas como média, variância, *skewnees*, *kurtosis*, geradas a partir dos sinais de corrente possibilitaram a identificação de falhas de curto-circuito de estator. Já em Asfani et al. (2012), utiliza-se a Transformada *Wavelet* Discreta (TWD) juntamente com as RNA no processo de investigação deste tipo de falhas. Os níveis de energia dos coeficientes *wavelet* de alta frequência são utilizados como parâmetros de entrada das RNA.

No artigo de Antonino-Daviu et al. (2013), foi desenvolvida uma metodologia que aplica a TWD com uma Transformada Escalar nos sinais de corrente em regime transitório, a fim de diagnosticar a presença de barras quebradas em motores de diversas potências operando em uma ampla faixa de condições. Em Shi et al. (2014), os autores utilizam novos índices baseados no valor médio da corrente do estator para o diagnóstico de barras quebradas de rotor em motores de indução. Estes índices são propostos por meio de análises dos coeficientes *wavelets*, que permitem a extração de informações necessárias para um eficiente diagnóstico de falhas de barras quebradas do motor.

No trabalho de Sahraoui et al. (2014), o método baseado na análise espectral dos módulos vetoriais de *Park* combinados com a TH é utilizado para a detecção de falhas de curto-circuito entre as espiras de estator em MITs. Observou-se que estas medidas contêm informações relevantes para o diagnóstico destas falhas. Já em Devi, Sarma e Rao (2015), a TWD foi utilizada no processo de extração de características dos sinais de corrente para a identificação da severidade destas falhas, mesmo com a máquina operando sob condições de desequilíbrio de tensão.

Na pesquisa de Leite et al. (2015), são analisados os sinais das correntes do MIT por meio de algoritmos utilizando *kurtosis* espectrais como a kurtograma rápida e a kurtograma *wavelet*, buscando detectar a severidade de falhas nos rolamentos de pista externa em motores de indução trifásicos. Recentemente, o trabalho de Pons-Llinares et al. (2015) apresentou uma comparação do emprego das TWC e TWD, e da Transformada Rápida de *Fourier* (FFT) nas correntes, em regime transitório, para o diagnóstico de falhas de rotor em MITs sujeitos a situações reais adversas.

Outros autores propõem métodos e técnicas que utilizam monitoramento de vibração (FILHO; PEDERIVA; BRITO, 2014; SESHADRINATH; SINGH; PANIGRAHI, 2014), monitoramento térmico (GAO et al., 2008), sinais magnéticos (FILHO; PEDERIVA; BRITO, 2014; BARZEGARAN; MAZLOOMZADEH; MOHAMMED, 2013; FROSINI et al., 2012), potências ativa e reativa (DRIF; CARDOSO, 2014), dentre outras variáveis para o diagnóstico de falhas, conforme apresentado a seguir.

No trabalho de Barzegaran, Mazloomzadeh e Mohammed (2013), os autores desenvolveram uma metodologia para o diagnóstico de falhas de curto-circuito nos enrolamentos de estator por meio do uso de sinais magnéticos, associando o método numérico de elementos finitos com RNA. Já os estudos de Immovilli et al. (2013) e Jin et al. (2014) fizeram uso de técnicas de análise dos elementos finitos e de análise estatística para o desenvolvimento de métodos de diagnósticos de falhas nos rolamentos de máquinas elétricas.

Em Filho, Pederiva e Brito (2014), os autores utilizam técnicas de análises dos sinais de vibração e do fluxo magnético para a detecção e o diagnóstico de falhas de estator, com o MIT sujeito a desbalanceamento nas tensões de alimentação. No artigo de Drif e Cardoso (2014) é proposta uma metodologia para o diagnóstico destas falhas em motores acionados diretamente da rede e também por inversores de frequência. A estratégia apresentada consiste na comparação da análise de assinatura de ambas as potências instantâneas ativa e reativa obtidas por meio de medidas das tensões e correntes no domínio da frequência.

No trabalho de Seshadrinath, Singh e Panigrahi (2014), os autores utilizaram um sistema inteligente para o diagnóstico de múltiplas falhas em motores acionados por inversores de frequência. Realizou-se uma investigação das assinaturas de vibração da máquina combinando a TW e os classificadores SVM e *k-Nearest Neighbor* (*k*-NN).

Já em Konar e Chattopadhyay (2015), também propõem-se um método de diagnóstico multi-falhas, isto é, falhas de rotor, rolamentos, estator e desequilíbrio de tensão para motores de indução. Utilizam-se a TWC e a TH combinadas com AG para a extração das características e redução da dimensionalidade das informações obtidas dos sinais de vibração não estacionários. Na etapa de classificação das falhas, foram utilizados os classificadores *Multi-Layer Perceptron* (MLP), SVM e *Radial Basis Function* (RBF).

De modo a eliminar a necessidade de sensores de vibração, dentre outros equipamentos que possam encarecer o sistema de diagnóstico e detecção de falhas, alguns autores estão buscando métodos não-invasivos baseados em sinais de corrente de linha.

Em Godoy et al. (2015) são apresentadas estratégias alternativas aos métodos tradicionais baseada em sistemas inteligentes para o diagnóstico e classificação de falhas no enrolamento de estator de MITs acionados por três modelos distintos de inversores de frequência. Monitoram-se as amplitudes dos sinais das correntes no domínio do tempo, utilizando diretamente um semiciclo da forma de onda para a classificação das falhas.

No artigo de Palácios et al. (2015), é proposta a avaliação de diversos métodos de classificação de padrões, como *Naive Bayes*, *k*-NN, SVM, RNA e AD, para a identificação de multi-falhas, como falhas de rotor, rolamentos e estator, utilizando as amplitudes das correntes do motor no domínio do tempo.

2.3 CONCLUSÃO DO CAPÍTULO

Neste capítulo foram apresentadas algumas metodologias para detecção de falhas em motores de indução. É possível notar que, recentemente, alguns pesquisadores estão adotando técnicas de identificação de falhas não-invasivas à máquina.

Tendo em vista a identificação e detecção de falhas de estator, 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 árvores de decisão tanto no processo de seleção dos atributos quanto na classificação das amostras. Os padrões da informação mútua também são utilizados como parâmetros de entrada de uma rede neural artificial com o intuito de avaliar estes padrões. No próximo capítulo são descritos os conceitos das ferramentas utilizadas neste sistema.

3 ESTUDO DAS FERRAMENTAS DE RECONHECIMENTO DE PADRÕES

Neste capítulo são abordadas as principais ferramentas utilizadas no sistema proposto de reconhecimento de padrões aplicado a falhas de estator em MITs com alimentação senoidal. São descritos os aspectos gerais relacionados às etapas de processamento dos sinais, bem como de classificação de padrões de acordo com a metodologia proposta para este trabalho. Detalhes acerca da teoria da informação mútua, árvores de decisão e redes neurais artificiais, base para a implementação do método tratado neste trabalho, são apresentados neste capítulo.

3.1 EXTRAÇÃO DAS CARACTERÍSTICAS UTILIZANDO MEDIDAS DE INFORMAÇÃO

Nesta seção são descritos os conceitos relacionados à etapa de extração de características, com o intuito de se obter os padrões dos sinais saudáveis e com falhas das máquinas de indução trifásicas. São apresentados os conceitos relacionados à teoria da informação, bem como seus modelos matemáticos envolvidos.

Ferramentas baseadas em extração de características são aplicadas em áreas como biomédica, diagnóstico de sistemas, mineração de dados, aprendizagem de máquinas e reconhecimento de padrões (HAN; KAMBER; PEI, 2012). Assim, a teoria da informação vem se tornando alvo de estudo nestes processos de extração de características. Os dois conceitos mais utilizados são entropia e informação mútua. A entropia é uma ferramenta difundida, sendo utilizada em uma ampla quantidade de aplicações como biomédica, mineração de dados, aprendizagem de máquinas, reconhecimento de padrões e problemas relacionados a falhas em máquinas elétricas (ZHANG et al., 2010; ZHU; SONG; XUE, 2014; VERMA; SARANGI; KOLEKAR, 2014; SCHMITT et al., 2013; SCHMITT et al., 2015). Já a informação mútua encontra-se numa grande quantidade de estudos em áreas como biomédica, mineração de dados e reconhecimento de padrões (ONG; SEGHOUANE, 2011; LOECKX et al., 2010; MELIA et al., 2015; LI et al., 2011; FAIZ et al., 2010).

Desta forma, uma das contribuições deste trabalho consiste no desenvolvimento de um sistema de extração de características e reconhecimento de padrões aplicado aos sinais de correntes de linha de máquinas elétricas utilizando informação mútua. Para tal, utiliza-se o conceito de entropia.

Conforme Cover e Thomas (2006), a Entropia (H) definida por Shannon para uma variável aleatória discreta X, é dada pela equação (1), em *bits*.

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

Sendo que o alfabeto de eventos da variável aleatória $X \notin \chi$ e a função distribuição de probabilidade associada a esta variável, $p_X(x)$. Quando a entropia é calculada com o logaritmo na base 2, a mesma é medida em *bits*. Entretanto, quando utiliza-se a base neperiana sua unidade é o *nats*.

Os conceitos de entropia são aplicados a sistemas de diagnóstico de falhas em máquinas elétricas. Zhang et al. (2010) propuseram uma técnica para o diagnóstico de falhas nos rolamentos de MITs, baseados no conceito da entropia multi-escala, do termo em inglês *Multi-Scalar Entropy* (MSE), e em sistemas de inferência neuro-fuzzy, do termo em inglês *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Os referidos autores, com o intuito de reduzir a dimensão da matriz de entrada do sistema ANFIS, extraíram parâmetros estatísticos do conjunto de dados original através da MSE.

No trabalho de Zhu, Song e Xue (2014), os autores desenvolveram um modelo para o diagnóstico de falhas em rolamentos de MITs através da combinação da entropia hierárquica, do termo em inglês *Hierarchical Entropy* (HE), e SVM. As HEs dos sinais de vibração da máquina sob diversas condições de operação foram calculadas a fim de formar a matriz de entrada do classificador SVM.

Diferentemente de Zhang et al. (2010) que utilizaram a MSE para analisar apenas os sinais de vibração do motor, Verma, Sarangi e Kolekar (2014) apresentam uma metodologia para o diagnóstico de falhas de estator de MITs, que utiliza a MSE para analisar os sinais de vibração e das correntes da máquina, onde as características extraídas destes sinais serviram como parâmetros de entrada do classificador de Lógica *Fuzzy*.

Schmitt et al. (2013) e Schmitt et al. (2015) apresentaram um estudo com sinais, simulados e reais, de corrente de MITs com rolamentos normais e com falhas. Utilizaramse medidas de previsibilidade dos sinais por meio da entropia relativa de componentes *wavelet*, e de redes neurais para a detecção das falhas.

Utilizando-se dos conceitos da entropia de Shannon entre duas variáveis aleatórias, $H(X) \in H(Y)$, é possível determinar a informação mútua, do termo inglês *Mutual Information* (MI).

Estas ferramentas são muito utilizadas na área de sistemas biológicos, com o intuito de solucionar problemas de reconhecimento de padrões, como por exemplo, reconhecimento de imagens. No trabalho de Ong e Seghouane (2011), utiliza-se a MI no processo de extração de características das imagens obtidas por meio de exames de colonografia, objetivando identificar os possíveis pólipos, antes que os mesmos já tenham se tornados cancerígenos.

Loeckx et al. (2010) propuseram uma nova medida de similaridade, designada informação mútua condicional, para o registro de imagens, como de tomografia computa-

cional, ressonância magnética, dentre outros tipos de imagens médicas.

Com o objetivo caracterizar dois grupos de pacientes com diferentes níveis de excessiva sonolência diurna por meio de análises dos sinais de Eletroencefalograma (EEG), Melia et al. (2015) desenvolveram duas novas técnicas de processamento de sinais nãolineares; a saber: a auto-informação mútua, do termo inglês *Auto-Mutual Information Function* (AMIF) e a informação mútua cruzada, do termo inglês *Cross-Mutual Information Function* (CMIF). Estas novas ferramentas detectam as características relevantes nos sinais EEG, resultando assim em um alto desempenho na discriminação das amostras.

Na área de diagnóstico e monitoramento de falhas em máquinas elétricas, encontrase o trabalho de Li et al. (2011). No referido trabalho, os autores utilizaram a MI como ferramenta de extração de características, com o objetivo de extrair a máxima relevância e mínima redundância entre os sinais de vibração de uma caixa de engrenagens. Os autores empregaram a metodologia em vários equipamentos industriais, de modo a diagnosticar as falhas de engrenagens e rolamentos presentes no equipamento.

Faiz et al. (2010) utilizaram o método de elementos finitos para modelar um motor de indução sob diversos tipos de falhas de excentricidade. Na etapa de extração de características, os autores empregaram o critério da MI, a fim de selecionar as características mais relevantes e menos redundantes dos sinais de corrente do motor. A metodologia adotada se mostrou precisa e confiável para a detecção de falhas de excentricidade.

Em termos gerais, a MI é uma métrica que possibilita a determinação da informação compartilhada entre duas variáveis baseadas nas medidas de incerteza dadas pelas entropias condicionais destas duas variáveis. De certa forma, esta grandeza indica a redução no nível de incerteza associado a uma variável aleatória por meio da informação trazida por outra variável (COVER; THOMAS, 2006). Em termos de suas respectivas entropias, a informação mútua é descrita pela equação (2).

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

Sendo $H(X|Y) \in H(Y|X)$, as entropias condicionais de *X* dado *Y*, e de *Y* dado *X*, respectivamente.

Segundo Reza (1994) e Dionisio, Menezes e Mendes (2004), uma desigualdade importante para os estudos relacionados a teoria da informação é que $H(X) \ge H(X|Y)$, sendo isto válido quando X e Y forem estatisticamente independentes. Esta afirmação mostra que a incerteza associada a uma variável aleatória X será sempre maior ou igual à incerteza associada a esta variável dado que se conhece uma segunda variável aleatória, neste caso, a variável Y. Portanto, a entropia de X nunca é aumentada pelo conhecimento de *Y*; será menor, exceto na situação em que *X* e *Y* forem estatisticamente independentes, caso em que não há alteração no seu valor, resultando em um nível de incerteza máximo. A Figura 3 apresenta o diagrama de Venn que ilustra as relações existentes entre as medidas de informação.



Figura 3 – Diagrama de Venn representando as relações existentes entre as medidas de informação, como entropia, entropias condicionais e informação mútua
 Fonte: Adaptado de Cover e Thomas (2006)

A MI é uma ferramenta de medida de similaridade entre séries temporais coletadas simultaneamente a partir de um sistema em estudo (FAES; ERLA; NOLLO, 2012; DIONISIO; MENEZES; MENDES, 2004). Assim, ao aplicar esta ferramenta nos sinais de correntes das máquinas elétricas é possível quantificar essa medida de associação entre os sinais, possibilitando então verificar as condições de operação da máquina.

A MI também é considerada como uma das principais consequências da entropia de Shannon, e para o cálculo desta, utilizam-se as funções densidade de probabilidade, do termo inglês *Probability Density Function* (PDF), dos sinais em estudo. O cálculo da informação mútua é definido pela equação (3).

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

Sendo que o alfabeto de eventos da variável aleatória $X \notin \chi$ e o da variável aleatória Yé γ , p(x) e p(y) são as probabilidade marginais de X e Y, respectivamente, e p(x,y), a probabilidade conjunta entre estas duas variáveis.

Tendo em vista que os modelos e funções de transferência de um sistema não são tão simples de serem obtidos, a utilização das medidas de similaridade obtidas através do cálculo da MI se torna uma alternativa para a obtenção de relações de causalidade. Estas, por sua vez, não dependem de um modelo ou de uma função de transferência e as relações são extraídas diretamente dos sinais em estudo. Desta forma, as aplicações com a informação mútua podem ser designadas como *model-free* (ENDO, 2014; ENDO et al., 2015).

Outra medida de informação que vem sendo utilizada em análises de estruturas dinâmicas de sistemas complexos é a informação mútua atrasada, do termo inglês *Delayed Mutual Information* (DMI) (NICHOLS, 2006; ALONSO et al., 2007; MELIA et al., 2015). Esta grandeza quantifica a dependência entre as variáveis aleatórias buscando encontrar a medida de similaridade em função de um deslocamento de tempo τ . Segundo Nichols (2006), adotando as variáveis aleatórias X e Y como sinais estacionários com probabilidade conjunta dependente apenas do deslocamento τ , tem-se a informação mútua atrasada a qual é definida pela equação (4).

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

Onde *X* e *Y* podem ser definidos como processos estocásticos, sendo *X* = (x_1 , x_2 , ..., x_n) e $Y^{\tau} = (y_{1-\tau}, y_{2-\tau}, ..., y_{n-\tau})$ variáveis aleatórias. $p(x_n)$ e $p(y_{n-\tau})$ são as funções densidade probabilidade marginais de *X* e Y^{τ} , respectivamente, e $p(x_n, y_{n-\tau})$, a pdf conjunta em função do tempo de atraso τ .

A MI detecta as dependências estatísticas lineares e não lineares entre as séries temporais. Já a DMI, busca detectar estas dependências em função de deslocamento de tempo τ . Como neste trabalho são analisados as séries temporais dos sinais das correntes das fases A e B do motor, utiliza-se a informação mútua atrasada para se detectar a medida de associação entre estes sinais, bem como para verificar o atraso ou 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 e/ou curto-circuito entre as espiras do estator.

Após a abordagem dos conceitos relacionados à etapa de extração de características, serão descritos os aspectos gerais associados ao classificadores de padrões utilizados para a identificação de falhas de estator em MITs.

3.2 CLASSIFICAÇÃO DE PADRÕES UTILIZANDO ÁRVORES DE DECISÃO

A árvore de decisão é uma ferramenta de seleção de características. Ela seleciona, por meio de medidas estatísticas, os atributos mais relevantes do conjunto original de dados para a construção do seu modelo classificador. Diante deste fato, tornou-se uma estratégia amplamente aplicada na área de mineração de dados e classificação de falhas em máquinas elétricas (NGUYEN; LEE; KWON, 2008; SUGUMARAN; MURALIDHARAN; RAMACHANDRAN, 2007; SEERA et al., 2012; SEERA et al., 2013; AYDIN; KARAKOSE; AKIN, 2014).

Nguyen, Lee e Kwon (2008) utilizaram a árvore de decisão para coletar as informações relevantes do sinais de vibração de um motor de indução trifásico com o intuito de diagnosticar as falhas mecânicas presentes na máquina. O artigo de Peng e Chiang (2011) propõe um método de detecção de falhas de rolamentos analisando os sinais de vibração do motor. O método proposto utiliza a análise da componente principal, do termo em inglês *Principal Component Analysis* (PCA) para o pré-processamento dos sinais, combinado com ferramentas baseadas em árvores de decisão, *Random Forest* e C4.5, para a classificação das amostras.

Os trabalhos de Seera et al. (2012) e Seera et al. (2013) apresentaram o desenvolvimento de um modelo efetivo e de baixo custo para a detecção e classificação de diversos tipos de falhas presentes nos MITs, como barras quebradas de rotor, curto-circuito no enrolamento do estator e desequilíbrio de tensão. Assim, os autores propuseram utilizar os espectros de frequência das correntes de estator como parâmetros de entrada do classificador. O classificador de padrões adotado é híbrido e composto por uma combinação de uma rede neural *Fuzzy Min-Max* (FMM) e de uma árvore de regressão e classificação, do termo em inglês *Classification and Regression Tree* (CART), o qual é responsável pela indicação da situação de operação do motor.

Recentemente no artigo de Aydin, Karakose e Akin (2014), os autores propõem um novo método para o diagnóstico de falhas de rotor, mais especificadamente de barras e conectores quebrados. Nesta metodologia, extraem-se os padrões de falhas através da reconstrução dos espaços de fase das correntes da máquina pela Transformada *Hilbert*. Para a classificação dos padrões, este trabalho avalia a capacidade de classificação das AD, RNA, Modelos de Mistura Gaussiana e AG.

Tendo em vista a aplicabilidade da árvore de decisão em processos de seleção de características e classificação de padrões, este trabalho utiliza esta ferramenta com o intuito de selecionar os atributos e classificar as condições de operação do motor.

3.2.1 Árvore de Decisão

Segundo Fürnkranz, Gamberger e Lavrac (2012), a árvore de decisão é um modelo de classificador cuja estrutura é constituída de um determinado número de nós e arcos. Seu modelo é composto por uma estrutura no formato de uma árvore, sendo cada nó interno da árvore um determinado teste em uma característica de uma instância, e sendo os arcos, uma representação do resultado do teste realizado. Os nós-folha, isto é, os nós externos da árvore, representam as classes de classificação.

A classificação de uma determinada amostra se dá ao percorrer toda a árvore de decisão, de cima para baixo ("*Top-Down*"), ou seja, do seu nó-raiz, seguindo pelos arcos dos nós até alcançar um nó-folha, onde contém a nova classificação da instância. A Figura 4 ilustra, como exemplo, o processo de classificação de uma árvore de decisão para o problema de haver ou não um jogo de Tênis dependendo do panorama do dia.



Figura 4 – Exemplo de uma árvore de decisão Fonte: Autoria própria

Neste exemplo podem ser notadas algumas situações facilmente compreendidas. Se o dia estiver ensolarado, verifica-se então, qual a taxa de umidade, se ela estiver alta, não haverá jogo de Tênis, já se estiver normal, sim. No caso em que o dia estiver nublado, haverá jogo de Tênis. Agora, se o dia estiver chuvoso e o vento forte, não haverá jogo, já se o vento estiver fraco, sim. Como se pode constatar, a árvore de decisão possibilita a montagem de expressões ou regras que auxiliam na classificação de instâncias nunca vistas. Na seção a seguir, são descritas as características relacionadas ao modelo de árvore de decisão utilizado neste trabalho.

3.2.2 Árvore de Decisão C4.5

No ano de 1993, J. Ross Quinlan desenvolveu o algoritmo da árvore de decisão C4.5, sendo este considerado até hoje como referência para o desenvolvimento de novos algoritmos de classificação (RUGGIERI, 2004).

Nesta árvore de decisão, emprega-se o algoritmo *dividir-e-conquistar*, que trabalha dividindo o conjunto total de dados de treinamento em subconjuntos, de maneira recursiva,

utilizando-se de dados estatísticos como critérios de seleção. Com base no conjunto de dados de treinamento, este algoritmo inicia escolhendo a árvore de decisão mais geral, contendo apenas o nó inicial, designado de nó-raiz. Através deste nó-raiz, refina-se a árvore até que o número máximo possível de instâncias de um subconjunto pertença a uma única classe, surgindo assim os nós-folha, concluindo então a construção da árvore.

Para a escolha dos nós utilizam-se dados estatísticos como critérios de seleção, sendo estes a entropia, o ganho de informação e a taxa de ganho de informação dos atributos de cada amostra presente no subconjunto de treinamento. Estes três critérios devem ser realizados de forma subsequente, minimizando assim, a quantidade de informação necessária para a classificação de uma determinada amostra, e garantindo que uma árvore simplificada seja obtida. Essas medidas são definidas a seguir.

3.2.3 Medidas Estatísticas Utilizadas para a Construção da Árvore de Decisão

A entropia, já descrita na Seção 3.1, é utilizada para o cálculo da incerteza de um determinado subconjunto de dados. Assim, com base na mesma, há a possibilidade de se minimizar a quantidade de informação necessária para a classificação de uma determinada amostra garantindo a obtenção de uma árvore simplificada. A entropia em um conjunto de dados de treinamento T é calculada por meio das equações (5) e (6).

$$H(T) = -\sum_{i=1}^{c} p_i \log_2(p_i)$$
(5)

$$p_i = \frac{C_{i,T}}{T} \tag{6}$$

Onde *c* é o número total de classes, p_i é a probabilidade de uma amostra aleatória *i* pertencer a uma classe C_i , sendo esta probabilidade calculada através da equação (6), e $C_{i,T}$, a quantidade de amostras de *T* que pertencem a C_i . Por meio desta medida é possível realizar o cálculo do Ganho de Informação (GI).

O ganho de informação consiste na redução da quantidade de informação necessária para a classificação de uma determinada amostra com base no atributo que está sendo utilizado para o cálculo. Desta forma, mede-se a efetividade de um atributo em classificar um determinado conjunto de dados obtido pela diferença entre a entropia do conjunto H e a entropia calculada após o particionamento do conjunto de dados de acordo com o atributo selecionado H_c . Esta entropia definida após o particionamento do conjunto é calculada por meio da equação (7).

$$H_{c}(T) = -\sum_{i=1}^{\nu} \frac{T_{i}}{T} H(T_{i}) C_{\nu}$$
(7)

Onde v é a quantidade de valores que um atributo C pode assumir, T_i é o subconjunto de amostras em que C assume um valor C_v , e $H(T_i)$ é a entropia do subconjunto. Calculando a entropia para cada atributo, escolhe-se o menor valor encontrado, pois este, consequentemente, resultará no maior GI, e, portanto, será definido como nó de decisão. A equação (8) descreve como é encontrado o valor de GI.

$$GI(C) = H(T) - H_c(T)$$
(8)

Em geral, uma das limitações encontradas nas árvores de decisão é que estas não trabalham com variáveis contínuas mas apenas com discretas. Entretanto, com o surgimento do algoritmo C4.5 tornou possível a manipulação deste tipo de dados. De modo geral, é produzido uma separação binária do conjunto de amostras do tipo "maior que" ou "menor ou igual que" uma referência.

Para a escolha desta referência, o algoritmo ordena os valores contínuos em ordem crescente. O mesmo utiliza um ponto intermediário entre dois valores diferentes e consecutivos aos valores observados no conjunto total de amostras. Considera-se o valor médio entre dois valores diferentes e consecutivos. Assim, calcula-se o GI para cada uma das possíveis referências, sendo o de maior valor encontrado, escolhido para ser um nó de decisão da árvore.

Embora seja eficiente, esta grandeza possui uma deficiência, pois favorece os atributos que apresentam uma grande quantidade de valores. Tendo isto em vista, Quinlan (1993) desenvolveu duas medidas: Razão de Ganho (RG) e Divisão de Informação (DI).

Estas medidas tem o intuito de reduzir o peso da quantidade de valores como um fator determinante para a escolha do atributo a ser definindo como raiz ou nó da árvore. A DI é definida como sendo a entropia do conjunto de dados T em relação ao atributo C, e seu cálculo é dado pela equação (9).

$$DI(T) = -\sum_{i=1}^{\nu} \frac{T_i}{T} \log_2(\frac{T_i}{T})$$
(9)

Obtendo esta medida, torna-se possível encontrar a RG, tal qual é definida pela equação (10).

$$RG(T) = \frac{GI(C)}{DI(T)}$$
(10)

Quando não há uma alta variância entre os valores de determinado atributo, o valor de DI assume valores próximos de zero, resultando assim em uma RG com valor muito alto. Desta forma, o algoritmo C4.5 utiliza estas duas métricas, DI e RG, apenas em situações onde o valor obtido pelo GI é maior que a média dos ganhos de todos os
atributos, evitando assim, problemas no cálculo da RG.

Para a construção do modelo de árvore decisão baseado no algoritmo C4.5, devese executar todas estas etapas recursivamente até que se torne possível classificar todos dados do conjunto de treinamento.

Porém, após a construção da árvore, deve-se podá-la, pois muitas sub-árvores podem refletir ruídos ou erros, acarretando em um problema conhecido como *overfitting*. Este problema indica que houve um aprendizado muito específico do conjunto de treinamento, não permitindo assim, a generalização do modelo. Nesta parte da construção do modelo, são removidas determinadas sub-árvores, substituindo-as por um nó folha. Neste caso, deve ser atribuída a este nó a classificação mais comum das amostras de treinamento afiliados a ele (HAN; KAMBER; PEI, 2012). O algoritmo C4.5 utiliza a técnica de poda conhecida como "poda posterior", ou também denominada poda "pessimista".

3.2.4 Método de Poda Pessimista

Conforme Witten e Frank (2000), o método de poda pessimista da árvore de decisão baseia-se em uma estimativa de erro calculada. Como o algoritmo C4.5 faz esta estimativa em relação ao conjunto de dados de treinamento, uma correção deve ser adicionada. Isto ocorre porque as estimativas de erro ou precisão calculadas com os dados previamente conhecidos são, geralmente, bem otimistas (HAN; KAMBER; PEI, 2012). Desta forma, a estimativa de erro pessimista é calculada de acordo com a equação (11).

$$p = f + z \cdot \sqrt{\frac{f(1+f)}{N}} \tag{11}$$

Sendo *f* a estimativa de erro calculada baseado nos dados de treinamento; *z* é a dispersão em relação ao fator de confidência utilizado e *N* é o tamanho do conjunto de dados de treinamento. Como valor padrão, adota-se para o algoritmo C4.5, uma taxa de erro de estimativa de 25% e um valor de dispersão de 0,69 (WITTEN; FRANK, 2000).

Encontrada a estimativa de erro pessimista p, o algoritmo C4.5 começa o processo de poda do nível mais baixo da árvore até o nível mais alto, onde esta abordagem é conhecida como *bottom-up*. Em cada sub-árvore, este método verifica se a estimativa de erro calculada é maior que a estimativa de erro se esta sub-árvore fosse simplificada por um nó-folha; ou seja, verifica se a substituição diminui o erro de treinamento. Sendo esta situação verdadeira, a sub-árvore é podada, simplificando-a por um nó-folha.

3.3 CLASSIFICAÇÃO DE PADRÕES UTILIZANDO REDES NEURAIS ARTIFICIAIS

As RNA são modelos matemáticos baseado no sistema nervoso dos seres vivos. Elas são definidas como um conjunto de unidades de processamento, os neurônios artificiais, e possuem a capacidade de manutenção e aquisição de conhecimento a partir de informações. Segundo Silva, Spatti e Flauzino (2010), as características essenciais das RNA estão na adaptação por experiência, capacidade de aprendizado, habilidade de generalização, organização de dados, tolerância a falhas e armazenamento distribuído.

Com base neste neurônio, várias topologias de RNA são construídas utilizando uma ou mais camadas neurais, como por exemplo as RNA do tipo MLP que são utilizadas neste trabalho. A rede MLP é composta ao menos de uma camada neural escondida, encontrada entre a camada de entrada e a camada neural de saída. Nesta topologia de rede, o fluxo de informações na estrutura da rede segue estritamente um caminho, o qual se inicia na camada neural de entrada e percorre, em seguida, as camadas neurais intermediárias a camada de saída, respectivamente. Na Figura 5 é ilustrado uma rede MLP com duas camadas escondidas.



Figura 5 – Exemplo de uma rede neural artificial MLP Fonte: (SILVA; SPATTI; FLAUZINO, 2010)

Esta topologia utiliza o algoritmo *backpropagation*, o qual possui dois estágios: *forward* e *backward*. O primeiro é um estágio supervisionado onde os vetores de entrada de uma amostra do conjunto de treinamento, representados por x_1 , x_2 ,..., x_n , são propagados camada a camada até a produção das suas respectivas saídas, objetivando assim obter as respostas das redes. Vale a pena destacar que nesta etapa do algoritmo de treinamento, são considerados apenas os valores atuais dos pesos sinápticos e dos limiares dos neurônios. Como trata-se de um processo de aprendizagem supervisionado, as respostas produzidas pelas saídas da rede são comparadas com as suas respectivas respostas desejadas. Assim, em função do desvio entre o valor atual e o desejado, no segundo estágio do algoritmo *backpropagation* são ajustados os valores dos pesos sinápticos e dos limiares dos neurônios. Aplicando estes dois estágios sucessivamente, estes valores são alterados automaticamente em cada iteração do processo de treinamento, acarretando assim em uma diminuição gradual da soma dos erros produzidos pelas respostas da rede frente aos seus respectivos valores desejados (SILVA; SPATTI; FLAUZINO, 2010).

O Erro Quadrático (E(k)) e Erro Quadrático Médio (E_M) têm a função de medir o desvio entre as respostas produzidas pela camada neural de saída em relação aos respectivos valores desejados. O Erro Quadrático fornece o desempenho local associado aos resultados produzidos pelos neurônios da camada de saída frente à referida amostra, sendo definido pela equação (12).

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_s} (d_j(k) - Y_j(k))^2$$
(12)

Onde $Y_j(k)$ é o valor produzido pelo *j*-ésimo neurônio de saída da rede considerando-se 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.

Já o Erro Quadrático Médio mede a evolução do desempenho global do algoritmo *backpropagation*, sendo o mesmo calculado pela soma dos erros quadráticos relativos a todos os padrões de entrada utilizados no conjunto de treinamento da rede. Este valor é definido pela equação (13).

$$E_M = \frac{1}{p} \sum_{k=1}^{p} E(k)$$
 (13)

Sendo o parâmetro p o número de padrões de treinamento ou a quantidade de vetores de entrada.

Deste modo, ao executar o algoritmo *backpropagation* durante o processo de treinamento da rede, as matrizes de pesos $W_{ji}^{(1,2,3)}$ da rede são ajustadas a fim de minimizar o Erro Quadrático Médio, E_M . Este processo de ajuste dos pesos pode ser verificado, com mais detalhes, em Silva, Spatti e Flauzino (2010).

A aplicação das RNA em problemas relacionados a área de mineração de dados, reconhecimento de padrões e detecção de falhas elétricas comprovam-se ser adequadas conforme Ghate e Dudul (2010), Ghate e Dudul (2011), Seera et al. (2012), Seera et al.

(2013), Tran et al. (2013), Zarei, Tajeddini e Karimi (2014), Godoy et al. (2015) e Palácios et al. (2015).

3.4 CONCLUSÃO DO CAPÍTULO

Neste capítulo apresentou-se a fundamentação teórica necessária para a compreensão das ferramentas relacionadas ao modelo de reconhecimento de padrões aplicado na identificação de falhas no enrolamento do estator de motores de indução trifásicos. No próximo capítulo serão descritos os aspectos gerais relacionados ao desenvolvimento e implementação deste modelo.

4 MATERIAIS E MÉTODOS

Neste capítulo são abordados os principais métodos utilizados para a criação e validação do modelo de aprendizado de máquina baseado no algoritmo da informação mútua atrasada. Ainda, a árvore de decisão C4.5 e a rede neural artificial do tipo MLP são aplicadas como classificadores de padrões de falhas de estator em MITs com alimentação senoidal. São descritos os aspectos gerais relacionados a todas as fases de implementação, desde a aquisição do banco de dados até o desenvolvimento dos classificadores de acordo com a metodologia proposta para este trabalho. A Figura 6 exibe a estrutura geral de como esta abordagem é desenvolvida. Detalhes acerca do processo de classificação de falhas tratado neste trabalho são discutidos ao longo deste capítulo.



Figura 6 – Estrutura geral da metodologia utilizada no trabalho Fonte: Autoria própria

4.1 BANCO DE DADOS

Nesta seção são tratadas as particularidades relacionadas ao banco de dados utilizado neste trabalho. Parte dos dados utilizados foram coletados no Laboratório de Automação Inteligente de Processos e Sistemas (LAIPS) da Escola de Engenharia de São Carlos (EESC) da Universidade de São Paulo (USP), por meio do Projeto Casadinho/Procad (Processo Nº 552269/2011-5) entre a referida instituição e a Universidade Tecnológica Federal do Paraná (UTFPR), Campus Cornélio Procópio. Já a obtenção da outra parte dos dados experimentais foi realizada no Laboratório de Sistemas Inteligentes (LSI) do Centro Integrado de Pesquisa em Controle e Automação (CIPECA).

Para o presente estudo, utilizou-se a bancada de ensaios proposta originalmente por Goedtel (2007), e utilizada por Gongora et al. (2013), Santos et al. (2014), Broniera (2014), Palácios et al. (2014), Godoy et al. (2015), Palácios et al. (2015), Godoy et al. (2016), Palácios et al. (2016) e Graciola et al. (2016), sendo esta planejada para o monitoramento de medidas elétricas e mecânicas de um motor de indução trifásico tais como tensão, corrente, vibração, torque e velocidade. Ainda, na referida estrutura é possível a simulação de diversas condições de operação como variação na alimentação e variação no conjugado de carga. Tal bancada pode ser visualizada na Figura 7.



Figura 7 – Bancada de Ensaios Experimentais

Em relação ao funcionamento da bancada experimental, a variação na alimentação do motor se dá por meio de variadores de tensão independentes por fase e a imposição de conjugado no eixo do MIT ocorre pelo acoplamento a um gerador de corrente contínua. A bancada também possui um torquímetro de dupla faixa de atuação com sensor de velocidade integrado da marca *Kistler*, o qual é responsável pela leitura dos sinais de torque e velocidade. Os sinais de correntes utilizados neste trabalho são coletados de forma individual por meio de sensores Hall. Estes sensores são responsáveis por condicionar os sinais das correntes que são transferidas às entradas analógicas da placa de aquisição de dados, DAQ USB-6221 da National Instruments, a qual está conectada a um microcomputador. A descrição completa da bancada experimental de ensaios pode ser encontrada em Goedtel (2007).

O banco de dados foi criado de acordo com os ensaios propostos por Broniera (2014), contendo os dados de motores sujeitos a diversas condições de operação, sendo a taxa de amostragem para a aquisição dos sinais fixada em 15,5 kHz. As características básicas construtivas relacionadas aos motores utilizados, bem como suas condições de curto-circuito entre as espiras de estator, podem ser visualizadas na Tabela 2.

Parâmetro	Motor 1	Motor 2	Motor 3
Fabricante	WEG	WEG	WEG
Modelo	Standard	Alto rendimento	Alto rendimento
Potência	0,74 kW	0,74 kW	1,48 kW
Tensão de Alimentação (Δ / Y)	220/380 V	220/380 V	220/380 V
Corrente de Alimentação (Δ/Y)	3,60/2,08 A	3,02/1,75 A	5,98/3,46 A
Número de Fases	3	3	3
Frequência	60	60	60
Número de Polos	4	4	4
Velocidade Nominal	1730 rpm	1730 rpm	1750 rpm
Conjugado Nominal	4,1 N.m	4,1 N.m	8,2 N.m
Fases Rebobinadas	1	3	3
Nível de Curto-Circuito	1, 3, 5 e 10%	1, 3, 5 e 10%	1, 3, 5 e 10%

Tabela 2 –	Parâmetros de	e Es	pecifica	ção	dos	Motores	de	Indug	;ão

Os motores adotados neste trabalho foram acionados diretamente da rede elétrica, estando os mesmos sob diversas condições de serviço, tais como variações no nível de conjugado em seu eixo de 20% a 120% do Torque nominal (T_n) para os Motores 1 e 2 e de 10% a 110% para o Motor 3, no nível de desequilíbrio das tensões de suas fases e também no nível de curto-circuito entre as espiras na fase A. A base de dados experimentais consiste de 2750 ensaios realizados nos motores operando em regime permanente e sob diversas condições de operação, todas estas situações comuns a um ambiente industrial. Para o Motor 1¹ foram coletadas 550 amostras variando o nível de conjugado de

¹O Motor 1 foi rebobinado e utilizado por Suetake (2012) para a criação de um banco de dados de falhas de estator. No referido trabalho o autor analisa as falhas de estator em regime permanente, juntamente com as demais falhas do MIT.

carga de 0,7 N.m a 4,9 N.m em intervalos de 0,2 N.m, e desequilíbrio de tensão na fase A, de 0 a -4%, com intervalos de -2% e na fase B, de 0 a +4%, com intervalos de +2%. Em relação ao Motor 2, foram aquisitadas 1100 amostras também com variação no nível de conjugado de carga de 0,7 N.m a 4,9 N.m em intervalos de 0,2 N.m. Entretanto, foram aplicados desequilíbrios de tensões na fase A entre 0 a -10% e na fase B entre 0 a +8%, com intervalos de -2% e +2%, respectivamente. No caso do Motor 3, foram coletadas 1100 amostras variando o nível de conjugado de carga de 0,9 N.m a 9,3 N.m, em intervalos de 0,4 N.m, e considerando as mesmas condições de desequilíbrio de tensão utilizadas no Motor 2. Assim, para as situações em que os motores estão operando sem defeitos e também com níveis de curto-circuito de 1%, 3%, 5% e 10%, foram aquisitados dados conforme apresentados nas Tabelas 3, 4 e 5.

Tabela 3 – Limites de tensão e torque de carga na aquisição dos dados experimentais para o Motor 1

$%V_a$	$%V_b$	$%V_c$	Torque de Carga (N.m)	Número de Aquisições
100	100	100	0,7-4,9	22
98	100	100	0,7-4,9	22
96	100	100	0,7-4,9	22
100	102	100	0,7-4,9	22
100	104	100	0,7-4,9	22
-				

Tabela 4 – Limites de tensão e torque de carga na aquisição dos dados experimentais para o Motor 2

$%V_a$	$%V_b$	$%V_c$	Torque de Carga (N.m)	Número de Aquisições
100	100	100	0,7-4,9	22
98	100	100	0,7-4,9	22
96	100	100	0,7-4,9	22
94	100	100	0,7-4,9	22
92	100	100	0,7-4,9	22
90	100	100	0,7-4,9	22
100	102	100	0,7-4,9	22
100	104	100	0,7-4,9	22
100	106	100	0,7-4,9	22
100	108	100	0,7-4,9	22
-				

Tabela 5 – Limites de tensão e torque de carga na aquisição dos dados experimentais para o Motor 3

$%V_a$	V_b	V_c	Torque de Carga (N.m)	Número de Aquisições
100	100	100	0,9-9,3	22
98	100	100	0,9-9,3	22
96	100	100	0,9-9,3	22
94	100	100	0,9-9,3	22
92	100	100	0,9-9,3	22
90	100	100	0,9-9,3	22
100	102	100	0,9-9,3	22
100	104	100	0,9-9,3	22
100	106	100	0,9-9,3	22
100	108	100	0,9-9,3	22

A partir destes ensaios, foram armazenadas no banco de dados, variáveis como: torque, velocidade, tensões e correntes. Como na ferramenta de processamento de sinais proposta, emprega-se apenas as correntes das fases A e B, as outras variáveis não serão utilizadas. Após a descrição do banco de dados utilizado neste trabalho, será demonstrada a etapa de processamento destas amostras. Nesta fase são extraídas as características necessárias para uma efetiva identificação de falhas de estator em MITs.

4.2 EXTRAÇÃO DE CARACTERÍSTICAS PELA INFORMAÇÃO MÚTUA ATRASADA

A partir de uma adequada rotina de importação do conjunto de dados descritos nas Tabelas 3, 4 e 5, estes são manipulados e avaliados no software Matlab®. O objetivo desta fase consiste em extrair o máximo de informação presente nos dados e simplificar o número de entradas do sistema de reconhecimento de padrões.

Na Figura 8 é ilustrado o gráfico com 775 pontos dos sinais de correntes das fases A e B. Nesta figura usou-se os sinais do Motor 1 operando sem falhas e com conjugado de carga de 0,7 N.m.



Figura 8 – Sinais de correntes das fases A e B do Motor 1 operando sem falhas e conjugado de carga em seu eixo de 0,7 N.m Fonte: Autoria própria

Uma forma de verificar a medida de associação entre as séries temporais dos sinais das correntes das fases A e B do motor consiste na utilização da versão atrasada da informação mútua, previamente descrita na Seção 3.1. Baseado nos conceitos apresentados no Capítulo 3, foi desenvolvido o algoritmo para o cálculo da DMI. Esse algoritmo trabalha com os sinais das correntes das fases $i_a e i_b$ do motor e com a definição do deslocamento τ . A corrente i_b deve ser deslocada de 1 em 1 amostra até que se atinja o deslocamento em τ pontos. Para cada iteração, calcula-se as PDFs marginais das correntes $i_a e i_b$, a PDF conjunta entre estas duas correntes e, também, o valor da informação mútua. Este valor é armazenado em uma matriz. Estes passos são realizados recursivamente até que se atinja o deslocamento τ . Ao final, encontra-se a informação mútua atrasada. A Figura 9 e o Algoritmo 1² apresentam o fluxograma geral para a obtenção dos valores da DMI e o pseudocódigo do algoritmo desenvolvido, respectivamente.

Procedure 1 Algoritmo para o cálculo da informação mútua atrasada
Input : Deslocamento τ , Corrente i_a , Corrente i_b
Output: Informação Mútua Atrasada
begin
for Corrente i_b deslocada ao passo de 1 até atingir τ do Calcular a PDF marginal da corrente i_a
Calcular a PDF marginal da corrente i_b
Calcular a PDF conjunta entre a corrente i_a e a corrente i_b
Calcular a MI entre a corrente i_a e a corrente i_b
end
Encontrar a DMI entre i_a e i_b
end

Esta medida depende diretamente das funções densidade de probabilidade das correntes em estudo. Estas funções são obtidas sem a utilização de parâmetros de aproximação, isto é, diretamente dos dados a serem analisados usando histogramas, sendo que cada barra relata a ocorrência dos dados em uma faixa de intervalo específica. Assim, não são necessárias funções conhecidas, tais como as gaussianas e estimadores de *Kernel*, para a representação das distribuições de probabilidades.

Para o presente trabalho, foi definido um número fixo de 32 barras, porém, este pode ser variável. Na literatura, encontram-se trabalhos onde são apresentadas técnicas para a otimização do número de barras de acordo com a aplicação (SHIMAZAKI; SHINO-MOTO, 2007).

Na Figura 10 são ilustradas as funções densidade de probabilidade, marginais e conjunta, utilizadas para a determinação da informação mútua do Motor 1.

²Os comandos do algoritmo estão em língua inglesa devido a formatação do LaTeX.



Figura 9 – Fluxograma geral do processo de cálculo da DMI Fonte: Autoria própria

Como a corrente da fase B está defasada em relação a corrente da fase A, temse a necessidade de deslocá-la em função de uma unidade de tempo τ , obtendo então, a medida de similaridade entre os sinais. Assim, neste trabalho são utilizados diferentes valores do deslocamento τ de 150 a 300 pontos, sendo estes valores explicitados com mais detalhes no decorrer desta seção. Na Figura 11 são ilustrados os valores da informação





(a) Função Densidade Probabilidade Marginal - *i*_a

(b) Função Densidade Probabilidade Marginal - *i*_b





Figura 10 – Exemplos das PDFs marginais e conjunta das correntes, *i_a* e *i_b*, para o Motor 1 operando sem falhas, com torque em seu eixo de 0,7 N.m e tensões equilibradas
 Fonte: Autoria própria

mútua para uma faixa de 150 amostras. Verifica-se que o valor da informação mútua será máximo quando os dois sinais de corrente estiverem em fase, indicando uma redução no nível de incerteza associado a corrente i_a devido à informação trazida pelo outro sinal de corrente i_b .

Executando o cálculo da informação mútua, com suas respectivas PDFs, para todas as aquisições pertencentes ao banco de dados utilizado neste trabalho, percebe-se



Figura 11 – Exemplo da informação mútua deslocada em uma faixa de 150 amostras para o caso do Motor 1 operando sem falhas, com conjugado de carga em seu eixo de 0,7 N.m e tensões equilibradas

Fonte: Autoria própria

que cada condição de operação do motor apresenta uma curva característica. Para ilustrar esta afirmação, nas Figuras 12 a 23 são apresentadas as curvas da informação mútua para diversas situações de operação.

Na Figura 12a são exibidas as curvas para o Motor 1 operando sem falhas e sujeito a variações no nível de carga. Percebe-se que o aumento no nível de carga gera um atraso na curva característica da DMI em relação à curva inicial, no qual o MIT opera com conjugado mínimo e sem desequilíbrio de tensões. Deve-se lembrar que T_n é o conjugado nominal da máquina. Ainda, verifica-se que a alteração no desequilíbrio negativo de tensão da fase A ocasiona um atraso e o desequilíbrio positivo de tensão na fase B produz um avanço em relação à curva inicial, como é apresentado na Figura 12b.

Essas duas análises, variação de carga e desequilíbrio entre as tensões, também podem ser visualizadas quando há curto-circuito entre as espiras do estator, não importando qual o nível do mesmo. Assim, na Figura 13 são ilustradas as curvas da DMI em que o Motor 1 está operando com 1% de curto-circuito entre as espiras do estator. Quando esta máquina está sob variações no conjugado de carga nominal, observa-se que o aumento no nível de torque de carga provoca o deslocamento a direita, porém com um valor menor do que no caso em que o Motor 1 operando sem falhas, como ilustrado na Figura 13a.



 (a) Variação no nível de carga - Motor 1 operando sem falhas e com as tensões equilibradas



(b) Variação no nível de desequilíbrio de tensão - Motor 1 operando sem falhas e com carga nominal

Figura 12 – Assinaturas da DMI para o Motor 1 operando sem falhas Fonte: Autoria própria

Na Figura 13b, exibem-se as curvas características quando a máquina está sob desequilíbrios nas tensões de alimentação e curto-circuito de 1% entre as espiras do estator. Verifica-se que a variação na tensão de alimentação da fase A gera um atraso na curva, porém com valor maior do que no nível de desequilíbrio anterior. Entretanto, quando é alterado o desequilíbrio na fase B, 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 curvas da DMI.





 (a) Variação no nível de carga - Motor 1 operando com 1% de curto-circuito na fase A e tensões equilibradas

(b) Variação no nível de desequilíbrio de tensão - Motor 1 operando com 1% de curto-circuito na fase A e carga nominal

Figura 13 – Assinaturas da DMI para o Motor 1 operando com 1% de curto-circuito entre espiras do estator

Fonte: Autoria própria

Na Figura 14 é apresentado o comportamento das assinaturas da DMI para o caso que foram aplicados 3% de curto-circuito entre as espiras no estator do Motor 1, estando a máquina sujeita a variação tanto no conjugado de carga quanto nas tensões de alimentação. A Figura 14a ilustra a situação de variação no conjugado de carga. Assim, com o aumento do nível da carga mecânica, observa-se que há atraso em relação a assinatura em que o motor está operando com 20% do valor de seu conjugado nominal. Além disso, verifica-se que os valores de pico das curvas da DMI são menores do que nos outros casos, quando o Motor 1 está operando sem falhas ou com 1% de curto-circuito entre as espiras do estator.

Na Figura 14b, exibem-se as assinaturas da DMI quando o motor está sujeito a variação no nível de desequilíbrio de tensões. Ao variar a tensão de alimentação da fase A, a curva da DMI atrasa-se em relação a curva onde as tensões estão equilibradas, além de apresentar um valor de pico maior. No caso da variação no nível de desequilíbrio da fase B, verifica-se o avanço em relação a curva em que as tensões do Motor 1 estão equilibradas. Neste caso percebe-se que os picos da DMI não sofrem uma expressiva alteração.



 (a) Variação no nível de carga - Motor 1 operando com 3% de curto-circuito na fase A e tensões equilibradas



(b) Variação no nível de desequilíbrio de tensão - Motor 1 operando com 3% de curto-circuito na fase A e carga nominal

Figura 14 – Assinaturas da DMI para o Motor 1 operando com 3% de curto-circuito entre espiras do estator

Fonte: Autoria própria

As curvas da DMI em que o Motor 1 está operando com 5% de curto-circuito entre as espiras do estator são apresentadas na Figura 15. No caso de um conjugado de carga de até 60% do seu valor nominal, não há alteração significativa nos valores de pico da DMI. Porém, com o aumento do conjugado mecânico, observa-se acentuado deslocamento entre as curvas. Quando é aumentado o nível de torque para 85% de seu valor nominal, além do atraso em relação a curva 0.2^*T_n , observa-se também que o valor de pico da DMI nesta situação tem aumento significativo. Estas verificações são observadas na Figura 15a.

Ao examinar a Figura 15b percebe-se que a alteração no desequilíbrio de tensão da fase A produz um atraso e o desequilíbrio de tensão na fase B acarreta um avanço em relação à curva em que as tensões estão equilibradas. Em baixas variações no nível de desequilíbrios como -2% na fase A e +2% na fase B, nota-se que os valores máximos da DMI quase não se alteram. Entretanto, com o aumento no nível de desequilíbrio, observase um aumento nos valores de pico das assinaturas.



 (a) Variação no nível de carga - Motor 1 operando com 5% de curto-circuito na fase A e tensões equilibradas

(b) Variação no nível de desequilíbrio de tensão - Motor 1 operando com 5% de curto-circuito na fase A e carga nominal

Figura 15 – Assinaturas da DMI para o Motor 1 operando com 5% de curto-circuito entre espiras do estator

Fonte: Autoria própria

Na Figura 16 são apresentadas as curvas para o Motor 1 operando com curtocircuito de 10% entre as espiras do estator. Observa-se um aumento no valor máximo da assinatura da DMI quando o motor está sujeito a 60% do seu valor de torque nominal, como visualiza-se na Figura 16a quando comparado a Figura 15a. Como já citado em outros níveis de curto-circuito, o acréscimo no nível de carga proporciona o atraso na curva da DMI em relação à curva em que o Motor 1 está operando com apenas 20% do seu conjugado nominal.

A análise da Figura 16b permite inferir que a diminuição da tensão da fase A implica no atraso em relação a curva onde as tensões estão equilibradas. Por outro lado, o aumento da tensão na fase B, resulta no avanço em relação a assinatura em que as tensões estão equilibradas e também o aumento nos picos da DMI.

Além destas duas análises, variação de carga e nível de desequilíbrio das tensões, pode-se examinar a variação no nível de curto-circuito entre as espiras do estator,



 (a) Variação no nível de carga - Motor 1 operando com 10% de curto-circuito na fase A e tensões equilibradas

(b) Variação no nível de desequilíbrio de tensão - Motor 1 operando com 10% de curto-circuito na fase A e carga nominal

Figura 16 – Assinaturas da DMI para o Motor 1 operando com 10% de curto-circuito entre espiras do estator

Fonte: Autoria própria

onde na Figura 17 é demonstrada tal situação. Observa-se que a variação no nível de curto-circuito provoca o avanço em relação à curva inicial, no qual o MIT está operando com torque nominal, tensões equilibradas e sem falhas. Além disso, percebe-se também o achatamento na assinatura da DMI com o aumento do nível de curto-circuito entre as espiras do estator.



Figura 17 – Curvas características da DMI com variação do nível de curto-circuito - Motor 1 com carga nominal e tensões equilibradas

Fonte: Autoria própria

Todas as análises realizadas para o Motor 1 também são aplicadas para os outros motores. Verifica-se que o comportamento de avanço ou atraso para diversas situações de operação como variação de carga, desequilíbrio de tensões e curto-circuito, também podem ser observadas no Motor 2 e no Motor 3. As variações de torque no eixo da máquina, desequilíbrio entre as tensões de alimentação e do curto-circuito aplicado nas espiras causam o deslocamento na posição do valor máximo do sinal da DMI.

Assim, o comportamento das curvas características da DMI na situação em que o Motor 2 estiver operando sem falhas é apresentada na Figura 18. Ao analisar a Figura 18a, observa-se novamente que o aumento do torque no eixo da máquina produz o deslocamento à direita no valor máximo da assinatura da DMI. Entretanto, percebe-se que este deslocamento é menor em relação a curva DMI da Figura 12a, além de serem obtidos valores máximos da DMI menores. A Figura 18b demonstra o comportamento de avanço ou atraso das curvas dependendo da fase onde está ocorrendo o desequilíbrio e se este é positivo ou negativo. Porém, nas assinaturas da DMI relacionadas ao Motor 2, é observado um achatamento do pico maior quando há variação mais significativa nos desequilíbrios das tensões de alimentação.



 (a) Variação no nível de carga - Motor 2 operando sem falhas e com as tensões equilibradas



(b) Variação no nível de desequilíbrio de tensão - Motor 2 operando sem falhas e com carga nominal



Na Figura 19 são apresentados as curvas para a situação em que o Motor 2 está operando com um curto-circuito de 10% entre as espiras do estator. Analisando a variação no torque de carga por meio da Figura 19a, verifica-se que esta variação produz um atraso nas assinaturas da DMI em relação a que está operando com apenas 20% do conjugado de carga nominal. Além disso, percebe-se que a partir de um torque de 40% do valor nominal, os valores máximos da DMI são bem próximos. O comportamento das curvas

da DMI para a variação na tensão de alimentação é ilustrado na Figura 19b. Ao variar a tensão de alimentação da fase A, a curva DMI sofre um atraso em relação a curva DMI em que o Motor 2 está operando com as tensões equilibradas. Ainda, observa-se que não há alteração significativa nos valores de pico da DMI. No caso da alteração na tensão da fase B as curvas da DMI avançam além de sofrer um aumento perceptível nos seus valores máximos.



 (a) Variação no nível de carga - Motor 2 operando com 10% de curto-circuito na fase A e tensões equilibradas



(b) Variação no nível de desequilíbrio de tensão - Motor 2 operando com 10% de curto-circuito na fase A e carga nominal

Figura 19 – Assinaturas da DMI para o Motor 2 operando com 10% de curto-circuito entre espiras do estator

Fonte: Autoria própria

A progressão do curto-circuito ocasiona um deslocamento à esquerda nas assinaturas da DMI, além de uma redução no valor de pico, como apresentado na Figura 20. No Motor 2, verifica-se um decaimento menor no valor máximo da DMI, quando comparado ao Motor 1. Entretanto, o comportamento de avanço da curva DMI com a evolução do curto-circuito são observados em ambos os motores.

Em relação ao Motor 3, as assinaturas da DMI quando o motor está operando sem falhas são apresentadas na Figura 21. Observa-se por meio da Figura 21a que ao variar o conjugado de carga, as curvas da DMI tem um pequeno deslocamento. Entretanto, verifica-se que este deslocamento e também a variação nos valores máximos da DMI são menores do que os apresentados nas Figuras 12a e 18a para o Motor 1 e Motor 2, respectivamente. Em relação a variação no desequilíbrio de tensão, é notado por meio da Figura 21b o deslocamento a direita ou a esquerda nas assinaturas da DMI dependente da fase em quem está sendo imposto o desequilíbrio. No entanto, verifica-se o achatamento menor das curvas se forem comparadas com as do Motor 2, as quais foram exibidas na Figura 18b.



Figura 20 – Curvas características da DMI com variação do nível de curto-circuito - Motor 2 com carga nominal e tensões equilibradas

Fonte: Autoria própria



 (a) Variação no nível de carga - Motor 3 operando sem falhas e com as tensões equilibradas

(b) Variação no nível de desequilíbrio de tensão - Motor 3 operando sem falhas e com carga nominal

Figura 21 – Assinaturas da DMI para o Motor 3 operando sem falhas Fonte: Autoria própria

É ilustrado na Figura 22 os comportamentos das variações de conjugado de carga e de desequilíbrio de tensão nas assinaturas da DMI para o Motor 3 operando com um curto-circuito de 10% entre as espiras do estator. Além de se deslocar a direita com o aumento do torque no eixo da máquina, as assinaturas da DMI tem um ligeiro acréscimo em seus valores máximos. Diferente do observado para o Motor 1 e Motor 2, na Figura 22a tem-se o deslocamento mais significativo. Analisando o desequilíbrio das tensões de alimentação por meio da Figura 22b, novamente, verifica-se que a alteração na fase A produz atraso em relação a curva DMI em que o Motor 3 está operando com as tensões equilibradas. Ainda, a variação na fase B gera o avanço em relação a esta mesma assinatura. Contudo, as variações nos valores de pico das curvas são menores do que os apresentados nas Figuras 16b e 19b para o Motor 1 e Motor 2, respectivamente.





 (a) Variação no nível de carga - Motor 3 operando com 10% de curto-circuito na fase A e tensões equilibradas



Figura 22 – Assinaturas da DMI para o Motor 3 operando com 10% de curto-circuito entre espiras do estator

Fonte: Autoria própria

A Figura 23 exibe o comportamento da variação do curto-circuito no Motor 3. Observa-se que a evolução do curto-circuito gera deslocamento a esquerda, além de um achatamento maior nas curvas características da DMI. Vale a pena destacar que na Figura 23 não foi visualizado um deslocamento significativo da curva DMI quando o Motor 3 está operando com 1% de curto-circuito em relação a curva DMI quando este mesmo motor está operando sem falhas. Já nas Figuras 17 e 20 referentes ao Motor 1 e Motor 2, respectivamente, foi possível observar o deslocamento mais evidente quando aplicou-se o curto-circuito de 1% entre as espiras do estator.

Assim, para examinar a precisão e robustez desta técnica de extração de características aplicada na detecção de falhas de curto-circuito entre as espiras do enrolamento do estator, são realizados diversos testes. No primeiro teste, é analisada a dispersão da informação mútua para valores de deslocamento (τ) de 150 e 300 pontos. Na Figura 24 são exemplificadas as assinaturas da DMI para estes dois casos que serão utilizadas como matriz de entrada dos classificadores de padrões quando o Motor 1 está operando sem falhas, com conjugado de carga de 0,7 N.m e com as tensões equilibradas. Na Figura 24a é apresentado a curva da DMI para um deslocamento (τ) de 150 pontos. Já na Figura 24b, ilustra-se a curva DMI para um deslocamento de 300 pontos.



Figura 23 – Curvas características da DMI com variação do nível de curto-circuito - Motor 3 com carga nominal e tensões equilibradas

Fonte: Autoria própria



Figura 24 – Assinaturas da DMI para o Motor 1 operando sem falhas, com torque em seu eixo de 0,7 N.m e tensões equilibradas

Fonte: Autoria própria

No segundo teste é realizada a análise da resolução da informação mútua para diferentes valores como apresentado na Figura 25. São utilizados como dados de entrada do sistema classificador: somente o máximo valor da informação mútua ou este valor e os seus 4, 14, 24, 34 ou 44 valores adjacentes. Na Figura 25a é ilustrada a execução desta análise. Diferentemente dos testes das Figuras 24a e 24b, onde são utilizados como dados de entrada todos os 150 ou 300 pontos das curvas da DMI, na análise da resolução, apresentado pela Figura 25a, é utilizado um número menor de atributos a fim de reduzir a dimensão da matriz de entrada dos classificadores. Ainda, nesta segunda etapa de testes, foi constatado o atraso ou o avanço em relação à curva do motor que está operando em condições sem falhas, com conjugado de carga de 20% do seu valor nominal e com suas tensões equilibradas, conforme ilustrado na Figura 25b. Assim, o deslocamento entre os máximos valores da MI também é usado como dado de entrada do sistema de classificação.



 (a) Exemplo dos valores da matriz de entrada pela análise da resolução da DMI
 Motor 1 operando sem falhas, com torque em seu eixo de 0,7 N.m e tensões equilibradas



(b) Exemplo da análise do deslocamento entre as curvas DMI - Motor 1 operando sem falhas e com 5% de curto-circuito entre espiras do estator, com torque de 0,7 N.m e tensões equilibradas

Figura 25 – Exemplo de uma análise da resolução da informação mútua Fonte: Autoria própria

Após o tratamento dos sinais, normaliza-se todos os valores da DMI entre 0 e 1, para que seja possível realizar os testes de generalização com motores de várias potências. Para cada motor, os dados são normalizados em função do valor máximo da informação mútua (MI_{max}) encontrado para todas as condições de operação, obtendo assim, a matriz de entrada do sistema de classificação de padrões de falhas no estator de MIT.

4.3 CLASSIFICAÇÃO DE PADRÕES POR SISTEMAS INTELIGENTES

De posse da matriz de dados referenciada na Seção 4.2, torna-se possível utilizar a ferramenta de classificação de falhas do estator em MITs baseado tanto em árvores de decisão quanto em redes neurais artificiais. Primeiro é descrito a implementação da AD e num segundo momento, como o modelo da RNA é obtido.

4.3.1 Árvore de Decisão

A construção do modelo de árvore de decisão C4.5 baseou-se nos conceitos descritos no Capítulo 3. A sua escolha ocorreu por ser uma ferramenta robusta e de baixa complexidade de implementação, pois o mesmo é construído baseado em regras.

O algoritmo da árvore de decisão C4.5 trabalha com uma ramificação por vez. No início, é verificado se as amostras pertencem a uma única classe. Caso haja amostras de diferentes classes, necessita-se identificar qual o atributo produz a maior RG, para que este atributo seja definido como o nó-raiz da árvore de decisão. Para cada valor deste atributo escolhido, deve-se verificar se será criado um nó-folha ou se o processo de construção será repetido recursivamente para as demais amostras e atributos. O algoritmo deve ser repetido até que todas as amostras sejam classificadas em nós-folha ou então todos atributos sejam utilizados (RUGGIERI, 2004). O Algoritmo 2 apresenta o pseudocódigo do algoritmo para obtenção do modelo da árvore de decisão C4.5.

Procedure 2 Algoritmo para a obtenção da árvore de decisão C4.5 Input: Amostras, Classe, Atributos

Output: Árvore de decisão baseada nas amostras de treinamento

begin

Crie um nó raiz para a árvore;

if Todas as amostras pertencer a uma mesma classe then Retorne a árvore somente com a raiz, com a única classe dos elementos;

end

if Atributos for uma lista vazia then

Retorne a árvore somente com a raiz, com o valor mais comum da classe no conjunto de amostras;

end

else

 $A \leftarrow$ o atributo da lista de atributos que melhor classifica as amostras de acordo com a RG

Atributo de decisão da raiz $\leftarrow A$;

for cada possível valor, v_i , de A do

Adicione uma nova ramificação abaixo da árvore, correspondente ao teste $A=v_i$; Torne *Amostras*_{v_i}, o subconjunto de amostras que tem o valor, v_i , para A; if $Amostras_{v_i}$ for vazio then

Adicione uma folha com a classe mais comum do atributo base no conjunto de amostras;

end

else

Adicione a sub-árvore (C4.5($Amostras_{v_i}$, Classe, Atributos–A)) na ramificação

end

end

end

end

Após a construção da árvore, torna-se necessário realizar a poda para torná-la mais simplificada. O algoritmo de poda trabalha a partir das folhas até o nó-raiz. Em cada nível da árvore de decisão, deve-se verificar se a taxa de erros da sub-árvore é maior que a taxa de erros da árvore como um todo. Caso isto realmente seja verdadeiro, a subárvore deve ser substituída por um nó-folha. Este processo se repete até que todas as possíveis sub-árvores sejam avaliadas. Assim, encontra-se a árvore de decisão podada, sendo esta mais simplificada e generalista (WITTEN; FRANK, 2000). O algoritmo para realizar esta etapa do processo é apresentado em forma de pseudocódigo no Algoritmo 3. Outra forma de visualização do processo de construção do modelo da árvore de decisão C4.5 é ilustrado na forma de fluxograma na Figura 26.



4.3.2 Rede Neural Artificial

A construção do modelo de RNA do tipo MLP também foi baseada nas definições descritas no Capítulo 3. A escolha desta ferramenta se fundamenta nas características intrínsecas na solução de problemas de detecção de falhas em máquina elétricas (GHATE; DUDUL, 2010; GHATE; DUDUL, 2011; SEERA et al., 2012; SEERA et al., 2013; TRAN et al., 2013; ZAREI; TAJEDDINI; KARIMI, 2014; GODOY et al., 2015; PALÁCIOS et al., 2015; GONGORA et al., 2016; GODOY et al., 2016; PALÁCIOS et al., 2016).

O processo de treinamento da RNA do tipo MLP é realizado mediante o algoritmo *backpropagation*, conhecido também como regra delta generalizada. Este treinamento é composto por duas fases: i) propagação adiante (*forward*) e ii) propagação reversa (*backward*). Na primeira fase é apresentado um padrão à camada de entrada da rede, assim, propaga-se através da rede, camada por camada, até que a resposta seja produzida na camada de saída. Na segunda etapa, a saída obtida é comparada à saída desejada para esse padrão particular. Se não for a correta, o erro calculado é propagado a partir



Figura 26 – Fluxograma geral para a criação da árvore de decisão C4.5 Fonte: Autoria própria

da camada de saída até à camada de entrada para que os pesos das camadas internas sejam gradativamente ajustados em função dos pesos das camadas adiante. O processo é realizado por meio de aplicações sucessivas destas duas fases até que a rede aprenda o padrão de entrada (SILVA; SPATTI; FLAUZINO, 2010). No Algoritmo 4 e na Figura 27 são apresentados o pseudocódigo e o fluxograma do algoritmo para obtenção do modelo da rede neural do tipo MLP de 2 camadas ocultas, respectivamente.

Procedure 4 Algoritmo para o treinamento da RNA do tipo MLP
Input: Matriz de entrada da rede
Output: RNA do tipo MLP treinada
begin
repeat
Apresente a entrada à primeira camada da rede que deve ser propagada em direção
às saídas da rede;
Calcule os sinais de saída dos neurônios da primeira camada oculta e os propague
para a segunda camada oculta;
Calcule os sinais de saída dos neurônios da segunda camada oculta e os envie à
camada de saída;
Calcule os valores de saída da rede;
Calcule o erro entre o valor de saída da rede e o valor desejado;
Calcule o termo de correção dos pesos sinápticos entre a camada de saída e a
segunda camada oculta;
Envie o erro da camada de saída para a segunda camada oculta;
Calcule o erro da segunda camada oculta;
Calcule o termo de correção dos pesos sinápticos entre as duas camadas ocultas;
Calcule o erro da primeira camada oculta;
Calcule o termo de correção dos pesos sinápticos entre a primeira camada oculta
e a entrada;
Atualize os pesos sinápticos de cada camada neural
until o erro quadrático médio entre duas iterações seja menor do que a precisão;

end

Como são realizados diversos testes para os três motores de indução trifásicos, há a necessidade da construção de uma árvore de decisão e uma rede neural artificial para cada situação. Tendo isto em vista, para o presente trabalho foi utilizado o *software Waikato Environment for Knowledge Analysis* (WEKA), que permite a resolução de problemas concretos de mineração de dados e classificação de padrões por meio do conjunto de algoritmos que nele estão disponíveis (HALL et al., 2009).

Após a criação do modelos, tanto da árvore de decisão quanto da rede neural artificial, busca-se avaliar o sistema de classificação proposto. Desta forma, as amostras de validação são apresentadas aos modelos criados. Entretanto, os classificadores estão sujeitas ao problema chamado de *overfitting*, o qual consiste na incapacidade do modelo em generalizar adequadamente as novas amostras de teste devido aos modelos criados serem muito específicos ao conjunto de amostras de treinamento. Uma forma de reduzir este problema é utilizando a técnica de validação cruzada, descrita com mais detalhes na Seção 4.4.

4.4 VALIDAÇÃO CRUZADA

A técnica de validação cruzada avalia a capacidade de generalização do modelo a partir de um conjunto de dados, buscando verificar se o conjunto de dados de treinamento é representativo o suficiente em relação à base de dados na qual se deseja predizer.

O método utilizado neste trabalho foi o de k-partições, onde a base de dados é dividida em k subconjuntos de mesmo tamanho, sendo cada um rotulado com valores de 1 a k. O processo é realizado por k vezes, sendo que em cada iteração, um subconjunto é designado como conjunto de teste e os outros k-1 subconjuntos restantes são 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 esta fase, as amostras de sinais com falhas de estator recebem um rótulo de saída desejada igual a 1, e as amostras de sinais do motor saudável, um rótulo de saída desejada igual a 0.

4.5 CONCLUSÃO DO CAPÍTULO

Neste capítulo apresentaram-se os aspectos gerais relacionados ao desenvolvimento e implementação do modelo de detecção de curto-circuito entre espiras do estator. No capítulo 5, serão apresentados os resultados dos testes exeperimentais no modo *offline* e *online* realizados.



Figura 27 – Fluxograma geral para o treinamento da RNA do tipo MLP Fonte: Autoria própria

5 RESULTADOS E DISCUSSÕES

Neste capítulo são descritos os principais resultados obtidos utilizando o sistema de reconhecimento de padrões baseado em informação mútua atrasada e sistemas inteligentes aplicado em falhas de estator de MITs sujeitos a diversas condições de operação. Primeiramente, são apresentados os resultados experimentais dos testes *offline* utilizando o classificador de padrões baseado em árvores de decisão C4.5. Em seguida, são apresentados os resultados obtidos nos testes *online* para esse mesmo classificador. Os modelos de árvores de decisão C4.5 que atingiram as melhores taxas de classificação nos testes *offline* são utilizados na validação *online*, a fim de comprovar a robustez do sistema de identificação de falhas de estator proposto frente a algumas adversidades encontradas em um ambiente industrial. Ainda, com o intuito de avaliar os padrões da DMI obtidos na etapa de extração de características em um outro classificador de padrões, são realizados testes *offline* e *online* utilizando uma rede neural artificial do tipo MLP.

Uma medida estatística é o coeficiente Kappa (K), sendo este definido como uma medida de associação utilizada para descrever ou testar o grau de concordância, confiabilidade e precisão, na classificação das amostras. Na Tabela 6 são exibidas as diferentes faixas de valores do coeficiente K de acordo com o grau de concordância sugerido pelo trabalho de Landis e Koch (1977).

Valores de Kappa	Concordância de Classificação
<0	Nenhuma
0 - 0,19	Pobre
0,20 - 0,39	Fraca
0,40 - 0,59	Moderada
0,60 - 0,79	Substancial
0,80 - 1,00	Total

Tabela 6 – Caracterização do coeficiente Kappa

Calcula-se este índice por meio dos valores gerados pelo classificador de padrões, conforme a matriz de confusão mostrada na Tabela 7.

		Classe I	Total	
		Normal	Falha	Total
Classe Real	Normal	VN	FP	$L_1 = VN + FP$
	Falha	FN	VP	$L_2 = FN + VP$
Total		$C_1 = VN + FN$	$C_2 = FP + VP$	N

Onde VN é a quantidade de amostras sem falhas classificadas corretamente, VP

é a quantidade de amostras com falhas identificadas corretamente; FP é a quantidade de amostras sem falhas classificadas de forma errada; FN é a quantidade de amostras com falhas identificadas erroneamente e N é o número total de amostras classificadas.

Este coeficiente mede a proporção de concordância observada (P_o) entre as classes de comportamentos existentes (classe real) e calculadas (classe prevista) sobre a base de treinamento após ser removida a proporção de concordância devido ao acaso (P_a). As equações (14), (15) e (16) descrevem como este índice é encontrado.

$$k = \frac{P_o - P_a}{1 - P_a} \tag{14}$$

$$P_o = \frac{VN + VP}{N} \tag{15}$$

$$P_a = \frac{(C_1 \cdot L_1) + (C_2 \cdot L_2)}{N^2} \tag{16}$$

5.1 RESULTADOS - TESTES EXPERIMENTAIS OFFLINE

Nas Seções 5.1.1 e 5.1.2 são apresentados os resultados dos testes offline quando utiliza-se o classificador de padrões baseado em árvores de decisão C4.5. Estes testes são dividos em duas etapas: na primeira, realiza-se a análise da dispersão da informação mútua em função do tamanho do deslocamento τ e, na segunda, a análise da dispersão da informação da informação mútua em função de sua resolução e da distância em relação à curva do MIT operando em condições iniciais.

5.1.1 Resultados da Análise da DMI em Função do Deslocamento τ

Nesta seção são apresentados os resultados obtidos no diagnóstico de falhas de estator utilizando como matriz de entrada a curva de dispersão da informação mútua com 150 e 300 pontos. Conforme citado no Capítulo 4, estes MITs foram sujeitos a diversas condições de operação como variação de seu torque de carga, no nível de desequilíbrio de tensões e no nível de curto-circuito entre as espiras.

Na Figura 28 e na Tabela 8 são apresentados os resultados de classificação do conjunto composto por 550 ensaios experimentais coletados mediante as várias condições de carga do Motor 1. Nos referidos testes são considerados os desequilíbrios entre as tensões das fases A e B conforme descrito no Capítulo 4. Estas amostras, por sua vez, são utilizadas para o treinamento e validação do modelo de árvore de decisão C4.5.

Analisando a Figura 28a, observa-se que a matriz de entrada com 300 pontos



(a) Precisão de classificação em função do número de entradas

(b) Índice Kappa em função do número de entradas

Figura 28 – Resultados experimentais *offline* - Análise da DMI em função do deslocamento - Motor 1 Fonte: Autoria própria

Tabela 8 – Matriz de Confusão - Análi	se da DMI em função do	deslocamento - Motor 1
---------------------------------------	------------------------	------------------------

	Atributos				
	150 300			0	
Classes	Normal	Falha	Normal	Falha	
Normal	91	19	101	9	
Falha	9	431	8	432	

resulta em uma melhor classificação, atingindo 96,91% de acerto em todas as amostras. Já aplicando a matriz de entrada com 150 pontos, o sistema classificador atingiu 94,91% de acerto em todas as amostras.

Em relação à taxa de acerto das amostras sem defeitos, observa-se na Tabela 8 que, quando utiliza-se 300 pontos da curva de dispersão da informação mútua, o classificador atinge 91,82% de acerto, errando apenas 9 das 110 amostras sem defeitos. Entretanto, quando utiliza-se 150 pontos, esta taxa de acerto cai para 82,70%, errando 19 das 110 amostras sem defeitos.

Este dado indica que quando o motor estiver operando sem defeitos, a árvore de decisão criada a partir dos 300 pontos da curva de dispersão da informação mútua causará poucas paradas desnecessárias do sistema de produção. No entanto, com uma entrada de 150 pontos, pode-se ter uma incidência de parada desnecessária maior quando comparado com o primeiro caso.

Na Figura 28b são apresentados os índices K para os testes realizados. Observase que ambos os coeficientes são maiores do que 0,80, indicando uma total concordância com os resultados obtidos, confirmando assim a capacidade do sistema de classificação proposto frente a diversas condições de operação do motor.

Ressalta-se que neste teste, o Motor 1 está sujeito a níveis de desequilíbrio de até 4% entre as tensões das fases A e B. Estas situações são encontradas com frequência em um ambiente industrial e que influenciam diretamente nas curvas de dispersão da informação mútua, como observado no Capítulo 4.

Na Figura 29 e na Tabela 9 são apresentados os resultados obtidos para o Motor 2. Para este motor, foram executados 1100 ensaios experimentais, conforme descrito no Capítulo 4. O motor operou sujeito a diversas condições de operação como variação de 20% a 120% de seu torque de carga nominal, desequilíbrio na tensão de alimentação de até 10% entre as fases A e B, além de variar em até 10% o nível de curto-circuito entre espiras do estator.





(a) Precisão de classificação em função do número de entradas

(b) Índice Kappa em função do número de entradas

Figura 29 – Resultados experimentais *offline* - Análise da DMI em função do deslocamento - Motor 2 Fonte: Autoria própria

|--|

	Atributos				
	150		300		
Classes	Normal	Falha	Normal	Falha	
Normal	149	71	161	59	
Falha	63	817	73	807	

Por meio da Figura 29a é observado que os resultados obtidos tanto para uma matriz de entrada de 150 pontos quanto para uma de 300 pontos apresentam aproximadas taxas de precisão na classificação das amostras em torno de 88%. Os índices K de aproximadamente 0,62 em ambos os casos, demonstram substanciais concordâncias com os resultados obtidos, como apresenta-se na Figura 29b.

Além disso, observa-se na Tabela 9 que em relação as amostras sem defeitos, o sistema proposto classificou erroneamente de 27% a 33% desse tipo de amostra, confundindo-as com as amostras com 1% de curto-circuito entre as espiras de estator. Uma das razões para a queda na acurácia em relação aos resultados do Motor 1, é que nos testes referentes ao Motor 2 foram utilizados níveis de desequilíbrios de tensão de até 10% entre as fases. Essas condições extremas de operação, aliado com a similaridade entre as amostras sem defeitos e com defeitos de 1% de curto-circuito fazem com que a árvore de decisão não diferencie satisfatoriamente estes dois tipos de amostras.

Na Figura 30 e na Tabela 10 são apresentados os resultados para o caso em que o Motor 2 esteve sujeito a curto-circuito entre as espiras de estator maiores ou iguais a 3%, além das condições de torque em seu eixo e desequilíbrio de tensão impostas no teste anterior para esse mesmo motor. Neste caso, foram realizados 880 ensaios experimentais, sendo 220 ensaios com o motor saudável e 660 ensaios com o motor operando com curto-circuito entre as espiras do estator de 3%, 5% e 10%. Na Figura 30 também são apresentados os índices K obtidos nestes testes.









Figura 30 – Resultados experimentais *offline* - Análise da DMI em função do deslocamento - Motor 2 -Curto-circuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

É possível observar o aumento nas taxas de precisão de acerto das amostras sem defeitos e com defeitos, bem como nos coeficientes K, quando comparados com os testes realizados com curto-circuito entre as espiras maior ou igual a 1%, como apresenta-se na Tabela 10 e na Figura 30b, respectivamente. Para este novo teste, o sistema de classificação obteve acurácia em torno de 94% para o conjunto total de amostras, em ambos

	Atributos				
	150		300		
Classes	Normal	Falha	Normal	Falha	
Normal	197	23	196	24	
Falha	26	634	22	638	

Tabela 10 – Matriz de confusão - Análise da DMI em função do deslocamento - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%

os casos. Em relação as amostras sem defeitos, também houve um aumento significativo na taxa de classificação, obtendo assim aproximadamente 89% de precisão. Tendo em vista que o curto-circuito entre as espiras de 3% é um defeito ainda em estágio inicial, sua correta identificação pode levar ao operador a uma melhor tomada de decisão a respeito da manutenção do equipamento.

Na Figura 31 e na Tabela 11 são apresentados os resultados obtidos para o Motor 3. Foram executados 1100 ensaios experimentais, conforme descrito no Capítulo 4, nos quais esse motor esteve sujeito às mesmas condições de operação do Motor 2. Aplicou-se variação de 10% a 110% em seu conjugado de carga nominal, desequilíbrio na tensão de alimentação de até 10% entre as fases A e B e aplicação de curto-circuito entre 1% a 10% das espiras do estator.







(b) Índice Kappa em função do número de entradas

Figura 31 – Resultados experimentais *offline* - Análise da DMI em função do deslocamento - Motor 3 Fonte: Autoria própria

Semelhante ao ocorrido no Motor 2, os resultados para os dois testes realizados no Motor 3, os quais utilizaram-se como entrada uma matriz de 150 e 300 pontos, atingiram equivalentes taxas de acurácia de 87%, como é apresentado na Figura 31a. Os coeficientes K com valores próximos a 0,61 apresentados na Figura 31b demonstram substanciais
	Atributos									
	150 300									
Classes	Normal	Falha	Normal Fall							
Normal	152	68	153	67						
Falha	72	73	807							

Tabela 11 – Matriz de confusão - Análise da DMI em função do deslocamento - Motor 3

concordâncias com os resultados.

Nos resultados apresentados para o Motor 1 verificou-se que, quando são utilizados diferentes valores de entrada, o comportamento do sistema obtém melhores taxas de classificação quando são utilizados 300 pontos. Tanto para o Motor 2 quanto para o Motor 3 não foi possível notar diferenças significativas nos resultados dependendo do número de entradas, pois utilizou-se os mesmos atributos para a construção do modelo da árvore de decisão, em ambos os casos.

Nos testes executados no Motor 3, o sistema identificou de forma errônea 30% das amostras sem defeitos, confundindo-as com as amostras com 1% de curto-circuito entre as espiras do estator. É importante destacar que o Motor 3 operou com até 10% de desequilíbrio de tensão entre as fases enquanto o Motor 1 com apenas 4%. Além disso, a queda pode também ter sido causada pelo fato de que 1% de curto-circuito entre as espiras é uma falha em estágio prematuro, o que dificulta sua correta identificação.

Na Figura 32 e na Tabela 12 são apresentados os resultados para o caso em que o Motor 3 esteve sujeito a curto-circuito entre as espiras de estator maiores ou iguais a 3%. As condições de torque em seu eixo e desequilíbrio de tensão são as mesmas do teste anterior. Foram realizados 880 ensaios experimentais, sendo 220 com o motor saudável e 660 com o motor operando com curto-circuito entre as espiras do estator de 3%, 5% e 10%. Na Figura 32b são apresentados os índices K obtidos nestes testes.

	Atributos										
	150 300										
Classes	Normal	Falha	Normal Falh								
Normal	209	11	210	10							
Falha	9	651	9	651							

Tabela 12 – Matriz de confusão - Análise da DMI em função do deslocamento - Motor 3 - Curto-circuitoentre espiras do estator maior ou igual a 3%

Novamente, observa-se o aumento nas taxas de acurácia global, bem como nos coeficientes K, quando comparados com os testes realizados com curto-circuito entre as espiras maior ou igual a 1%, como pode ser observados nas Figuras 32a e 32b, respectivamente. Neste novo teste, o sistema proposto identifica corretamente 95% das amostras



(a) Precisão de classificação em função do número de entradas

(b) Índice Kappa em função do número de entradas

Figura 32 – Resultados experimentais *offline* - Análise da DMI em função do deslocamento - Motor 3 -Curto-circuito entre espiras do estator maior ou igual a 3% Fonte: Autoria própria

sem defeitos e 98% das amostras com defeitos, totalizando 97% para o conjunto global de amostras, em ambos os casos. Os índices Kappa de 0,94, apresentados na Figura 32b, confirmam a total concordância com os resultados atingidos.

Uma forma de verificar a robustez da técnica de processamento e a classificação dos sinais é por meio dos testes de generalização, nos quais são empregados os conjuntos de dados provenientes de motores de potências variadas. Na etapa de validação, é utilizada uma parte destes dados, os quais devem ser distintos dos adotados na fase de treinamento. Foram utilizadas as amostras do Motor 2 e do Motor 3. O Motor 1 foi emprestado pela USP/São Carlos ao LSI por meio do projeto Casadinho/Procad para a construção do banco de dados de Broniera (2014).

Na Figura 33 e na Tabela 13 são apresentados os resultados dos testes realizados com o Motor 2 e o Motor 3. Estes demonstram que nas amostras sem defeitos os modelos de árvore de decisão construídos não obtiveram resultados satisfatórios de generalização, os quais atingiram acurácias de aproximadamente 70%. Os classificadores de padrões baseados nas árvores de decisão não conseguiram diferenciar de forma satisfatória as amostras sem defeitos e com 1% de curto-circuito entre as espiras de estator. Já em relação às amostras com defeitos, os modelos identificaram corretamente 93% do conjunto destes dados, o que resultou em coeficientes K acima de 0,60, demonstrando substancial concordância com os resultados atingidos.

Na Figura 34 e na Tabela 14 são ilustrados os resultados para o caso em que os Motores 2 e 3 estão sujeitos a curto-circuito entre as espiras do estator maiores ou iguais



(a) Precisão de classificação em função do número de entradas

(b) Índice Kappa em função do número de entradas

Figura 33 – Resultados experimentais *offline* - Análise da DMI em função do deslocamento - Motores 2 e 3

Fonte: Autoria própria

	Atributos										
	150 300										
Classes	Normal	Falha	Normal Falha								
Normal	295	145	318	122							
Falha	119	1641	129	1631							

a 3%. Foram realizados 1760 ensaios experimentais, sendo 440 com os motores sem defeitos e 1320 com os motores operando com curto-circuito entre as espiras de estator de 3% à 10%. Na Figura 34b são exibidos os índices K atingidos nestes testes.

Tabela 14 – Matriz de confusão - Análise da DMI em função do deslocamento - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 3%

	Atributos										
	150 300										
Classes	Normal	Falha	Normal	Falha							
Normal	397	43	396	44							
Falha	25	1295	37	1283							

É possível observar na Figura 34 e na Tabela 14 que foram obtidos resultados de generalização satisfatórios, levando em consideração que utilizam-se motores de potências distintas, um de 1 CV e outro de 2 CV. Nas amostras sem defeitos, os modelos criados atingiram 90% de precisão. Avaliando-se a capacidade de generalização do sistema e levando-se em conta as amostras com defeitos e no global, tanto a curva de dispersão da informação mútua com 150 pontos quanto a de 300 pontos apresentaram desempenhos



(a) Precisão de classificação em função do número de entradas

(b) Índice Kappa em função do número de entradas

Figura 34 – Resultados experimentais *offline* - Análise da DMI em função do deslocamento - Motores 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a 3% Fonte: Autoria própria

em torno de 98% de acerto para as amostras com defeitos e 96% no global.

Analisando do ponto de vista de esforço computacional, neste caso, é mais indicado utilizar a curva de dispersão da informação mútua com 150 pontos. Isso se deve ao fato da mesma exigir um menor tempo para a extração das características e também para a construção do modelo classificador.

Estes resultados validam a técnica de extração de características dos sinais baseada na informação mútua atrasada, demonstrando que, conhecendo o sinal de corrente de uma fase do motor, pode-se verificar o que está ocorrendo na outra fase. Assim, obtémse uma medida de similaridade entre as mesmas para o diagnóstico da situação real da máquina.

Na Seção 5.1.2 são apresentados os testes *offline* realizados pela análise da resolução da curva de dispersão da informação mútua. Nesta subseção é observado o valor do deslocamento entre as curvas medidas em relação a curva de dispersão quando o motor está operando em condições iniciais, ou seja, sem falhas, com conjugado de carga mínimo e tensões equilibradas. Os conjugados mínimos do Motor 2 e Motor 3 são 0,7 N.m e 0,9 N.m, respectivamente.

5.1.2 Resultados da Análise da Resolução da DMI

A análise da resolução da DMI tem o objetivo de verificar se a redução na matriz de entrada dos classificadores terá um reflexo significativo nos resultados de classificação.

Ao reduzir a matriz de entrada de 150 ou 300 pontos para um menor número de entradas, o tempo para a construção dos modelos classificadores de padrões será menor.

Na Figura 35 e na Tabela 15 são apresentados os resultados de classificação do conjunto constituído por 550 ensaios experimentais coletados frente as várias condições de operação do Motor 1 em relação ao número de pontos (1, 5, 15, 25, 35 e 45) da curva DMI, bem como os índices K e a matriz de confusão dos resultados destes testes realizados. Conforme descrito na Seção 5.1.1, para os ensaios desse motor, variou-se o conjugado de carga de 20% a 120% de seu valor nominal, o desequilíbrio de tensão entre as fases A e B foi de no máximo 4% e aplicou-se curto-circuito entre as espiras do estator de 1% à 10%.





(a) Precisão de classificação em função do número de entradas

(b) Índice Kappa em função do número de entradas

Figura 35 – Resultados experimentais *offline* - Análise da resolução da DMI - Motor 1 Fonte: Autoria própria

Tabela 15 – Matriz de Confusão - Análise da resolução da DMI - Motor 1

		Atributos										
	1	1 5			15	5	25		35		45	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	71	39	76	34	96	14	100	10	99	11	99	11
Falha	4	436	5	435	8	432	5	435	12	428	10	430

Analisando a Figura 35 e a Tabela 15, verifica-se a convergência para um número de entradas designado ótimo, onde as taxas de precisão, bem como os coeficientes K atingem os melhores resultados. Este número ótimo é de 25 pontos, onde são classificadas corretamente 90,90% das amostras sem defeitos, 98,90% das amostras com defeitos e 97,27% no global. Ainda, obtém-se o coeficiente K de 0,9133, tal qual representa uma total concordância nos resultados de classificação, como apresentado na Figura 35b. Estes dados retratam o desempenho do sistema de classificação 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 a variação no nível de curto-circuito entre as espiras.

Nesta segunda etapa de testes utilizam-se poucos pontos da curva de dispersão da informação mútua, ou seja, 1, 5, 15, 25, 35 e 45 pontos. O tempo computacional para a construção do modelo classificador é menor do que dos testes realizados anteriormente na Seção 5.1.1. Enquanto que para a análise da resolução da DMI o modelo é construído em 0,20 segundos, na análise em função do deslocamento (τ) é dispendido 1 segundo num computador com processador Intel CoreTM i7 6^a geração e 16 GB de memória RAM.

Na Figura 36 e na Tabela 16 são apresentados os resultados da análise de resolução da DMI para o Motor 2 operando com os mesmos níveis de conjugado no eixo e curto-circuito entre as espiras de estator do Motor 1. Entretanto, neste caso, há a variação no desequilíbrio de tensão entre as fases A e B de até 10%.





(a) Precisão de classificação em função do número de entradas

(b) Índice Kappa em função do número de entradas

Figura 36 – Resultados experimentais *offline* - Análise da resolução da DMI - Motor 2 Fonte: Autoria própria

Tabela 16 – Matriz de confusão -	Análise da resolução	o da DMI - Motor 2
----------------------------------	----------------------	--------------------

	Atributos											
	1 5				15		25		35		45	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	91	129	109	111	134	86	126	94	139	81	138	82
Falha	58	822	57	823	83	797	92	788	75	805	65	815

Por meio da Figura 36a, verifica-se que ao aumentar o número de entradas, o sistema de classificação tende à melhor resposta. As melhores acurácias são obtidas quando utiliza-se como matriz de entrada 45 pontos e o valor do deslocamento entre a

curva atual em relação a de referência. Na curva de referência a máquina está operando sem defeitos, com conjugado de carga de 0,7 N.m e suas tensões estão equilibradas.

Para uma matriz de entrada de 45 pontos, o modelo criado apresentou taxas de classificação corretas de 62,73% para as amostras sem defeitos, 92,61% para as amostras com defeitos e 86,64% para as amostras globais. Na Figura 36b é apresentado o índice K de 0,5699 para este número de entradas, tal qual indica uma moderada concordância com os resultados de classificação obtidos. Além disso, observa-se na Tabela 16 que independente do número de entradas utilizado, o sistema de classificação não foi capaz de identificar boa parte das amostras sem defeitos, pois classificou-as equivocadamente como amostras de 1% de curto-circuito entre as espiras de estator.

Sabe-se que o curto-circuito de 1% entre as espiras do estator é um defeito incipiente da máquina o que leva o sistema de diagnóstico a detectar de forma equivocada esse tipo de amostra com os dados da máquina operando sem defeitos. A Figura 37 e a Tabela 17 apresentam o comportamento da metodologia quando o Motor 2 opera em condições de desequilíbrio de tensão e conjugado de carga semelhantes ao teste anterior. Entretanto, neste caso tem-se curto-circuito entre as espiras do estator de 3% a 10%.





(a) Precisão de classificação em função do número de entradas



Figura 37 – Resultados experimentais *offline* - Análise da resolução da DMI - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

Ao analisar a Figura 37 e a Tabela 17 verifica-se que quando não são apresentadas ao classificador as amostras com 1% de curto-circuito entre as espiras do estator, o modelo construído faz uma melhor separação entre as classes, atingindo assim uma precisão superior ao do teste em que foram utilizados este tipo de dados.

Na Figura 37 e na Tabela 17, observa-se também que há uma tendência para um

		Atributos										
	1		5		15	5	25		35		45	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	141	79	186	34	183	37	194	26	191	29	186	34
Falha	28	632	31	629	22	638	13	647	18	642	20	640

Tabela 17 – Matriz de confusão - Análise da resolução da DMI - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%

número de entradas que atingem os melhores resultados. Como no caso do Motor 1, o número ótimo é de 25 pontos. Para este número de entradas são classificadas corretamente 88,18% das amostras sem defeitos, 98,03% das amostras com defeitos e 95,57% de todas as amostras. Ainda obtém-se um índice K de 0,8794 representando uma forte concordância nos resultados de classificação, conforme apresentado na Figura 37b. Estes resultados demonstram o satisfatório desempenho do sistema de classificação.

Na Figura 38 e na Tabela 18 são apresentados os resultados para o Motor 3, tal qual esteve operando com as mesmas adversidades do Motor 2. Foram realizados 1100 ensaios experimentais, sendo 220 ensaios do motor sem defeitos e 880 ensaios com defeitos, conforme relatado no Capítulo 4. Houve variação no conjugado de 10% a 110% do seu valor nominal, desequilíbrios de tensão entre as fases de até 10% e curto-circuito entre as espiras do estator de 1%, 3%, 5% e 10%.









Figura 38 – Resultados experimentais *offline* - Análise da resolução da DMI - Motor 3 Fonte: Autoria própria

Novamente, o aumento do número de entradas melhora a resposta da árvore de decisão. Conforme pode ser observado na Figura 38a, quando utilizam-se as matrizes de entrada de 25 e 45 pontos, os modelos criados apresentaram as melhores taxas de classificação, 87,27% e 87,82% de acerto das amostras globais, respectivamente. Tendo

		Atributos											
	1 5				15		25		35		45		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	57	163	98	122	152	68	143	77	148	72	147	73	
Falha	47	833	89	791	121	759	63	817	80	800	61	819	

Tabela 18 – Matriz de confusão - Análise da resolução da DMI - Motor 3

em vista que essas acurácias possuem valores bem próximos, o sistema de diagnóstico mais indicado para este Motor 3 consiste na utilização da matriz de entrada de 25 pontos, pois o mesmo dispende de um esforço computacional menor, quando comparado com uma matriz de entrada de 45 pontos.

Quando utiliza-se todo o conjunto de dados disponível para o Motor 3, o sistema de identificação apresenta taxas de classificação entre 26% à 69% para as amostras sem defeitos. Isto ocorre pois as amostras sem defeitos tem características similares à uma amostra com 1% de curto-circuito entre as espiras do estator, como demonstrado pela Tabela 18. Assim como realizado para o Motor 2, investiga-se o comportamento do sistema quando são aplicados no Motor 3 curto-circuitos entre as espiras de 3%, 5% ou 10%.

Na Figura 39 e na Tabela 19 são exibidos os resultados dos testes em que aplicouse no Motor 3 o curto-circuito entre as espiras do estator maior ou igual a 3%. Nota-se, novamente, que as taxas de acerto das amostras globais aumentaram independente do número de entradas utilizadas. As árvores de decisão, para esta situação, diferenciam as classes sem defeitos e com defeitos. Os melhores resultados são atingidos com 25 e 45 pontos, sendo alcançadas acurácias de 96,02% e 96,25%, respectivamente, como ilustrase na Figura 39a. A Figura 39b exibe os coeficientes Kappa de 0,8931 para 25 pontos e 0,8992 para 45 pontos, os quais representam a total concordância com os resultados de classificação. Como os resultados são similares, é mais adequado a utilização da árvore de decisão criada a partir de uma matriz de entrada de 25 pontos, pois o seu tempo computacional para a construção do modelo é menor do que para uma matriz de 45 pontos.

Tabela 19 – Matriz de confusão - Análise da resolução da DMI - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%

		Atributos										
	1		5		15	5	25		35		45	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	94	126	185	35	197	23	200	20	200	20	201	19
Falha	9	651	29	631	22	638	15	645	17	643	14	646

Tendo como objetivo verificar a robustez desta metodologia proposta, os testes de generalização descritos na Seção 5.1.1 são realizados para a análise da resolução da DMI. Na Figura 40 e na Tabela 20 são apresentados os resultados de classificação do curto-circuito entre as espiras do estator de 1%, 3%, 5% e 10%.



(a) Precisão de classificação em função do número de entradas



15

25

Número de Pontos

35

45

0.8777 0,8931 0,8874 0,8992



Fonte: Autoria própria





(a) Precisão de classificação em função do número de entradas



Figura 40 – Resultados experimentais *offline* - Análise da resolução da DMI - Motores 2 e 3 Fonte: Autoria própria

		Atributos											
	1 5				15		25		35		45		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	73	367	172	268	288	152	270	170	298	142	301	139	
Falha	67	1693	119	1641	141	1619	157	1603	117	1643	115	1645	

Tabela 20 - Matriz de Confusão - Análise da resolução da DMI - Motores 2 e 3

Como observado na Figura 40a, os melhores resultados encontrados utilizam entradas de 35 e 45 pontos. Em ambos os casos, as taxas de acurácias das amostras globais atingem, aproximadamente 88%. Entretanto, destaca-se que os modelos criados a partir do conjunto total de dados não são capazes de separar eficientemente as amostras sem defeitos com as de 1% de curto-circuito entre as espiras do estator, como apresentado na Tabela 20.

Assim, na Figura 41 e na Tabela 21 são descritos os resultados para os testes de generalização para o caso em que os motores operam sujeito a conjugados de cargas de 10% a 120% dos seus valores nominais, variação no nível de desequilíbrio de tensão na fase A de até 10% e na fase B de até 8% e curto-circuitos de 3%, 5% e 10% entre as espiras do estator.





(a) Precisão de classificação em função do número de entradas

(b) Índice Kappa em função do número de entradas

Figura 41 – Resultados experimentais *offline* - Análise da resolução da DMI - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

Tabela 21 – Matriz de Confusão - Análise da	resolução da DMI - Motores 2 e 3 - Curto-circuito entre
espiras do estator maior ou igual	l a 3%

	Atributos											
	1	1 5		15		25		35		45		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	273	167	352	88	395	45	397	43	400	40	393	47
Falha	79	1241	60	1260	58	1262	60	1260	53	1267	58	1262

As Figuras 41a e 41b revelam que, quando utiliza-se na matriz de entrada um número igual ou maior do que 15 pontos, os modelos criados atingem acurácias de classificação maiores do que 94% e coeficientes K acima de 0,84. Estes índices K demonstram uma perfeita concordância com os resultados obtidos. O número de entradas ótimo para este teste de generalização é de 35 pontos, onde são alcançadas taxas de precisão de 94,72% para as amostras globais, 90,91% para as amostras sem defeitos e 95,98% para as amostras defeituosas. Porém, se forem analisadas as questões do custo computacional para contrução do modelo e do tamanho da árvore de decisão criada, o número adequado de entradas é de 25 pontos. O mesmo apresenta satisfatório desempenho de classificação, com um esforço computacional e um modelo criado com um menor número de regras, quando é comparado com os outros casos.

Os principais resultados obtidos nos testes *offline* são empregados na validação *online*. Neste caso, o sistema de diagnóstico apresenta um desempenho superior, tanto nas taxas de classificação quanto no aspecto do esforço computacional, quando utiliza-se a matriz de entrada 25 pontos, para todos os motores. Assim, na Seção 5.2 são apresentados os resultados alcançados nos ensaios experimentais realizados de forma *online*.

5.2 RESULTADOS - TESTES EXPERIMENTAIS ONLINE

Nesta Seção são apresentados os resultados experimentais para o caso em que as máquinas, descritas no Capítulo 4, estão sujeitas aos testes *online*. Foram incluídos no algoritmo de validação, implementado no ambiente do Matlab®, os modelos de árvores de decisão que alcançaram as melhores acurácias de classificação.

Conforme tratado na Seção 5.1, as árvores de decisão empregadas no algoritmo de validação foram as que utilizaram na matriz de entrada 25 pontos da curva característica da DMI. A validação destes testes foi realizada por meio de ensaios experimentais no laboratório, nos quais foram apresentadas sinais de corrente dos motores com desequilíbrio entre as tensões de alimentação e variação de carga mecânica acoplada ao eixo da máquina. Ao executar cada ensaio experimental proposto para esta etapa, a estratégia indica na tela do microcomputador a presença ou não da falha de curto-circuito entre as espiras de estator.

O classificador baseado em árvores de decisão não é capaz de fazer a classificação satisfatória entre as classes sem defeitos e com 1% de curto-circuito entre as espiras do estator. Assim, nesta seção, são aplicados níveis de curto-circuito maiores ou iguais a 3%. No entanto, é importante destacar que esse nível de curto-circuito ainda pode ser considerado um problema incipiente da máquina. Assim, sua correta identificação pode colaborar na redução das perdas nos processos, do tempo fora de serviço e da quebra do equipamento, além de garantir uma operação confiável e consistente dos sistemas industriais.

Para a validação do sistema utilizando os sinais de corrente do Motor 2, considera-

se a variação de carga mecânica acoplada ao eixo do motor de indução de até 4,5 N.m. Esta carga mecânica foi variada em passos de 0,5 N.m compreendendo valores de 2,5 N.m a 4,5 N.m. Este processo foi repetido para cada percentual de desequilíbrio entre as tensões de alimentação no momento dos ensaios, os quais variam de 0,5% a 10% em uma das fases. Já os níveis de curto-circuito aplicados a esse motor foram de 3%, 5%, 10%, 15% e 20% entre as espiras da fase A. Na Tabela 22 são exibidos os limites de tensão e conjugado de carga utilizados para cada situação de operação do Motor 2, seja sem defeitos e também com 3%, 5%, 10%, 15% e 20% de curto-circuito entre as espiras do estator.

V_a	V_b	$%V_c$	Torque de Carga (N.m)	Número de Aquisições
100	100	100	2,5-4,5	5
98	100	100	2,5-4,5	5
96	100	100	2,5-4,5	5
94	100	100	2,5-4,5	5
92	100	100	2,5-4,5	5
90	100	100	2,5-4,5	5
100	102	100	2,5-4,5	5
100	104	100	2,5-4,5	5
100	106	100	2,5-4,5	5
100	108	100	2,5-4,5	5

Tabela 22 – Limites de tensão e torque de carga nos testes online para o Motor 2

Na Figura 42 e a Tabela 23 são apresentados os resultados do teste realizado. Na Figura 42a, verifica-se que, quando o motor está operando em situações de desequilíbrio máximo de 0,5%, o sistema de diagnóstico é capaz de identificar corretamente todas as amostras apresentadas ao mesmo. Quando aumenta-se o nível de desequilíbrio em até 10%, observam-se quedas nas acurácias das amostras sem defeitos e com defeitos, resultando em um percentual de classificação total de 95,33%. É importante destacar que o sistema identificou incorretamente apenas 1 amostra com curto-circuito entre as espiras de 5%, estando a máquina sujeita a um desequilíbrio de 8% entre as suas tensões de alimentação, que é considerada uma situação extremamente adversa de operação, como é demonstrado na Tabela 23. Este dado demonstra o satisfatório desempenho do sistema de monitoramento de falhas, pois quando houver a evolução da severidade de curto-circuito, o sistema será capaz de identificar o defeito presente na máquina. Além disso, na Figura 42b são apresentados os valores dos coeficientes K. No pior caso, onde há desequilíbrio de até 10% entre as tensões, tem-se K de 0,8320 o qual confirma a perfeita concordância com os resultados de classificação obtidos.

Na validação do sistema utilizando os valores de corrente aquisitados do Motor 3, foram consideradas as variações da carga mecânica acoplada ao eixo do motor de indução de até 9 N.m. A carga mecânica foi variada em passos de 1 N.m compreendendo valores de 5 N.m à 9 N.m. Os percentuais de desequilíbrios entre as tensões de alimentação e os



(a) Precisão de classificação em função do nível de deseguilíbrio

<= 4%

Nível de Desequilíbrio

<= 2%

(b) Índice Kappa em função do nível de deseguilíbrio

<= 4%

Nível de Desequilíbrio

<= 6%

<= 10%

<= 2%

Figura 42 - Resultados experimentais online - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%

0,4

0,2

0

<= 0,5%

Fonte: Autoria própria

100

80

60

40

20

0

<= 0,5%

Precisão de Classificação (%)

100,00

97.78

98,00

97,14

<=6%

95,33

<= 10%

Tabela 23 – Matriz de Confusão - Testes online - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%

	Nível de Desequilíbrio										
	\leq 0,	$\leq 0.5\%$ $\leq 2.0\%$ $\leq 4.0\%$					≤ 6,0%		≤ 10,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	5	0	15	0	25	0	33	2	43	7	
Falha	0	25	2	73	3	122	4	171	7	243	

níveis de curto-circuito entre as espiras do estator são os mesmos aplicados para o Motor Os limites de tensão e conjugado de carga utilizados para cada situação de operação do Motor 3, seja sem defeitos e também com 3%, 5%, 10%, 15% e 20% de curto-circuito entre as espiras do estator são apresentados na Tabela 24.

$%V_a$	V_b	$%V_c$	Torque de Carga (N.m)	Número de Aquisições
100	100	100	5,0-9,0	5
98	100	100	5,0-9,0	5
96	100	100	5,0-9,0	5
94	100	100	5,0-9,0	5
92	100	100	5,0-9,0	5
90	100	100	5,0-9,0	5
100	102	100	5,0-9,0	5
100	104	100	5,0-9,0	5
100	106	100	5,0-9,0	5
100	108	100	5,0-9,0	5

Tabela 24 - Limites de tensão e torque de carga nos testes online para o Motor 3

Na Figura 43 e na Tabela 25 são exibidos os resultados referente ao Motor 3. Na referida figura, com o desequilíbrio entre as tensões de alimentação de até 2%, o sistema de monitoramento identifica corretamente todas as amostras. Além disso, por meio da Tabela 25, verifica-se que mesmo com o desequilíbrio de até 10%, o sistema demonstra acurácias de 96,00% e 97,20% para as amostras sem defeitos e com defeitos, respectivamente. Com a progressão do curto-circuito, o sistema identificará a presença do defeito, pois com um curto-circuito igual ou maior do que 5% entre as espiras do estator, o algoritmo de validação implementado conseguiu classificar corretamente todas as amostras, não importando o nível de desequilíbrio de tensão na alimentação do motor.





(a) Precisão de classificação em função do nível de desequilíbrio



Figura 43 – Resultados experimentais *online* - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

Tabela 25 – Matriz de Confusão - Testes *online* - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%

	Nível de Deseguilíbria									
	Nivel de Desequilibrio									
	\leq 0,	5%	≤ 2,	0%	\leq 4,0%		$\leq 6,0\%$		\leq 10,0%	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	5	0	15	0	25	0	34	1	48	2
Falha	0	25	0	75	2	123	3	172	7	243

Na Figura 44 e na Tabela 26 são apresentados os resultados obtidos na validação online para o modelo criado a partir do conjunto de motores de potências variadas. O Motor 2 e o Motor 3 foram submetidos às mesmas condições impostas nos testes anteriores. Para o Motor 2 variou-se seu conjugado de carga de 2,5 N.m a 4,5 N.m, ao passo de 0,5 N.m e para o Motor 3 seu conjugado foi alterado de 5 N.m a 9 N.m, ao passo de 1 N.m. O desequilíbrio entre as tensões de alimentação e o nível de curto-circuito na fase A são semelhantes aos dos testes individuais; a saber: variação no desequilíbrio nas tensões de alimentação até 10% e curto-circuito entre as espiras do estator aplicado de 3% a 20%.

Nestas validações observou-se que o aumento do nível de desequilíbrio entre as tensões de alimentação implica no decréscimo da acurácia de classificação global, como



(a) Precisão de classificação em função do nível de desequilíbrio

(b) Índice Kappa em função do nível de desequilíbrio

Figura 44 – Resultados experimentais *online* - Motores 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

Tabela 26 – Matriz de Confusão - Testes *online* - Motores 2 e 3 - Curto-circuito entre espiras do estator maior ou igual a 3%

Nível de Desequilíbrio											
								<u>≤</u> 10	,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	9	1	26	4	42	8	57	13	85	15	
Falha	0	50	0	150	0	250	1	349	2	498	

ocorreu nos testes *online* individuais. Como apresentado na Figura 44a, no pior cenário de desequilíbrio entre as tensões de alimentação, a metodologia de diagnóstico proposta atingiu uma taxa de classificação global de 97,17%. É importante destacar que em relação às amostras com defeitos e sem defeitos, o sistema conseguiu identificar corretamente 99,60% e 85,00% destes tipos de amostras, respectivamente, mesmo utilizando motores de diferentes potências, como pode ser visualizado na Tabela 26. Isso demonstra o satis-fatório desempenho do sistema de diagnóstico de falhas de estator frente as adversidades que as máquinas podem estar sujeitas, tais como curto-circuito entre as espiras ainda em estágio inicial, desequilíbrio entre as tensões de alimentação de até 10% e uma sobrecarga de até 20% do conjugado mecânico no eixo. O índice K de 0,8924 exibido na Figura 44b indica uma perfeita concordância com os resultados obtidos.

Conforme descrito no Capítulo 3, bem como pelos estudos desenvolvidos neste trabalho pode-se dizer que a árvore de decisão é uma ferramenta de relativa facilidade de implementação e com baixo custo computacional, pois é construída baseada em regras. Porém, quando utiliza-se um conjunto de dados com características similares, como no caso das amostras sem defeitos e com 1% de curto-circuito entre as espiras do estator, o classificador apresenta dificuldade de fazer a separação entre as classes.

Assim, os padrões da DMI obtidos na etapa de extração de características são empregados em uma rede neural artificial MLP. Nos testes, *offline* e *online*, utiliza-se a matriz de entrada com 25 pontos, devido ao satisfatório desempenho nos testes anteriores com o classificador baseado em árvores de decisão.

5.3 COMPORTAMENTO DOS PADRÕES DA DMI EM UM CLASSIFICADOR BASEADO EM RNA

Nesta seção, os padrões da DMI que obtiveram os melhores resultados de classificação nas Seções 5.1 e 5.2 são utilizados como matriz de entrada desta RNA do tipo MLP. Desta forma, pode-se avaliar o comportamento destes padrões extraídos na etapa de extração de características. Utiliza-se a RNA devido a sua eficiência na solução de problemas de classificação de padrões (GHATE; DUDUL, 2010; GHATE; DUDUL, 2011; SEERA et al., 2012; SEERA et al., 2013; TRAN et al., 2013; ZAREI; TAJEDDINI; KARIMI, 2014; GODOY et al., 2015; PALÁCIOS et al., 2015; GONGORA et al., 2016; GODOY et al., 2016; PALÁCIOS et al., 2016; PALÁCIOS et al., 2016).

Na construção da RNA do tipo MLP utilizada neste trabalho, a taxa de aprendizagem foi definida como 0,30, o termo *momentum* recebeu 0,20, e o número máximo de épocas para o treinamento foi 500. Doze e três neurônios (empiricalmente definidos) estão na primeira e segunda camada escondida, respectivamente. Para as camadas escondidas são utilizadas a função de ativação logística e para a camada de saída a função de ativação linear é utilizada.

Os resultados experimentais dos testes *offline* e *online* são apresentados nas Seções 5.3.1 e 5.3.2, respectivamente.

5.3.1 Testes Experimentais Offline Utilizando a Rede Neural MLP

Nesta Seção são apresentados os resultados experimentais dos testes *offline* para o sistema de diagnóstico de falhas de estator baseado em medidas de informação e RNA. Na Figura 45 e na Tabela 27 são apresentados os resultados de classificação do conjunto constituído por 1100 ensaios experimentais realizados com o Motor 2. Neste conjunto de dados tem-se a variação do conjugado de carga de 20% a 120% de seu valor nominal, o desequilíbrio de tensão entre as fases A e B em até 10% e níveis de curto-circuito entre as espiras do estator de 1%, 3%, 5% e 10%.

Ao utilizar a RNA do tipo MLP como classificadora dos padrões da DMI, observase o aumento na acurácia de classificação das amostras do Motor 2 quando utiliza-se as amostras de 1% também na construção do modelo classificador. O sistema apresenta



(a) Precisão de classificação em função do nível de desequilíbrio

(b) Índice Kappa em função do nível de desequilíbrio

Figura 45 – Resultados experimentais *offline* utilizando a rede neural MLP - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 1%

Fonte: Autoria própria

Tabela 27 – Matriz de Confusão - Testes *offline* utilizando a rede neural MLP - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 1%

	Nível de Desequilíbrio										
	\leq 0,	≤ 0,5% ≤ 2,0%				\leq 4,0%		0%	≤ 10,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	21	1	62	4	88	22	126	28	153	67	
Falha	2	86	9	255	18	422	28	588	62	818	

satisfatório desempenho mesmo frente à críticas condições de operação como um desequilíbrio entre as tensões de alimentação de até 6%. Neste caso, obtém-se acurácias de classificação de 92,73% para o conjunto total de amostras, 81,82% e 95,45% para as amostras sem defeitos e com defeitos, respectivamente. O índice K de 0,7727 também confirma a substancial concordância com os resultados alcançados, como apresentado na Figura 45b.

No entanto, quando utiliza-se o classificador MLP, o custo computacional é superior quando comparado à árvore de decisão C4.5. Enquanto na árvore de decisão C4.5 o modelo é construído em torno de 0,20 segundos, o classificador baseado na rede MLP é ajustado em torno de 5 segundos para o mesmo *hardware*.

Por meio da Tabela 27, verifica-se que, mesmo utilizando a RNA do tipo MLP, o sistema ainda classifica erroneamente 30% das amostras sem defeitos quando esse motor está operando com até 10% de desequilíbrio entre as suas tensões. Como relatado anteriormente, o curto-circuito de 1% entre as espiras do estator é um defeito em estágio inicial, que induz 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.

Novos testes são executados a fim de avaliar o comportamento da metodologia quando o Motor 2 estiver sujeito a semelhantes condições de desequilíbrio de tensão e conjugado de carga, porém com curto-circuito entre as espiras do estator de 3% à 10%.

Na Figura 46 e na Tabela 28 são apresentadas os referidos testes. Observase o elevado crescimento nas amostras sem defeitos, mesmo quando a máquina está operando com uma desequilíbrio de até 10%. Neste caso, o sistema atingiu acurácias de 97,50%, 95,91% e 98,03%, para o conjunto total de amostras, amostras sem defeitos e com defeitos, respectivamente. Além disso, um outro dado importante que deve ser destacado é o coeficiente Kappa. Nesta situação o índice atingiu um valor de 0,9337, indicando total concordância com os resultados obtidos, conforme é apresentado na Figura 46b. Neste novo teste, verifica-se que quando não se utilizam as amostras com 1%, o sistema é capaz de executar a melhor separação entre as classes. Também é importante ressaltar que utilizou-se as amostras com 3% de curto-circuito entre as espiras no enrolamento do estator, que é considerada um problema incipiente da máquina. Verifica-se também que o tempo computacional para a construção do modelo é de 3,97 segundos para o último caso.











Na Figura 47 e na Tabela 29 são exibidos os resultados para o Motor 3, tal qual esteve sujeito às mesmas adversidades do Motor 2; a saber: semelhantes níveis de torque de carga, desequilíbrio de tensão e curto-circuito entre as espiras do estator. Foram realizados 1100 ensaios experimentais, sendo 220 ensaios do motor sem defeitos e 880 ensaios com

Tabela 28 -	- Matriz de Confusao -	lestes offline utilizando	a rede neural MLP	- Motor 2 -	Curto-circuito
	entre espiras do esta	tor maior ou igual a 3%			

	Nível de Desequilíbrio									
	\leq 0,5%		≤ 2,0%		\leq 4,0%		\leq 6,0%		\leq 10,0%	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	22	0	66	0	107	3	149	5	211	9
Falha	0	66	0	198	6	324	8	454	13	647

defeitos, conforme descrito no Capítulo 4. Foram aplicadas nestas aquisições variações no conjugado de 10% a 110% do seu valor nominal, desequilíbrios de tensão entre as fases de até 10% e curto-circuito entre as espiras do estator de 1%, 3%, 5% e 10%.









Figura 47 – Resultados experimentais *offline* utilizando a rede neural MLP - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 1%

Fonte: Autoria própria

Tabela 29 – Matriz de Confusão - Testes *offline* utilizando a rede neural MLP - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 1%

	Nível de Desequilíbrio										
	\leq 0,5%		\leq 2,0%		\leq 4,0%		\leq 6,0%		≤ 10,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	20	2	63	3	100	10	141	13	191	29	
Falha	0	88	1	263	10	430	10	606	33	847	

Por meio da Figura 47 e da Tabela 29, observa-se o desempenho do sistema quando são apresentadas as amostras do Motor 3. Mesmo utilizando as amostras com 1% de curto-circuito e diante de extremas condições de operação, a metodologia proposta identificou corretamente 94,36% do conjunto total de amostras, como é apresentado na Figura 47a. Em relação às amostras sem defeitos e com defeitos, foram atingidas taxas de acerto de 86,82% e 96,25%, respectivamente. O índice Kappa de 0,8251 exibido na Figura 47b confirma a perfeita concordância com os resultados obtidos. Entretanto, observa-se

que o tempo para a construção do modelo classificador, baseado na RNA do tipo MLP, é relativamente maior do que para as árvores de decisão. Enquanto que o primeiro caso dispende 5 segundos para a construção do modelo, no segundo, em 0,05 segundos o modelo já é construído.

Assim como realizado para o Motor 2, investiga-se o comportamento do sistema quando são aplicados no Motor 3 apenas os curto-circuitos entre as espiras de 3%, 5% ou 10%. Na Figura 48 e na Tabela 30 são ilustrados os resultados dos testes realizados para esta situação. Novamente, é possível notar que o modelo realiza a separação entre as classes, sem defeitos e com defeitos, bem como há o aumento nos coeficientes Kappa, quando é comparado com os testes que utilizam as amostras com 1% de curto-circuito entre as espiras do estator. Para o Motor 3 operando com desequilíbrio entre as tensões de alimentação de até 10%, o sistema proposto foi capaz de classificar corretamente 99,55% do conjunto total de amostras. Também 100% das amostras com defeitos e 98,18% das amostras sem defeitos foram identificadas corretamente, como apresentam-se na Figura 48 e na Tabela 30.









Figura 48 – Resultados experimentais *offline* utilizando a rede neural MLP - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

Tabela 30 – Matriz de Confusão - Testes *offline* utilizando a rede neural MLP - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%

	Nível de Desequilíbrio										
	\leq 0,5%		≤ 2,0%		\leq 4,0%		\leq 6,0%		\leq 10,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	22	0	66	0	109	1	152	2	216	4	
Falha	0	66	0	198	1	329	2	460	0	660	

Na Figura 49 e na Tabela 31 são apresentados os resultados relacionados ao teste que emprega dados provenientes de motores de potências variadas. Aplicou-se nestas máquinas um curto-circuito entre as espiras do estator de 1%, 3%, 5% e 10%, além de variar o conjugado de carga de 10% à 120% do valor nominal e o desequilíbrio entre as tensões de alimentação em até 10%.



(a) Precisão de classificação em função do nível de desequilíbrio

(b) Índice Kappa em função do nível de desequilíbrio

Figura 49 – Resultados experimentais *offline* utilizando a rede neural MLP - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 1%

Fonte: Autoria própria

Tabela 31	– Matriz de Confusão -	Testes offline util	lizando a rede ne	ural MLP - M	lotores 2 e 3 - C	Curto-
	circuito entre espiras	do estator maior	ou igual a 1%			

		Nível de Desequilíbrio										
	\leq 0,5%		≤ 2,0%		≤ 4,	\leq 4,0%		\leq 6,0%		\leq 10,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha		
Normal	35	9	117	15	163	57	224	84	309	131		
Falha	5	171	14	514	33	847	56	1176	140	1620		

Baseado nestes resultados, verifica-se, mais uma vez, que em situações extremas de operação o sistema tende a identificar de forma equivocada as amostras sem defeitos, classificando-as como defeituosas. Como os sinais das amostras sem defeitos e com curto-circuito entre as espiras de 1% apresentam características similares, visto que é um problema incipiente da máquina, o sistema não consegue fazer uma boa predição das amostras sem defeitos. Assim, são identificadas aproximadamente 70% das amostras sem defeitos. Já em relação as amostras com defeitos, o aumento do nível de desequilíbrio leva a diminuição da acurácia deste tipo de amostras, resultando em uma taxa de classificação de 92,05% para o pior caso. Assim, um novo teste é realizado com o objetivo de analisar o comportamento do sistema quando são utilizadas as amostras com um curto-circuito entre

as espiras do estator maior ou igual a 3%.

Na Figura 50 e na Tabela 32 são apresentados os resultados do referido teste. É possível perceber o aumento nas taxas de classificação, bem como nos índices K, quando é comparado com o teste em que foram utilizadas as amostras com 1% de curto-circuito entre as espiras do estator. Mesmo diante de situações não ideais de operação, o sistema atinge acurácias de 97,67%, 93,41% e 99,09% para o conjunto total de amostras, amostras sem defeitos e com defeitos, respectivamente. A RNA do tipo MLP alcança resultados levemente superiores ao da árvore de decisão C4.5. No entanto, é importante destacar que este tipo de classificador dispende do tempo computacional de 7,91 segundos e o C4.5 de 0,11 segundos, respectivamente. Assim, a utilização do tipo de classificador fica a critério do operador do sistema.





(a) Precisão de classificação em função do nível de desequilíbrio

(b) Índice Kappa em função do nível de desequilíbrio

Figura 50 – Resultados experimentais *offline* utilizando a rede neural MLP - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

Tabela 32 – Matriz de Confusão - Testes *offline* utilizando a rede neural MLP - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 3%

	Nível de Desequilíbrio										
	\leq 0,5%		\leq 2,0%		\leq 4,	\leq 4,0%		\leq 6,0%		\leq 10,0%	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	44	0	131	1	215	5	296	12	411	29	
Falha	1	131	0	396	1	659	11	913	12	1308	

Nesta seção, apresentou-se os resultados dos testes *offline* para o classificador neural do tipo MLP. Consequentemente, os modelos são empregados em algoritmos no Matlab® para que seja realizado a validação *online*. Na Seção 5.3.2, os resultados desta validação são apresentados.

5.3.2 Testes Experimentais Online Utilizando a Rede Neural MLP

De modo a validar os resultados experimentais alcançados na Seção 5.3.1, realizouse ensaios experimentais para o caso em que as máquinas, descritas no Capítulo 4, estiveram sujeitas a testes *online*. Assim, foram utilizados os algoritmos das RNAs no ambiente do Matlab® para a realização destes testes. Os motores estiveram sujeitos a variação no desequilíbrio entre as tensões de alimentação e variação de carga mecânica acoplada ao eixo da máquina, conforme descrito na Seção 5.2. Já os níveis de curto-circuito aplicados a esse motor, foram de 1% a 20% entre as espiras da fase A.

As Figuras 51 e 52, e as Tabelas 33 e 34 apresentam os resultados do testes realizados para o Motor 2. No primeiro teste, utilizou-se dados de curto-circuito entre as espiras iguais ou maiores que 1%. No segundo, por sua vez, somente foram utilizados dados com no mínimo 3% de curto-circuito entre as espiras do estator.

1

0,8

0,4

ndice Kappa

0,6 **0,6769**







0,6387

0,6699

0.6500

0,7333

(b) Índice Kappa em função do nível de desequilíbrio

Figura 51 – Resultados experimentais *online* utilizando a rede neural MLP - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 1%

Fonte: Autoria própria

Tabela 33 – Matriz de Confusão - Testes *online* utilizando a rede neural MLP - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 1%

		Nível de Desequilíbrio										
	\leq 0,	5%	≤ 2,	0%	≤ 4,	0%	≤ 6,	0%	<u>≤</u> 10	,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha		
Normal	4	1	14	1	18	7	26	9	37	13		
Falha	2	28	7	83	9	141	13	197	16	284		

Fica evidente por meio das Figuras 51 e 52 que ao utilizar as amostras com 1%, o sistema tende a reduzir a taxa de acerto. No primeiro teste, o classificador atingiu acurácias





(a) Precisão de classificação em função do nível de desequilíbrio

(b) Índice Kappa em função do nível de desequilíbrio

Figura 52 – Resultados experimentais *online* utilizando a rede neural MLP - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

Tabela 34 – Matriz de Confusão - Testes *online* utilizando a rede neural MLP - Motor 2 - Curto-circuito entre espiras do estator maior ou igual a 3%

		Nível de Desequilíbrio										
	\leq 0,	5%	≤ 2,	0%	\leq 4,	0%	≤ 6 ,	0%	<u>≤</u> 10	,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha		
Normal	5	0	14	1	23	2	33	2	48	2		
Falha	0	25	0	75	0	125	0	175	2	248		

em torno de 91% à 92%, para o conjunto total de amostras, independente dos níveis de desequilíbrio entre as tensões de alimentação. Além disso, os coeficientes K entre 0,64 e 0,73 confirmam a substancial concordância com os resultados obtidos. Outro ponto a ser destacado é que para o Motor 2, a rede MLP não conseguiu fazer uma boa separação entre as amostras sem defeitos e com defeitos de 1% de curto-circuito, tanto no teste *offline* quanto no *online*. Nos referidos testes foram atingidas taxas de acerto das amostras sem defeitos de 69,55% e 74%, respectivamente. Uma das razões para a ocorrência disso é que as assinaturas da DMI das amostras com 1% de curto-circuito, em situações em que o Motor 2 está sujeito a condições de 4% até 10% de desequilíbrio de tensão, tem um comportamento próximo ao motor operando sem defeitos.

Na Figura 52 e na Tabela 34, observa-se que quando não são utilizados as amostras com 1% o sistema apresenta melhora no desempenho. Mesmo sujeito a um desequilíbrio de até 10%, a estratégia identifica corretamente 98,67%, 96,00% e 99,20%, do conjunto total de amostras, das amostras sem defeitos e com defeitos, respectivamente. O coeficiente K de 0,9520 para esta situação confirma a total concordância com os resultados atingidos. Semelhante ao que foi realizado anteriormente para o Motor 2, foram executados dois testes de validação *online* para o Motor 3. Nas Figuras 53 e 54 e nas Tabelas 35 e 36 são exibidos os resultados dos testes realizados para este motor. Nestes testes são utilizadas amostras com curto-circuito entre as espiras iguais ou maiores que 1% e com no mínimo 3% de curto-circuito entre as espiras do estator.





(a) Precisão de classificação em função do nível de desequilíbrio

(b) Índice Kappa em função do nível de desequilíbrio

Figura 53 – Resultados experimentais *online* utilizando a rede neural MLP - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 1%

Fonte: Autoria própria

Tabela 35 – Matriz de Confusão - Testes *online* utilizando a rede neural MLP - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 1%

	Nível de Desequilíbrio										
	\leq 0,	5%	<u>≤</u> 2,	0%	\leq 4,	0%	<u>≤</u> 6,	0%	<u>≤</u> 10	,0%	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	
Normal	5	0	13	2	22	3	32	3	46	4	
Falha	0	30	1	89	6	144	10	200	12	288	

Tabela 36 – Matriz de Confusão - Testes *online* utilizando a rede neural MLP - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3%

		Nível de Desequilíbrio										
	\leq 0,	5%	<u>≤</u> 2,	0%	\leq 4,	0%	<u>≤</u> 6,	0%	<u>≤</u> 10	,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha		
Normal	5	0	15	0	25	0	35	0	50	0		
Falha	0	25	0	75	2	123	5	170	9	241		

Ao analisar as Figuras 53 e 54 e as Tabelas 35 e a 36, novamente observa-se a melhor predição das classes sem defeitos e com defeitos no segundo teste. No entanto, deve-se destacar que tanto nos testes *offline* quanto no *online* para o Motor 3, a rede neural MLP é capaz de fazer uma satisfatória separação entre as amostras sem defeitos e com defeitos de 1% de curto-circuito.



(a) Precisão de classificação em função do nível de desequilíbrio

(b) Índice Kappa em função do nível de desequilíbrio

Figura 54 – Resultados experimentais *online* utilizando a rede neural MLP - Motor 3 - Curto-circuito entre espiras do estator maior ou igual a 3% Fonte: Autoria própria

Verifica-se, por meio da Figura 53, que o sistema atinge taxas de classificação de 95,43%, 92,00% e 96,00% do conjunto total, das amostras sem defeitos e das amostras defeituosas, respectivamente. Em relação as amostras com defeitos, ressalta-se que o sistema só identificou de forma equivocada as amostras com 1% de curto-circuito e nas demais condições o sistema consegue identificar o problema, com taxas de 100% de acerto.

Já no segundo teste, quando não são utilizadas as amostras com 1% de curtocircuito, verifica-se que há um acréscimo nas acurácias das amostras sem defeitos. Conforme apresentado na Tabela 36, o sistema classifica corretamente todas as amostras sem defeitos. Contudo, algumas amostras com 3% de curto-circuito entre as espiras do estator são classificadas inadequadamente. O índice K de 0,8993 demonstra uma perfeita concordância com os resultados obtidos.

Nas Figuras 55 e 56 e nas Tabelas 37 e 38 são apresentados os resultados obtidos na validação *online* para o modelo criado a partir do conjunto de motores de potências variadas. O Motor 2 e o Motor 3 foram submetidos às mesmas condições de variação no nível de conjugado de carga e desequilíbrio de tensão impostas nos testes descritos na Seção 5.2. No entanto, há uma diferença entre os ensaios ilustrados. Na Figura 55 e na Tabela 37 são exibidos os resultados relacionados aos ensaios em que foram aplicados curto-circuito entre as espiras de 1% à 20%. Já na Figura 56 e na Tabela 38, aplicou-se curto-circuito de 3% à 20%.



(a) Precisão de classificação em função do nível de desequilíbrio



Figura 55 – Resultados experimentais *online* utilizando a rede neural MLP - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 1%

Fonte: Autoria própria

Tabela 37 – Matriz de Confusão - Testes *online* utilizando a rede neural MLP - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 1%

		Nível de Desequilíbrio										
	\leq 0,	5%	≤ 2 ,	0%	\leq 4,	0%	≤ 6 ,	0%	≤ 10	,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha		
Normal	9	1	27	3	44	6	55	15	80	20		
Falha	1	59	5	175	11	289	16	404	24	576		





(a) Precisão de classificação em função do nível de desequilíbrio



Figura 56 – Resultados experimentais *online* utilizando a rede neural MLP - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 3%

Fonte: Autoria própria

		Nível de Desequilíbrio										
	\leq 0,	5%	<u>≤</u> 2,	0%	\leq 4,	0%	\leq 6,	0%	<u>≤</u> 10	,0%		
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha		
Normal	10	0	29	1	47	3	70	5	93	7		
Falha	0	50	0	150	0	250	2	348	6	494		

Tabela 38 – Matriz de Confusão - Testes *online* utilizando a rede neural MLP - Motores 2 e 3 - Curtocircuito entre espiras do estator maior ou igual a 3%

Na Figura 55 e na Tabela 37, verificou-se que em condições normais de operação e desequilíbrio de tensão de até 0,5%, o sistema diagnosticou corretamente 97,14% do conjunto total de amostras, 90,00% das amostras sem defeitos e 98,33% das amostras com defeitos. O coeficiente K de 0,8833 comprova este desempenho. Além disso, mesmo diante de situações desfavoráveis, o sistema apresenta acurácias de classificação do conjunto global de amostras de 95,14% e 93,71%, para níveis de desequilíbrio entre as tensões de até 4% e 10%, respectivamente. Em relação às amostras com defeitos, o sistema identificou de forma incorreta apenas as amostras com curto-circuito entre as espiras do estator de 1%, quando a intensidade do curto-circuito aumentou, imediatamente a ferramenta detectou o defeito da máguina.

Em relação a Figura 56 e a Tabela 38, verificou-se o aumento nas taxas de classificação. A razão para a ocorrência disso é que neste teste não aplicou-se o curto-circuito de 1%. Assim, o sistema foi capaz de incrementar a taxa de predição entre as classes sem defeitos e com defeitos. Principalmente nas amostras sem defeitos, a metodologia proposta atingiu melhores acurácias do que no teste em que foram utilizadas as amostras com 1% de curto-circuito entre as espiras do estator. Independente do nível de desequilíbrio entre as tensões de alimentação, apresentou-se taxas de classificação das amostras sem defeitos, bem como índices K superiores a 93,00% e 0,9217, respectivamente.

5.4 COMPARAÇÃO COM OUTROS TRABALHOS ENCONTRADOS NA LITERATURA

Considerando estudos anteriores relativos a falhas do estator, este trabalho apresenta alguns pontos importantes que merecem ser destacados. Enquanto os pesquisadores Ghate e Dudul (2010), Ghate e Dudul (2011), Filho, Pederiva e Brito (2014), Drif e Cardoso (2014) e Devi, Sarma e Rao (2015) analisam os sinais no domínio da frequência utilizando medidas estatísticas, análise do envelope, FFT e TWD na etapa de processamento dos sinais, respectivamente, este trabalho, bem como os trabalhos de Palácios et al. (2015) e Palácios et al. (2016) consideram a análise no domínio do tempo. Neste trabalho, emprega-se a DMI entre os sinais de correntes do estator das fases A e B, já o préprocessamento dos dados nos trabalhos de Palácios et al. (2015) e Palácios et al. (2016) Outro aspecto importante deste trabalho refere-se a aplicação do desequilíbrio de tensão durante a aquisição dos dados, bem como nos trabalhos de Filho, Pederiva e Brito (2014), Devi, Sarma e Rao (2015), Palácios et al. (2015) e Palácios et al. (2016). Considerando a variação no conjugado de carga no eixo da máquina, as referências Ghate e Dudul (2010), Ghate e Dudul (2011), Drif e Cardoso (2014), Palácios et al. (2015) e Palácios et al. (2015) e Palácios et al. (2015) e

Considerando a análise comparativa de acurácia, é notado que os autores Filho, Pederiva e Brito (2014), Drif e Cardoso (2014) e Devi, Sarma e Rao (2015) não especificam os dados estatísticos, e sim, apresentam uma análise gráfica dos resultados. Os trabalhos de Ghate e Dudul (2010) e Ghate e Dudul (2011) atingem acurácias entre 96% e 99%, porém são empregados apenas variação de torque no eixo da máquina, não sendo considerados desequilíbrios entre as tensões de alimentação, que é um problema de qualidade de energia presente nos ambientes industriais. Já os trabalhos de Palácios et al. (2015) e Palácios et al. (2016), mesmo sob estas condições, atingem acurácias entre 93% e 99%. Neste trabalho, também considerando um curto-circuito entre as espiras do estator de 1%, que é um defeito incipiente da máquina, foram atingidas taxas de precisão entre 83% e 97% dependendo do classificador de padrões utilizado. A Tabela 39 resume esta comparação.

Literatura	Variação de Conjugado	Desequilíbrio	Preprocessamento	Classificador	Acurácia
Refs. [1]	Sim	Não	Medidas Estatísticas	RNA	Entre 96% e 99%
Ref. [2]	Não	Sim	Análise do Envelope	SHFC	NE
Ref. [3]	Sim	Não	FFT	IAPSA/IRPSA	NE
Ref. [4]	Não	Sim	TWD	RMFI/RAT	NE
Refs. [5]	Sim	Sim	Discretização	RNA/MAS	Entre 93% e 99%
Este trabalho	Sim	Sim	DMI	AD C4.5 e RNA MLP	Entre 83% e 97%

Tabela 39 – Resumo de alguns trabalho relacionados ao diagnóstico de falhas do estator

Refs. [1] - Ghate e Dudul (2010) e Ghate e Dudul (2011)/Ref. [2] - Filho, Pederiva e Brito (2014)

Ref. [3] - Drif e Cardoso (2014)/Ref. [4] - Devi, Sarma e Rao (2015)

Refs. [5] - Palácios et al. (2015) e Palácios et al. (2016)

SHFC - Componentes das Frequências das Harmônicas/NE - Não Especificado

IAPSA - Análise da Assinatura da Potência Ativa Instantânea/IRPSA - Análise da Assinatura da Potência Reativa Instantânea RMFI - Valor Relativo do Índice de Falha Máximo/RAT - Valor Relativo do Limiar Adaptativo

MAS - Sistemas de Multi-Agentes

5.5 CONCLUSÃO DO CAPÍTULO

Os resultados apresentados neste capítulo validam a técnica proposta para o diagnóstico de curto-circuito entre as espiras do estator considerando motores de 1 CV e 2 CV. Observou-se a boa capacidade do sistema de identificação de falhas no estator baseado em medidas de informação e árvores de decisão na correta classificação das instâncias, bem como quando utiliza-se o classificador neural MLP. Nos ensaios experimentais os motores operaram sob diversas condições de operação como desequilíbrio entre as tensões de alimentação, variação no nível de conjugado de carga aplicado ao eixo do motor e curto-circuito entre as espiras do estator. Na Figura 57 é apresentando um resumo com as acurácias de classificação obtidas para os testes *offline* e *online*, quando utiliza-se a matriz de entrada com 25 pontos da DMI.





Fonte: Autoria própria

6 CONCLUSÃO

Neste trabalho foi apresentada uma metodologia alternativa para o reconhecimento de padrões para o diagnóstico de curto-circuito entre as espiras de estator em MITs, a qual é baseada em medidas de informação, utilizando a informação mútua e classificadores de padrões baseados em árvores de decisão e redes neurais artificiais. Os testes foram realizados com sinais de correntes trifásicas obtidos por meio de ensaios experimentais. O banco de dados é composto por vários sinais de motores sujeitos a diferentes condições de operação, como variação do conjugado de carga, variação no nível de desequilíbrio entre as fases e, também, variação no nível de curto-circuito entre as espiras do estator, situações estas que podem ser encontradas em um ambiente industrial.

Na etapa de extração de características, utilizou-se a informação mútua para calcular as medidas de associação entre os sinais de corrente das fases A e B do motor, a fim de encontrar um padrão característico do sinal e assim diagnosticar a real situação da máquina.

Observou-se que para cada condição apresentada do motor foi encontrado um padrão característico da curva DMI. Com o acréscimo de conjugado de torque no eixo do motor detectou-se o atraso da curva DMI em relação à curva em condições iniciais, onde o motor opera com torque de carga no eixo mínimo, sem desequilíbrio entre as tensões e sem falhas.

Para o caso de variação no desequilíbrio de tensão na fase A, as curvas DMI também se atrasam em relação à curva inicial com agravamento desta situação de operação. No caso de um desequilíbrio de tensão na fase B, as curvas se adiantam.

Este comportamento de avanço ocorre nas situações onde o motor está operando com curto-circuito entre as espiras de estator. Com o aumento do nível de curto, as curvas DMI se adiantam em relação à curva inicial. Estes padrões característicos são encontrados independentemente da potência do motor, visto que neste trabalho foram utilizados dados experimentais de motores de 1 CV e 2 CV.

Para a etapa de classificação de padrões, utilizou-se o classificador baseado em árvores de decisão C4.5, o qual é uma estratégia amplamente aplicada na área de mineração de dados e classificação de falhas em máquinas elétricas. Este classificador tem característica construtiva simples, visto que é construído a partir de regras.

Os testes foram separados em *offline* e *online*. Nos testes *offline* foram realizadas duas análises, uma quando utilizou-se como parâmetros de entrada da árvore de decisão somente os pontos da curva DMI. Na outra análise foi aplicado também como parâmetro de entrada o deslocamento entre a curva DMI atual e a curva do motor operando em

condições iniciais. Já na validação *online*, os modelos criados que atingiram as melhores acurácias de classificação nos testes *offline* são utilizados nesta segunda fase, a fim de verificar a robustez do sistema proposto frente as dificuldades encontradas em um ambiente industrial.

O sistema teve dificuldades na identificação das amostras sem defeitos quando também utilizou-se no banco de dados amostras da máquina com 1% de curto-circuito entre as espiras do estator. Sabe-se que este tipo de defeito é incipiente, o que induz o sistema classificar de forma equivocada as amostras saudáveis. Assim, de modo a avaliar o modelo quando a máquina está sujeita a um curto-circuito entre as espiras igual ou maior do que 3%, novos testes foram realizados. Nestes testes, a técnica proposta apresentou acurácias acima de 94% nos resultados experimentais *offline*, tanto na análise em função do deslocamento τ quanto na análise da resolução da DMI. No entanto, o tempo computacional para a construção do modelo é menor quando utiliza-se a análise da resolução da DMI. Verificou-se que para esta análise, o sistema de monitoramento de falhas de estator apresenta um desempenho superior, tanto nas acurácias de classificação quanto no aspecto do esforço computacional, quando utiliza-se a matriz de entrada de 25 pontos, para todos os casos (Motor 1, Motor 2, Motor 3 e conjunto total).

A validação *online* confirmou os resultados atingidos nos ensaios preliminares. Verificou-se a capacidade do sistema de identificação de falhas de estator baseado em medidas de informação e árvores de decisão na correta classificação das instâncias, mesmo quando as máquinas estão expostas às adversidades como variação no conjugado de carga nominal, desequilíbrio entre as tensões de alimentação e curto-circuito entre as espiras do estator.

Além disso, neste trabalho, avaliou-se os padrões da DMI obtidos na etapa de extração de características por meio de uma RNA do tipo MLP. Observou-se os resultados ligeiramente superiores ao do classificador baseado em árvores de decisão C4.5, tanto nos ensaios *offline* quanto no *online*. No entanto, vale a pena destacar que o modelo construtivo mais simples é a árvore de decisão C4.5. Assim, a seleção do tipo de classificador a ser utilizado, fica a critério do usuário do sistema. Os resultados obtidos em ambos os testes demonstram que os padrões da DMI são capazes de fazer a separação entre as classes sem defeitos e com defeitos de curto-circuito entre as espiras do estator.

6.1 TRABALHOS FUTUROS ASSOCIADOS A PESQUISA

Os trabalhos futuros associados a esta pesquisa baseiam-se na implementação em *hardware* do sistema de diagnóstico e classificação das falhas de curto-circuito entre as espiras do estator em tempo real, bem como no aperfeiçoamento da metodologia proposta para identificação de outros tipos de falhas presentes nos motores de indução trifásicos. Devido ao alto esforço computacional no cálculo da DMI, pois a mesma apresenta um complexo cálculo estatístico, a aplicação da metodologia em *hardware* deve-se levar em consideração as limitações de memória impostas pelo sistema. Assim, as etapas para trabalhos futuros serão:

- Avaliar uma forma de otimizar e reduzir o processamento estatístico das funções densidade de probabilidade;
- Avaliar como embarcar os estimadores estatísticos, de forma online ou "real time";
- Avaliar a utilização de outros estimadores das funções densidade de probabilidade, tais como estimadores de *Kernel*, metodologias paramétricas, metodologias não paramétricas, dentre outros.
- Implementar o sistema de diagnóstico e identificação de falhas de curto-circuito entre as espiras do estator em *hardware*;
- Aperfeiçoar a metodologia proposta neste trabalho para a identificação de outros tipos de falhas presentes nos MITs.

REFERÊNCIAS

ALONSO, J.; MANANAS, M.; HOYER, D.; TOPOR, Z.; BRUCE, E. 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.

ANTONINO-DAVIU, J.; AVIYENTE, S.; STRANGAS, E.; 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.

ASFANI, D.; MUHAMMAD, A.; SYAFARUDDIN; PURNOMO, M.; 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.

AYDIN, I.; KARAKOSE, M.; AKIN, E. An approach for automated fault diagnosis based on a fuzzy decision tree and boundary analysis of a reconstructed phase space. **ISA Transactions**, v. 53, n. 2, p. 220–229, 2014.

BACCARINI, L. **Detecção e Diagnóstico de Falhas em Motores de Indução**. 179 p. Tese (Doutorado) — Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil, 2005.

BARZEGARAN, M.; MAZLOOMZADEH, A.; MOHAMMED, O. 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.

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.

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

BOUZID, M.; 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.

BOUZID, M.; MRABET, N.; MOREAU, S.; SIGNAC, L. Accurate detection of stator and rotor fault by neural network in induction motor. In: **4th International Multi-Conference on Systems, Signals and Devices (ISSD)**. [S.I.: s.n.], 2007. p. 1–7.

BRITO, J. **Desenvolvimento de um Sistema Inteligente Híbrido para Diagnóstico de Falhas em Motores de Indução Trifásicos**. 214 p. Tese (Doutorado) — Universidade Estadual de Campinas, Campinas, SP, Brasil, 2002. BRONIERA, P. **Diagnóstico de curto-circuito no enrolamento de estator em máquinas de indução trifásicas utilizando redes neurais artificiais**. 113 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR, Brasil, 2014.

CHOI, S.; OH, J.; CHOI, C.; KIM, C. Input variable selection for feature extraction in classification problems. **Signal Processing**, v. 92, n. 3, p. 636–648, 2012.

CHOW, M.; YEE, S. Methodology for online incipient fault detection in single-phase squirrelcage induction motors using artificial neural networks. **IEEE Transactions on Energy Conversion**, v. 6, n. 3, p. 536–545, Sep 1991.

CHOW, M.-y.; SHARP, R. N.; HUNG, J. C. On the application and design of artificial neural networks for motor fault detection - part i. **IEEE Transactions on Industrial Electronics**, v. 40, n. 2, p. 181–188, 1993.

CHOW, M.-Y.; SHARPE, R. N.; HUNG, J. C. On the application and design of artificial neural networks for motor fault detection - part ii. **IEEE Transactions on Industrial Electronics**, v. 40, n. 2, p. 189–196, 1993.

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

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.I.: s.n.], 2010.

DEVI, N.; SARMA, D. S.; RAO, P. R. 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.

DIONISIO, A.; MENEZES, R.; MENDES, D. Mutual information: A measure of dependency for nonlinear time series. **Physica A: Statistical Mechanics and its Applications**, v. 344, n. 1-2, p. 326–329, 2004.

DRIF, M.; CARDOSO, A. 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.

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.

ELETROBRÁS-PROCEL. **Balanço Energético Nacional**. disponível em http://www.procelinfo.com.br: acessado em 06/07/2015, 2015.

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

ENDO, W.; SANTOS, F.; SIMPSON, D.; MACIEL, C.; NEWLAND, P. 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.
ESTÉVEZ, P.; TESMER, M.; PEREZ, C.; ZURADA, J. Normalized mutual information feature selection. **IEEE Transactions on Neural Networks**, v. 20, n. 2, p. 189–201, 2009.

FAES, L.; ERLA, S.; NOLLO, G. Measuring connectivity in linear multivariate processes: Definitions, interpretation, and practical analysis. **Computational and Mathematical Methods in Medicine**, v. 2012, 2012.

FAIZ, J.; EBRAHIMI, B.; AKIN, B.; TOLIYAT, H. 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.

FILHO, P. L.; PEDERIVA, R.; BRITO, J. 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.

FROSINI, L.; BORIN, A.; GIROMETTA, L.; VENCHI, G. A novel approach to detect short circuits in low voltage induction motor by stray flux measurement. In: **Electrical Machines** (ICEM), 2012 XXth International Conference on. [S.I.: s.n.], 2012. p. 1538–1544.

FÜRNKRANZ, J.; GAMBERGER, D.; LAVRAC, N. Foundations of Rule Learning. Heidelberg, GER: Springer-Verlag Berlin, 2012.

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.

GAO, Z.; HABETLER, T. G.; HARLEY, R. G.; COLBY, R. S. A sensorless adaptive stator winding temperature estimator for mains-fed induction machines with continuous-operation periodic duty cycles. **IEEE Transactions on Industry Applications**, v. 44, n. 5, p. 1533–1542, Sept 2008.

GHATE, V.; DUDUL, S. Fault diagnosis of three phase induction motor using neural network techniques. In: **2nd International Conference on Emerging Trends in Engineering and Technology (ICETET)**. [S.I.: s.n.], 2009. p. 922–928.

GHATE, V.; DUDUL, S. 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.; DUDUL, S. 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.; SILVA, I. D.; GOEDTEL, A.; PALÁCIOS, R. C. Evaluation of stator winding faults severity in inverter-fed induction motors. **Applied Soft Computing Journal**, v. 32, p. 420–431, 2015.

GODOY, W. F.; SILVA, I. N. da; GOEDTEL, 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**, April 2016.

GOEDTEL, A. **Estimador Neural de Velocidade para Motores de Indução Trifásicos**. 133 p. Tese (Doutorado) — Universidade de São Paulo, São Carlos, SP, Brasil, 2007. GONGORA, W.; SILVA, H.; GOEDTEL, A.; GODOY, W.; SILVA, S. da. Neural approach for bearing fault detection in three phase induction motors. In: **9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEM-PED)**. [S.I.: s.n.], 2013. p. 566–572.

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

GRACIOLA, C. L.; GOEDTEL, 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.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. 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.

HAN, J.; KAMBER, M.; PEI, J. **Data Mining: Concepts and Techniques**. San Francisco, CA, USA: Morgan Kaufmann, 2012.

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.

IMMOVILLI, F.; BIANCHINI, C.; COCCONCELLI, M.; BELLINI, A.; RUBINI, R. Bearing fault model for induction motor with externally induced vibration. **IEEE Transactions on Industrial Electronics**, v. 60, n. 8, p. 3408–3418, Aug 2013.

JAIN, A.; DUIN, R.; MAO, J. Statistical pattern recognition: A review. **IEEE Transactions** on Pattern Analysis and Machine Intelligence, v. 22, n. 1, p. 4–37, 2000.

JIN, X.; ZHAO, M.; CHOW, T.; 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.

KOLLA, S.; ALTMAN, S. Artificial neural network based fault identification scheme implementation for a three-phase induction motor. **ISA Transactions**, v. 46, n. 2, p. 261–266, 2007.

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.

LAMIM, P. Acompanhamento Preditivo de Motores de Indução Trifásicos através da análise de Fluxo Magnético. 105 p. Dissertação (Mestrado) — Universidade Estadual de Campinas, Campinas, SP, Brasil, 2003.

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

LEITE, V.; SILVA, J. Borges da; VELOSO, G. C.; SILVA, L. Borges da; LAMBERT-TORRES, G.; BONALDI, E.; OLIVEIRA, L. 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.; 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.

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.

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.

MERTENS, A. **Uma Abordagem sobre Detecção de Barras Quebradas em Motores de Indução Trifásicos**. 214 p. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba, PR, Brasil, 2008.

NGUYEN, N.; LEE, H.; KWON, J. Optimal feature selection using genetic algorithm for mechanical fault detection of induction motor. **Journal of Mechanical Science and Technology**, v. 22, n. 3, p. 490–496, 2008.

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

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

PALÁCIOS, R.; SILVA, I. D.; GOEDTEL, A.; GODOY, W. 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.; GOEDTEL, A.; GODOY, W. F.; FABRI, J. A. Fault identification in the stator winding of induction motors using pca with artificial neural networks. **Journal of Control, Automation and Electrical Systems**, p. 1–13, 2016.

PALÁCIOS, R. H. C.; SILVA, I. N. da; GOEDTEL, A.; GODOY, W. F.; OLESKOVICZ, M. 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; GOEDTEL, 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.

PALANICHAMY, J.; RAMASAMY, K. A novel feature selection algorithm with supervised mutual information for classification. **International Journal on Artificial Intelligence To-ols**, v. 22, n. 4, 2013.

PENG, H.; CHIANG, P. Control of mechatronics systems: Ball bearing fault diagnosis using machine learning techniques. In: 8th Asian Control Conference (ASCC). [S.I.: s.n.], 2011. p. 175–180.

PONS-LLINARES, J.; ANTONINO-DAVIU, J.; RIERA-GUASP, M.; LEE, S. B.; KANG, T. june; YANG, C. Advanced induction motor rotor fault diagnosis via continuous and discrete time-frequency tools. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1791–1802, March 2015.

QUINLAN, J. **C4.5: Programs for Machine Learning**. San Francisco, CA, USA: Morgan Kaufmann Publishers, Inc., 1993.

REZA, F. **An Introduction to Information Theory**. New York, USA: Dover Publications, Inc., 1994.

RUGGIERI, S. Yadt: Yet another decision tree builder. In: **16th International Conference on Tools with Artificial Intelligence (ICTAI)**. [S.I.: s.n.], 2004. p. 260–265.

SAHRAOUI, M.; GHOGGAL, A.; GUEDIDI, S.; ZOUZOU, S. Detection of inter-turn shortcircuit in induction motors using park-hilbert method. **International Journal of System Assurance Engineering and Management**, v. 5, n. 3, p. 337–351, 2014.

SANTOS, F. M. C.; SILVA, I. N.; SUETAKE, M. About Application of Intelligent Systems for Fault Diagnosis in Induction Machines - An Overview (In Portuguese). **Sba: Controle & Automação**, v. 23, p. 553–569, 10 2012.

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

SCHMITT, H.; SCALASSARA, P.; GOEDTEL, 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.; SILVA, L.; SCALASSARA, P.; GOEDTEL, 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.I.: s.n.], 2013. p. 538–543.

SEERA, M.; LIM, C.; 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.; 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.

SESHADRINATH, J.; SINGH, B.; PANIGRAHI, B. 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.

SHARIFI, R.; EBRAHIMI, M. Detection of stator winding faults in induction motors using three-phase current monitoring. **ISA Transactions**, v. 50, n. 1, p. 14–20, 2011.

SHI, P.; CHEN, Z.; VAGAPOV, Y.; ZOUAOUI, Z. A new diagnosis of broken rotor bar fault extent in three phase squirrel cage induction motor. **Mechanical Systems and Signal Processing**, v. 42, n. 1-2, p. 388–403, 2014.

SHIMAZAKI, H.; SHINOMOTO, S. 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.

SILVA, I. d.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia** e ciências aplicadas. São Paulo, SP, Brasil: Artliber, 2010.

SUETAKE, M. Sistemas Inteligentes para o Diagnóstico de Falhas em Motores de Indução Trifásicos. 126 p. Tese (Doutorado) — Universidade de São Paulo, São Carlos, SP, Brasil, 2012.

SUETAKE, M.; SILVA, I. D.; GOEDTEL, A. Embedded dsp-based compact fuzzy system and its application for induction-motor v/f speed control. **IEEE Transactions on Industrial Electronics**, v. 58, n. 3, p. 750–760, 2011.

SUGUMARAN, V.; MURALIDHARAN, V.; RAMACHANDRAN, K. Feature selection using decision tree and classification through proximal support vector machine for fault diagnostics of roller bearing. **Mechanical Systems and Signal Processing**, v. 21, n. 2, p. 930–942, 2007.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. San Diego, CA, USA: Elsevier, 2009.

THORSEN, O.; 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.

TRAN, V.; 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.

VERMA, A.; SARANGI, S.; KOLEKAR, M. 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.

WANG, Y. Analysis of effects of three-phase voltage unbalance on induction motors with emphasis on the angle of the complex voltage unbalance factor. **IEEE Transactions on Energy Conversion**, v. 16, n. 3, p. 270–275, 2001.

WITTEN, I.; FRANK, E. Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations. San Francisco, CA, USA: Morgan Kaufmann, 2000.

ZAREI, J.; TAJEDDINI, M.; KARIMI, H. 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 multiscale entropy and adaptive neuro-fuzzy inference. **Expert Systems with Applications**, v. 37, n. 8, p. 6077–6085, 2010.

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.

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. **Measure-***ment: Journal of the International Measurement Confederation*, v. 47, n. 1, p. 669–675, 2014.

ZIDANI, F.; BENBOUZID, M.; DIALLO, D.; NAIT-SAID, M. Induction motor stator faults diagnosis by a current concordia pattern-based fuzzy decision system. **IEEE Transactions on Energy Conversion**, v. 18, n. 4, p. 469–475, 2003.