UNIVERSIDADE DE SÃO PAULO–USP
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Wagner Fontes Godoy

**Multiclassificador Inteligente de Falhas
no Domínio do Tempo em Motores de
Indução Trifásicos Alimentados por
Inversores de Frequência**

Wagner Fontes Godoy

**Multiclassificador Inteligente de Falhas
no Domínio do Tempo em Motores de
Indução Trifásicos Alimentados por
Inversores de Frequência**

Tese de doutorado apresentada ao Programa de Engenharia Elétrica da Escola de Engenharia de São Carlos da Universidade de São Paulo como parte dos requisitos para a obtenção do título de Doutor em Ciências.

Área de concentração: Sistemas Dinâmicos

Orientador: Ivan Nunes da Silva

Coorientador: Alessandro Goedtel

São Carlos

2016

Trata-se da versão corrigida da tese. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

G588m Godoy, Wagner Fontes
Multiclassificador Inteligente de Falhas no Domínio
do Tempo em Motores de Indução Trifásicos Alimentados
por Inversores de Frequência / Wagner Fontes Godoy;
orientador Ivan Nunes da Silva; coorientador Alessandro
Goedtel. São Carlos, 2016.

Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Elétrica e Área de Concentração em Sistemas
Dinâmicos -- Escola de Engenharia de São Carlos da
Universidade de São Paulo, 2016.

1. Sistema inteligentes. 2. Predição de falhas. 3.
Motor de indução trifásico. 4. Inversor de frequência.
5. Falhas de estator. 6. Falhas de rotor. 7. Falhas de
rolamentos. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **WAGNER FONTES GODOY**.

Título da tese: "Multiclassificador inteligente de falhas no domínio do tempo em motores de indução trifásicos alimentados por inversores de frequência".

Data da defesa: 18/04/2016

Comissão Julgadora:

Resultado:

Prof. Associado **Ivan Nunes da Silva (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Dr. **Ernesto Ruppert Filho**
(Universidade Estadual de Campinas/UNICAMP)

Aprovado

Prof. Dr. **Francisco de Assis dos Santos Neves**
(Universidade Federal de Pernambuco/UFPE)

APROVADO

Prof. Dr. **Marcelo Suetake**
(Universidade Federal de São Carlos/UFSCar)

APROVADO

Prof. Dr. **Jean Marcos de Souza Ribeiro**
(Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP – Ilha Solteira)

APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:
Prof. Associado **Luis Fernando Costa Alberto**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Paulo César Lima Segantine**

Dedico este trabalho aos meus pais Ana e Roberto, a minha esposa Vanessa e aos meus filhos João Gabriel e Lucas, pelo amor incondicional.

Agradecimentos

Inicialmente, agradeço à minha esposa Vanessa, por seu amor, por seu apoio, incentivo e, principalmente pelo seu companheirismo. Aos meus filhos João Gabriel e Lucas, pelos momentos de descontração e principalmente pela sua compreensão durante os longos momentinhos que fiquei estudando e não pude dar toda atenção, carinho e a diversão que vocês mereciam.

Aos meus pais, Ana e Roberto, minhas irmãs, Edilene e Edvania, que sempre estiveram presentes em todos os momentos da minha vida pessoal e profissional, amando, apoiando e orando para que tudo pudesse transcorrer na mais perfeita harmonia.

Ao meu orientador, Prof. Ivan Nunes da Silva, pela sua orientação, ensinamentos, e principalmente por suas contribuições para consolidação da minha formação acadêmica, ética e profissional. Agradeço ainda ao Prof. Ivan pelos preciosos ensinamentos na elaboração dos artigos científicos e construção desta pesquisa.

Ao meu co-orientador, Prof. Alessandro Goedtel, por ter acreditado, trabalhado incansavelmente ao meu lado, disponibilizando a bancada de ensaios experimentais desenvolvida durante o seu doutorado, bem como toda infraestrutura necessária para o desenvolvimento desta pesquisa. Também agradeço ao Prof. Alessandro pelos ensinamentos na elaboração e correção dos artigos científicos produzidos ao longo desta caminhada, por seu companheirismo, paciência e também por seus valorosos conselhos. A minha eterna gratidão.

Ao Prof. Bruno Augusto Angélico, por sua irrestrita disponibilidade, pelas inúmeras e valorosas sugestões que me ajudaram no entendimento, implementação e principalmente no direcionamento desta pesquisa.

Ao Prof. Marcelo Castoldi, pelas inúmeras contribuições, otimismo e ensinamentos que aqui compõem esta pesquisa bem como toda a minha jornada.

Ao Prof. Marcos Banheti Rabelo Vallim, que esteve comigo ao longo de toda esta jornada, apoiando e incentivando sempre.

Ao Prof. Daniel Moriñigo Sotelo, pelas oportunidades, acolhida, confiança depositada e principalmente pela sua intensa dedicação ao ensino e a pesquisa.

Ao Prof. Paulo Rogério Scalassara, pelas discussões e ensinamentos em relação a processamento de sinais.

Aos amigos e parceiros de doutorado, Profs. Leonardo Bruno Garcia Campanhol e Rodrigo Henrique Cunha Palácios, pela dedicação, disposição em sempre ajudar, pelas inesquecíveis e agradáveis conversas, e principalmente pelo incentivo em alcançarmos o objetivo que traçamos juntos, minha eterna gratidão.

Ao parceiro de doutorado Willian César de Andrade Pereira, pela disponibilidade irrestrita, exemplo de força, coragem e determinação.

Aos amigos e parceiros de laboratório, Profs. Clayton Luiz Graciola, Gustavo Henrique Bazan, Jacqueline Jordan Guedes, Tiago Drummond Lopes, Tiago Henrique dos Santos, Vinícius Dário Bacon, Wylliam Salviano Gongora e aos futuros engenheiros Bruno Tangerino, Igor Elias, Murilo Garcia Gentil, Pedro Petri e Tonicler Conti Kutz pelo convívio, pelo apoio, pela compreensão e pela amizade. Aqui tive a oportunidade de ver a vida de uma forma muito alegre e diferente.

À Universidade Tecnológica Federal do Paraná, em especial aos colegas do Departamento de Elétrica que permitiram meu afastamento das atividades, colaborando com este importante passo na minha carreira profissional.

Aos professores da Universidade de São Paulo (USP/EESC/SEL), em especial ao Prof. Dr. Mário Oleskovicz pelos exemplos de conduta ética e profissional, e também pelos seus ensinamentos.

Aos funcionários da Universidade de São Paulo (USP/EESC/SEL), em especial a Sra. Marisa Helena R. Vicente Fortulan, pela brilhante competência e profissionalismo.

As contribuições do CNPq (Processo 552269/2011-5), FAPESP (Processo 2011/17610-0), Fundação Araucária/CAPES (Chamada Publica 13/2014) e CAPES (Processo BEX 0309/15-0) pelo apoio financeiro e concessão de bolsas de estudo, sem os quais não seria possível o desenvolvimento desta pesquisa.

*“E ainda que tivesse o dom de profecia, e conhecesse todos os mistérios
e toda a ciência, e ainda que tivesse toda a fé, de maneira tal que
transportasse os montes, e não tivesse amor, nada seria.”
(1 Coríntios 13:2)*

Resumo

Godoy, Wagner Fontes **Multiclassificador Inteligente de Falhas no Domínio do Tempo em Motores de Indução Trifásicos Alimentados por Inversores de Frequência**. 162 p. Tese de doutorado – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2016.

Os motores de indução desempenham um importante papel na indústria, fato este que destaca a importância do correto diagnóstico e classificação de falhas ainda em fase inicial de sua evolução, possibilitando aumento na produtividade e, principalmente, eliminando graves danos aos processos e às máquinas. Assim, a proposta desta tese consiste em apresentar um multiclassificador inteligente para o diagnóstico de motor sem defeitos, falhas de curto-circuito nos enrolamentos do estator, falhas de rotor e falhas de rolamentos em motores de indução trifásicos acionados por diferentes modelos de inversores de frequência por meio da análise das amplitudes dos sinais de corrente de estator no domínio do tempo. Para avaliar a precisão de classificação frente aos diversos níveis de severidade das falhas, foram comparados os desempenhos de quatro técnicas distintas de aprendizado de máquina; a saber: (i) Rede *Fuzzy Artmap*, (ii) Rede Perceptron Multicamadas, (iii) Máquina de Vetores de Suporte e (iv) k -Vizinhos-Próximos. Resultados experimentais obtidos a partir de 13.574 ensaios experimentais são apresentados para validar o estudo considerando uma ampla faixa de frequências de operação, bem como regimes de conjugado de carga em 5 motores de diferentes.

Palavras-chave: Sistemas inteligentes, predição de falhas, motor de indução trifásico, inversor de frequência, falhas de estator, falhas de rotor e falhas de rolamentos.

Abstract

Godoy, Wagner Fontes **Time Domain Intelligent Faults Multiclassifier in Inverter Fed Three-Phase Induction Motors.** 162 p. Ph.D. Thesis – São Carlos School of Engineering, University of São Paulo, 2016.

Induction motors play an important role in the industry, a fact that highlights the importance of correct diagnosis and classification of faults on these machines still in early stages of their evolution, allowing increase in productivity and mainly, eliminating major damage to the processes and machines. Thus, the purpose of this thesis is to present an intelligent multi-classifier for the diagnoses of healthy motor, short-circuit faults in the stator windings, rotor broken bars and bearing faults in induction motors operating with different models of frequency inverters by analyzing the amplitude of the stator current signal in the time domain. To assess the classification accuracy across the various levels of faults severity, the performances of four different learning machine techniques were compared; namely: (i) Fuzzy ARTMAP network, (ii) Multilayer Perceptron Network, (iii) Support Vector Machine and (iv) k -Nearest-Neighbor. Experimental results obtained from 13.574 experimental tests are presented to validate the study considering a wide range of operating frequencies and also load conditions using 5 different motors.

Keywords: Intelligent systems, fault prediction, three-phase induction motor, inverters, stator faults, rotor faults and bearing faults.

Lista de ilustrações

Figura 2.1	Tipos de falhas	41
Figura 3.1	Representação do neurônio artificial	63
Figura 3.2	Representação de uma rede PMC	63
Figura 3.3	Exemplo de uma decomposição por transformada Wavelet - Adaptado de (MALLAT, 1999)	66
Figura 3.4	Expansão de uma DWT em três níveis - Adaptado de (MALLAT, 1999)	67
Figura 4.1	Estrutura geral de desenvolvimento do trabalho	69
Figura 4.2	Bancada experimental do laboratório de Sistemas Inteligentes da UTFPR: (1) Variadores de Tensão, (2) Carga da Máquina CC, (3) Gerador de Corrente Contínua, (4) Torquímetro, (5) Sensor de Vibração, (6) Motor de Indução, (7) <i>Display</i> do Torquímetro, (8) Contator para Geração Automática de Curto-Circuito de Estator, (9) Placa de Aquisição, (10) Fonte CC, (11) Inversor Schneider ATV12H075M2, (12) Inversor Siemens Sinamics G110 e (13) Inversor Siemens Micromaster 440	70
Figura 4.3	Placas de condicionamento de sinais dos sensores <i>Hall</i>	71
Figura 4.4	Bancada experimental do laboratório de Máquinas Elétricas da UVA: (1) Motor de indução, (2) Freio magnético, (3) Sensor de óptico, (4) Placa de Aquisição, (5) Inversor Allen Braddley e (6) Inversor WEG	72
Figura 4.5	Modelagem dos dados de entrada - discretização da corrente	76
Figura 4.6	Rotina de aquisição, tratamento e classificação dos dados	77
Figura 4.7	Organização dos dados de entrada com os sinais das correntes discretizados e normalizados	77
Figura 4.8	Filtro RC passa baixa	78
Figura 4.9	Diagrama de Bode - Filtro RC passa baixa	79
Figura 4.10	Decomposição multinível da DWT utilizada no trabalho	79
Figura 4.11	Sinal original e sinal reconstruído - fase A - motor sem defeito	80

Figura 4.12	Sinal original e sinal reconstruído - fase A - motor com 2 barras de rotor quebradas	80
Figura 4.13	Curva de resposta Filtro FIR	82
Figura 4.14	Diagrama de acionamento	83
Figura 4.15	Estator do motor de indução rebobinado com <i>taps</i>	84
Figura 4.16	Rotor com quebra forçada das barras	85
Figura 4.17	Contaminação do rolamento dianteiro com SiC	88
Figura 4.18	Desgaste do rolamento após período de execução dos testes	89
Figura 4.19	Contaminação do rolamento dianteiro com pasta abrasiva	90
Figura 5.1	Precisão de classificação - falhas de estator (Motor 1) - filtro analógico x digital	105
Figura 5.2	Precisão de multiclassificação - falhas de estator (Motor 1) - filtro analógico x digital	106
Figura 5.3	Precisão de classificação - falhas de estator (Motor 2) - filtro analógico x digital	106
Figura 5.4	Precisão de multiclassificação - falhas de estator (Motor 2) - filtro analógico x digital	107
Figura 5.5	Precisão de classificação - barras quebradas de rotor (Motor 3) - filtro analógico x digital	115
Figura 5.6	Precisão de multiclassificação - barras quebradas de rotor (Motor 3) - filtro analógico x digital	116
Figura 5.7	Precisão de classificação - falhas de rotor (Motor 4) - filtro analógico x digital	117
Figura 5.8	Precisão de multiclassificação - falhas de rotor (Motor 4) - filtro analógico x digital	117
Figura 5.9	Precisão de classificação - rolamentos (Motor 3) - filtro analógico x digital	126
Figura 5.10	Precisão de classificação - rolamentos (Motor 3) - filtro analógico x digital	126
Figura 5.11	Precisão de classificação - rolamentos (Motor 4) - filtro analógico x digital	127
Figura 5.12	Precisão de multiclassificação - rolamentos (Motor 4) - filtro analógico x digital	127
Figura 5.13	Estimador neural da evolução do desgaste de uma falha de rolamento .	131
Figura 5.14	Precisão de classificação (Motores 1 e 3) - filtro analógico x digital . . .	141
Figura 5.15	Precisão de classificação (Motores 1 e 3) - filtro analógico x digital . . .	141
Figura 5.16	Precisão de classificação (Motores 2 e 4) - filtro analógico x digital . . .	142
Figura 5.17	Precisão de multiclassificação (Motores 2 e 4) - filtro analógico x digital	142

Lista de tabelas

Tabela 2.1	Comparação entre porcentagens de falhas em motores elétricos	41
Tabela 4.1	Características dos motores utilizados no trabalho	73
Tabela 4.2	Características básicas dos inversores de frequência	73
Tabela 4.3	Número de aquisições por classe de defeitos	74
Tabela 4.4	Faixa de variação de frequência em função da taxa de amostragem MIT de 0,74 e 1,47 kW	75
Tabela 4.5	Especificações do rolamento modelo SKF Explorer 6004	87
Tabela 4.6	Descrição das condições de testes adotadas	87
Tabela 4.7	Especificações dos rolamentos NSK 6204 2Z e 6205 2Z	89
Tabela 4.8	Tabela para interpretação da estatística Kappa	91
Tabela 5.1	Resultados experimentais - Classificação de falhas de curto-circuito de estator (Motor 1)	96
Tabela 5.2	Matriz de confusão (Motor 1) - Classificação de curto-circuito de estator	96
Tabela 5.3	Resultados experimentais - Multiclassificação de falhas de curto-circuito de estator (Motor 1)	97
Tabela 5.4	Matriz de confusão (Motor 1) - Multiclassificação de curto-circuito de estator	97
Tabela 5.5	Resultados experimentais - Classificação de falhas de curto-circuito de estator (Motor 2)	98
Tabela 5.6	Matriz de confusão (Motor 2) - Classificação de curto-circuito de estator	98
Tabela 5.7	Resultados experimentais - Multiclassificação de falhas de curto-circuito de estator (Motor 2)	99
Tabela 5.8	Matriz de confusão (Motor 2) - Multiclassificação de curto-circuito de estator	99
Tabela 5.9	Resultados experimentais - Classificação de falhas de curto-circuito de estator (Motor 1) - Filtro Digital	101

Tabela 5.10	Matriz de confusão (Motor 1) - Classificação de curto-circuito de estator - Filtro Digital	101
Tabela 5.11	Resultados experimentais - Multiclassificação de falhas de curto-circuito de estator (Motor 1) - Filtro Digital	102
Tabela 5.12	Matriz de confusão (Motor 1) - Multiclassificação de curto-circuito de estator - Filtro Digital	102
Tabela 5.13	Resultados experimentais - Classificação de falhas de curto-circuito de estator (Motor 2) - Filtro Digital	103
Tabela 5.14	Matriz de confusão (Motor 2) - Classificação de curto-circuito de estator - Filtro Digital	103
Tabela 5.15	Resultados experimentais - Multiclassificação de falhas de curto-circuito de estator (Motor 2) - Filtro Digital	104
Tabela 5.16	Matriz de confusão (Motor 2) - Multiclassificação de curto-circuito de estator - Filtro Digital	104
Tabela 5.17	Resultados experimentais - Classificação de falhas de barras quebradas de rotor (Motor 3) - Filtro Analógico	108
Tabela 5.18	Matriz de confusão (Motor 3) - Classificação de barras quebradas de rotor - Filtro Analógico	108
Tabela 5.19	Resultados experimentais - Multiclassificação de falhas de barras quebradas de rotor (Motor 3) - Filtro Analógico	108
Tabela 5.20	Matriz de confusão (Motor 3) - Multiclassificação de barras quebradas de rotor - Filtro Analógico	109
Tabela 5.21	Resultados experimentais - Classificação de falhas de barras quebradas de rotor (Motor 4) - Filtro Analógico	109
Tabela 5.22	Matriz de confusão (Motor 4) - Classificação de barras quebradas de rotor - Filtro Analógico	110
Tabela 5.23	Resultados experimentais - Multiclassificação de falhas de barras quebradas de rotor (Motor 4) - Filtro Analógico	110
Tabela 5.24	Matriz de confusão (Motor 4) - Multiclassificação de barras quebradas de rotor	110
Tabela 5.25	Resultados experimentais - Classificação de falhas de barras quebradas de rotor (Motor 3) - Filtro Digital	111
Tabela 5.26	Matriz de confusão (Motor 3) - Classificação de barras quebradas de rotor - Filtro Digital	112
Tabela 5.27	Resultados experimentais - Multiclassificação de falhas de barras quebradas de rotor (Motor 3) - Filtro Digital	112
Tabela 5.28	Matriz de confusão (Motor 3) - Multiclassificação de barras quebradas de rotor - Filtro Digital	113

Tabela 5.29	Resultados experimentais - Classificação de falhas de barras quebradas de rotor (Motor 4) - Filtro Digital	113
Tabela 5.30	Matriz de confusão (Motor 4) - Classificação de barras quebradas de rotor - Filtro Digital	113
Tabela 5.31	Resultados experimentais - Multiclassificação de falhas de barras quebradas de rotor (Motor 4) - Filtro Digital	114
Tabela 5.32	Matriz de confusão (Motor 4) - Multiclassificação de barras quebradas de rotor - Filtro Digital	114
Tabela 5.33	Resultados experimentais - Classificação de falhas de rolamentos (Motor 3) - Filtro Analógico	118
Tabela 5.34	Matriz de confusão (Motor 3) - Classificação de falhas de rolamentos - Filtro Analógico	118
Tabela 5.35	Resultados experimentais - Multiclassificação de falhas de rolamentos (Motor 3) - Filtro Analógico	119
Tabela 5.36	Matriz de confusão (Motor 3) - Multiclassificação de falhas de rolamentos - Filtro Analógico	119
Tabela 5.37	Resultados experimentais - Classificação de falhas de rolamentos (Motor 4) - Filtro Analógico	120
Tabela 5.38	Matriz de confusão (Motor 4) - Classificação de falhas de rolamentos - Filtro Analógico	120
Tabela 5.39	Resultados experimentais - Multiclassificação de falhas de rolamentos (Motor 4) - Filtro Analógico	121
Tabela 5.40	Matriz de confusão (Motor 4) - Multiclassificação de falhas de rolamentos - Filtro Analógico	121
Tabela 5.41	Resultados experimentais - Classificação de falhas de rolamentos (Motor 3) - Filtro Digital	122
Tabela 5.42	Matriz de confusão (Motor 3) - Classificação de falhas de rolamentos - Filtro Digital	122
Tabela 5.43	Resultados experimentais - Multiclassificação de falhas de rolamentos (Motor 3) - Filtro Digital	123
Tabela 5.44	Matriz de confusão (Motor 3) - Classificação de falhas de rolamentos - Filtro Digital	123
Tabela 5.45	Resultados experimentais - Classificação de falhas de rolamentos (Motor 4) - Filtro Digital	124
Tabela 5.46	Matriz de confusão (Motor 4) - Classificação de falhas de rolamentos - Filtro Digital	124
Tabela 5.47	Resultados experimentais - Multiclassificação de falhas de rolamentos (Motor 4) - Filtro Digital	125

Tabela 5.48	Matriz de confusão (Motor 4) - Multiclassificação de falhas de rolamentos - Filtro Digital	125
Tabela 5.49	Resultados experimentais de classificação do conjunto composto pelos inversores Allen Braddley e WEG (filtro FIR)	128
Tabela 5.50	Matriz de confusão gerada a partir do conjunto de dados composto pelos inversores Allen Braddley e WEG (filtro FIR)	129
Tabela 5.51	Resultados experimentais de multiclassificação do conjunto composto pelos inversores Allen Braddley e WEG (filtro FIR)	129
Tabela 5.52	Matriz de confusão gerada a partir do conjunto de dados composto pelos inversores Allen Braddley e WEG (filtro FIR) - Multiclassificação	130
Tabela 5.53	Resultados experimentais para o conjunto composto por todas as falhas (Motores 1 e 3) - Filtro Analógico	132
Tabela 5.54	Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas - Motores 1 e 3 - Filtro Analógico	133
Tabela 5.55	Resultados experimentais para o conjunto composto por todas as falhas (Motores 1 e 3) - multiclassificação - Filtro Analógico	133
Tabela 5.56	Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 1 e 3) - Multiclassificação - Filtro Analógico .	134
Tabela 5.57	Resultados experimentais para o conjunto composto por todas as falhas (Motores 2 e 4) - Filtro Analógico	134
Tabela 5.58	Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 2 e 4) - Filtro Analógico	134
Tabela 5.59	Resultados experimentais para o conjunto composto por todas as falhas (Motores 2 e 4) - Multiclassificação - Filtro Analógico	135
Tabela 5.60	Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 2 e 4) - Multiclassificação - Filtro Analógico .	135
Tabela 5.61	Resultados experimentais para o conjunto composto por todas as falhas (Motores 1 e 3) - Filtro Digital	136
Tabela 5.62	Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 1 e 3) - Filtro Digital	136
Tabela 5.63	Resultados experimentais para o conjunto composto por todas as falhas (Motores 1 e 3) - Multiclassificação - Filtro Digital	137
Tabela 5.64	Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 1 e 3) - Multiclassificação - Filtro Digital . . .	137
Tabela 5.65	Resultados experimentais para o conjunto composto por todas as falhas (Motores 2 e 4) - Filtro Digital	138
Tabela 5.66	Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas - Filtro Digital	138

Tabela 5.67	Resultados experimentais para o conjunto composto por todas as falhas (Motores 2 e 4) - Multiclassificação - Filtro Digital	139
Tabela 5.68	Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas - Multiclassificação - Filtro Digital	139
Tabela 5.69	Comparação do método proposto com trabalhos recentemente publica- dos sobre classificações de barras quebradas de rotor	144

Lista de Abreviaturas

ABRAMAN	Associação Brasileira de Manutenção
AG	Algoritmo Genético
ANFIS	<i>Adaptive Neuro-Fuzzy Inference Systems</i>
ART	<i>Adaptive Resonance Theory</i>
CA	Corrente Alternada
CC	Corrente Contínua
DFT	<i>Discrete Fourier Transform</i>
DWT	<i>Discrete Wavelet Transform</i>
EDM	<i>Electrical Discharge Machining</i>
EMF	<i>Eletromotive force</i>
EPE	Empresa de Pesquisa Energética
EPRI	<i>Electric Power Research Institute</i>
FAM	<i>Rede Fuzzy Artmap</i>
FIR	<i>Finite Impulse Response</i>
FFT	<i>Fast Fourier Transform</i>
ICA	<i>Independent Component Analysis</i>
IEEE	<i>Institute of Electric and Electronic Engineers</i>
k -NN	<i>k-Nearest Neighbors</i>
LF	Lógica Fuzzy
MIT	Motores de Indução Trifásicos
MCSA	<i>Motor Current Signature Analysis</i>
PAD	Placa de Aquisição de Dados

PCA	<i>Principal Component Analysis</i>
PMC	Rede Perceptron Multicamadas
RMS	<i>Root Mean Square</i>
RNA	Rede Neural Artificial
rpm	rotações por minuto
SFAM	<i>Simplified Fuzzy ARTmap</i>
SiC	Carbeto de silício
SI	Sistemas Inteligentes
SMO	<i>Sequential Minimal Optimization</i>
SVM	<i>Support Vector Machine</i>
TW	Transformada Wavelet
USB	<i>Universal Serial Bus</i>
UTFPR	Universidade Tecnológica Federal do Paraná
UVa	Universidade de Valladolid
WEKA	<i>Waikato Environment for Knowledge Analysis</i>

Lista de Símbolos

T_n	Conjugado nominal
$V_{a,b,c}$	Tensões das fases a, b e c
$I_{a,b,c}$	Correntes das fases a, b e c
f	Frequência em Hz
n_i	Quantidade de amostras em Δ_i
Δ	Tensão de alimentação em Delta
V/f	Controle escalar frequência x tensão constante
n	Número de atributos
k	Número de conjuntos de treinamento
$dist(X_1, X_2)$	Distância Euclidiana entre dois pontos ou conjunto de dados
v	Valor de um atributo numérico
min_A	Valor mínimo do atributo A
max_A	Valor máximo do atributo A
$d(X, Y)$	Distância Euclidiana
$\wedge$	Operador mínimo de lógica <i>Fuzzy</i>
F_1^a	Camada responsável por calcular a codificação complementar do padrão apresentado à rede
a	Vetor de entrada da rede <i>Fuzzy ARTmap</i>
a^c	Vetor de entrada complementar
M	Tamanho do vetor de entrada da rede <i>Fuzzy ARTmap</i>
I	Vetor de entrada complementar da rede <i>Fuzzy ARTmap</i>
w_{jk}	Vetor de ganhos sinápticos da rede <i>Fuzzy ARTmap</i>
N^a	Número de categorias da rede
$T_j(I)$	Função de ativação de saída
α	Parâmetro de escolha
ρ	Parâmetro de vigilância
β	Taxa de aprendizagem
N	Número de pontos do conjunto de treinamento do SVM

w	Pesos dos nós das categorias de saída
b	Parâmetro <i>bias</i>
ξ	Variável de folga
C	Parâmetro custo do SVM
$\varphi(\cdot)$	Função de transformação
α_i	Multiplicador de Lagrange
F	Espaço de características dimensionais
$\varphi \rightarrow \varphi(x)$	Função de transformação
$k(x, x_i)$	Função de Kernel
x	Amostragem
x_i	Vetor de suporte
$L(z)$	Filtro Wavelet passa-baixas
$H(z)$	Filtro Wavelet passa-altas
$y_l(k)$	Coefficientes Wavelet passa-baixas
$y_h(k)$	Coefficientes Wavelet passa-altas
n	Número de sinais de entrada do neurônio
X_i	i -ésimo sinal de entrada do neurônio
w_i	Peso associado com o i -ésimo sinal de entrada
b	Limiar relacionado com o neurônio
$v_j(k)$	Resposta ponderada do neurônio j -ésimo em relação ao instante k
$g(\cdot)$	Função de ativação do neurônio j -ésimo
$y_j(k)$	Sinal de saída do j -ésimo neurônio em relação ao instante k
$e_j(k)$	Sinal do erro associado a k -ésima iteração
$d_j(k)$	Resposta desejada para o j -ésimo neurônio de saída
$E(k)$	Erros quadráticos produzidos pelos neurônios da saída
p	Número de neurônios de saída
η	Constante que determina a taxa de aprendizado do algoritmo <i>backpropagation</i>
f_c	Frequência de corte
R	Resistência
C	Capacitância
$G(s)$	Função de transferência
v_{in}	Tensão de entrada
v_{out}	Tensão de saída
(Δ)	Configuração de conexão dos motores em Delta
ω_c	Frequência de corte do Filtro FIR passa-baixa
α	Atraso da amostra do Filtro FIR passa-baixa
ω	Frequência de corte do Filtro FIR passa-baixa
$\omega(n)$	Função simétrica

Sumário

1	Introdução	31
1.1	Justificativa	34
1.2	Objetivos	35
1.3	Contribuições	36
1.4	Organização do Trabalho	36
2	Aspectos Relacionados às Falhas em Motores de Indução Trifásicos	39
2.1	Falhas em Motores de Indução Alimentados por Inversores de Frequência	39
2.2	Falhas Elétricas	42
2.2.1	Falhas de Estator	44
2.2.2	Falhas de Rotor	46
2.3	Falhas Mecânicas	49
2.3.1	Falhas de Rolamentos	50
2.3.2	Falhas de Excentricidade	52
2.4	Deteção de Falhas no Inversor	53
2.5	Conclusões Sobre a Revisão da Literatura	54
3	Estratégias de Classificação	57
3.1	Introdução	57
3.2	Rede <i>Fuzzy ARTmap</i>	58
3.3	Máquina de Vetores de Suporte	60
3.4	Redes Neurais Artificiais	62
3.5	k Vizinhos mais Próximos	64
3.6	Transformada Wavelet Discreta	65
3.7	Considerações Finais	67
4	Metodologia	69
4.1	Bancada Experimental de Ensaios	70

4.1.1	Bancada Experimental - Laboratório de Sistemas Inteligentes UTFPR	70
4.1.2	Bancada Experimental - Laboratório de Máquinas Elétricas UVa	72
4.1.3	Banco de dados	73
4.2	Aquisição e Tratamento dos Sinais	74
4.2.1	Filtro RC Analógico	77
4.2.2	Filtro DWT Digital	78
4.2.3	Filtro FIR Digital	80
4.3	Geração dos Dados Experimentais - Curto-Circuito de Estator - Laboratório de Sistemas Inteligentes UTFPR	82
4.4	Geração dos Dados Experimentais - Barras Quebradas de Rotor - Laboratório de Sistemas Inteligentes UTFPR	84
4.5	Geração dos Dados Experimentais - Rolamentos - Laboratório de Máquinas Elétricas UVa	86
4.6	Geração dos Dados Experimentais - Rolamentos - Laboratório de Sistemas Inteligentes UTFPR	88
4.7	Estruturas de Classificação	90
4.8	Considerações Finais	93

5 Resultados Experimentais 95

5.1	Resultados de Classificação - Falhas de Curto-Circuito de Estator	95
5.1.1	Classificações de Curto-Circuito de Estator - Filtro Analógico	96
5.1.2	Classificações de Curto-Circuito de Estator - Filtro Digital	101
5.1.3	Comparativo entre Filtro Analógico e Filtro Digital - Falhas de Curto-Circuito de Estator	104
5.2	Resultados de Classificação - Falhas de Barras Quebradas de Rotor	107
5.2.1	Classificações de Barras Quebradas de Rotor - Filtro Analógico	107
5.2.2	Classificações de Barras Quebradas de Rotor - Filtro Digital	111
5.2.3	Comparativo entre Filtro Analógico e Filtro Digital - Falhas de Barras Quebradas de Rotor	115
5.3	Resultados de Classificação - Falhas de Rolamentos - Laboratório de Sistemas Inteligentes	117
5.3.1	Classificações Rolamentos - Filtro Analógico	118
5.3.2	Classificações de Falhas de Rolamentos - Filtro Digital	122
5.3.3	Comparativo entre Filtro Analógico e Filtro Digital - Falhas de Rolamentos	125
5.4	Resultados de Classificação - Falhas de Rolamentos - Laboratório de Máquinas Elétricas UVa	128
5.5	Multiclassificador de Falhas	132
5.5.1	Multiclassificador de Falhas - Filtro Analógico	132
5.5.2	Multiclassificador de Falhas - Filtro Digital	136

5.5.3	Comparativo entre Filtro Analógico e Filtro Digital - Multiclassi- ficação de Falhas	140
5.6	Considerações Finais	142
6	Conclusões	147
6.1	Perspectivas para Trabalhos Futuros	149
6.2	Produção Científica	149
	Referências	153

Introdução

Os motores de indução trifásicos (MIT) são amplamente utilizados em grande parte das aplicações industriais devido à sua construção simples, robustez, elevada confiabilidade, e mais recentemente devido à possibilidade de emprego de inversores de frequência, em que diferentes estratégias de controle eficientes podem ser aplicadas nestas máquinas (BELLINI et al., 2008). Assim, estas máquinas estão presentes em muitas aplicações nos mais diversos processos industriais (SUETAKE; SILVA; GOEDTEL, 2011; TRAN et al., 2013).

A operação de motores alimentados por inversores de frequência desempenha um papel cada vez mais essencial em uma ampla variedade de aplicações industriais. Como resultado, o monitoramento preditivo de condições operacionais associadas com o diagnóstico de falhas, prevenção contra problemas indesejados e predição de possíveis danos futuros devem ser devidamente compreendidos (KARABADJI et al., 2014). Desta forma, o desenvolvimento de unidades de monitoramento das condições de um MIT tornou-se um componente essencial em unidades industriais (FAIZ; GHORBANIAN; EBRAHIMI, 2012a; SESHADRINATH; SINGH; PANIGRAHI, 2014).

Na indústria, muitos processos requerem variações de velocidade, ocasionando significativas alterações no perfil de acionamento de cargas ao longo da última década. Assim, busca-se o aumento da eficiência energética, da qualidade de energia elétrica, do cumprimento de requisitos legais, bem como na geração de benefícios aos próprios usuários. Nesse cenário encontram-se os acionamentos em corrente alternada (CA), em que o MIT associado ao inversor de frequência possibilitam a aplicação de diversas estratégias de controle além de aumentar a proteção do motor (SESHADRINATH; SINGH; PANIGRAHI, 2014).

Com o avanço das tecnologias na área de eletrônica de potência, a participação do inversor de frequência em acionamentos industriais tem crescido com o passar dos anos, uma vez que os mesmos podem apresentar proteção contra sobretensão/subtensão, sobrecorrente, sobrecarga no motor, falhas de curto-circuito nas saídas além de proteção contra sobretemperatura (FAIZ; GHORBANIAN; EBRAHIMI, 2012b). Desta forma, as aplicações envolvendo este dispositivo vêm ganhando espaço frente aos acionamentos de corrente

contínua (CC), uma vez que estes apresentam elevado custo de manutenção devido às suas características de comutação.

Os acionamentos utilizando inversores de frequência atualmente são parte integrante de vários processos produtivos devido às suas características de regulação de velocidade, rápida resposta dinâmica além de possibilitar a incorporação de esquemas de controle direto do torque.

Assim, mesmo robustas, as aplicações com velocidade variável estão sujeitas à maioria dos problemas das aplicações com velocidade constante, tais como falhas de curto-circuito nos enrolamentos de estator, barras quebradas de rotor e defeitos nos rolamentos. Contudo, existem fatores adicionais tais como o surgimento de harmônicos além da geração de calor adicional causados por frequências de chaveamento e ondas estacionárias, dentre outros, que podem prejudicar o sistema de isolamento do motor reduzindo assim sua vida útil.

Os trabalhos de Seshadrinath, Singh e Panigrahi (2014) e Seera et al. (2014) mostram que o diagnóstico de falhas em MIT acionados por inversores de frequência tem atraído a atenção de vários pesquisadores nos últimos anos.

Por outro lado, os acionamentos alimentados por inversores de frequência também podem influenciar de forma positiva na vida útil do motor, uma vez que a partida suave permite eliminar os altos esforços da partida nos enrolamentos estatóricos e nas barras do rotor, os quais são fortemente solicitados no caso de motores diretamente conectados na rede elétrica. Portanto, o monitoramento preditivo das condições de operação associado ao diagnóstico de falhas, prevenindo quebras indesejadas e principalmente alertando contra possíveis danos futuros deve ser adequadamente compreendido.

Embora estes motores sejam usualmente bem construídos e robustos, a possibilidade de falhas é inerente à operação do dispositivo. Defeitos incipientes dentro da máquina geralmente afetam seu desempenho antes mesmo que falhas significativas ocorram, trazendo assim, prejuízos ao processo industrial. A aplicação de metodologias de diagnóstico confiável permite a manutenção eficaz e consequente redução de custos operacionais (LEE et al., 2014).

Assim, neste trabalho é abordado o problema do diagnóstico e a classificação de múltiplas falhas em MIT, os quais são acionados por inversores de frequência e estão sujeitos aos mesmos problemas/defeitos de um motor acionado diretamente pela rede elétrica.

A literatura descreve que a indicação de falhas em MIT alimentados por inversores de frequência é influenciada principalmente pela dinâmica de controle e pelas operações em diferentes níveis de carga conforme os trabalhos de Bellini et al. (2008), Nussbaumer, Stojicic e Wolbank (2011) e Duque-Perez et al. (2012).

Inseridos neste contexto, os Sistemas Inteligentes (SI) têm sido utilizados na identificação e resolução de diversos problemas relacionados ao controle e acionamento de máquinas elétricas sendo capazes de classificar e determinar a origem de falhas ainda

em sua fase prematura (MUTHUSELVAN; DASH; SOMASUNDARAM, 2006; SAYOUTI et al., 2011). O objetivo principal destas pesquisas consiste na utilização de técnicas inteligentes como ferramenta complementar aos métodos tradicionais de manutenção preditiva para identificação precoce de falhas. Desta forma, tem-se em muitos casos as intervenções planejadas, aumentando assim a disponibilidade e a confiabilidade das máquinas e dos processos industriais.

Trabalhos recentes apresentam avanços na pesquisa de técnicas relacionadas ao diagnóstico de falhas utilizando ferramentas inteligentes, conforme observado nas pesquisas de Abu-Rub et al. (2010), Chen et al. (2011), Santos, Silva e Suetake (2012), Aydin, Karakose e Akin (2012) e Suetake (2012). Muitos pesquisadores têm sugerido uma série de técnicas de diagnóstico de falhas incluindo modelagem, sistemas especialistas e sistemas de confiabilidade, como pode ser visto em Gandhi, Corrigan e Parsa (2011a), Duque-Perez, Morinigo-Sotelo e Perez-Alonso (2011), Georgakopoulos, Mitronikas e Safacas (2011), Trabelsi, Boussak e Chaari (2012), Duque-Perez et al. (2012) e Faiz, Ghorbanian e Ebrahimi (2012a). Todos estes métodos apresentam suas próprias vantagens e satisfazem algumas necessidades práticas, no entanto, é essencial que estes sistemas incorporem as habilidades de monitorar as condições de operação em tempo real. Desta forma, o objetivo de classificar os diferentes tipos de falhas e suas evoluções é tema de pesquisas recentes, bem como uma necessidade do setor industrial.

Assim, a contribuição deste trabalho pode ser resumida na apresentação de uma estratégia alternativa aos métodos tradicionais baseados em SI para o diagnóstico e a multiclassificação de falhas em MIT acionados por modelos distintos de inversores de frequência. Isto é realizado por intermédio do monitoramento das amplitudes dos sinais de correntes no domínio do tempo, usando a forma de onda para classificar falhas de curto-circuito de estator, barras quebradas do rotor e a evolução de uma falha de rolamentos. Um total de 13.574 ensaios experimentais realizados em motores de 0,74 e 1,47 kW, operando em regime permanente, foram realizados em uma ampla faixa de frequência (12 a 60 Hz), sob condições de carga ($10\% < T_n < 110\%$), onde T_n é o conjugado nominal. A discretização do sinal de corrente permite reduzir a elevada dimensão dos vetores de entrada traduzindo a informação necessária sem descaracterizar a forma de onda. A metodologia empregada leva a um diagnóstico das condições dos MIT, incluindo a detecção de defeitos incipientes e o correto diagnóstico da máquina.

O trabalho também compara o desempenho de quatro técnicas de aprendizado supervisionado de máquina: (i) a Rede *Fuzzy Artmap* (FAM); (ii) Máquina de Vetores de Suporte/Otimização Mínima Sequencial (SVM/SMO); (iii) k -Vizinhos-Próximos (k -NN); (iv) e a utilização da rede *Perceptron* Multicamadas (PMC). Os resultados obtidos a partir dos ensaios experimentais confirmam que a multiclassificação de defeitos, que trata-se de uma necessidade da indústria, pode ser adequadamente avaliada por meio da abordagem proposta neste trabalho, independentemente da frequência de operação do motor ou

condições de carga mecânica, que não influenciam os resultados da medição. Além disso, esta metodologia pode ser aplicada a motores diretamente acionados na rede elétrica.

1.1 Justificativa

O setor industrial brasileiro consome 33,9% de toda energia elétrica produzida no país, em que aproximadamente 68% da energia consumida no referido setor é utilizada em sistemas motrizes (EPE, 2014). Este fato evidencia a importância do MIT nas mais diversas aplicações industriais. Assim, os estudos relacionados à eficiência energética, qualidade de energia, técnicas de manutenção, técnicas de controle e o correto dimensionamento das máquinas e seus sistemas de acionamentos são de grande relevância em função da necessidade de atendimento a requisitos legais, bem como geração de benefícios à sociedade.

No Brasil, a aplicação de recursos com a manutenção preditiva nos últimos 10 anos passou de 16,48% para 18,82% do total investido em manutenção. Já na manutenção corretiva, por sua vez, constata-se a redução de 32,10% para 30,86% dos investimentos, sendo que a estimativa do custo total da manutenção em função do faturamento bruto foi de 4,69% (ABRAMAM, 2013).

A detecção e a correta classificação precoce de falhas incipientes conferem agilidade à atividade de manutenção, além de eliminar paradas não programadas de processo. Como consequência tem-se um baixo tempo de inatividade do processo e consequente manutenção dos níveis de produtividade, o qual é um fator essencial para sobrevivência da indústria moderna. Uma abordagem possível para minimizar esses problemas consiste na incorporação de métodos e equipamentos que utilizem técnicas de processamento de sinais para extração de características específicas dos sinais de falhas, seguidos pelo emprego de uma técnica adequada para classificação do tipo de falha na máquina em operação. No entanto, deve-se considerar aspectos relacionados ao baixo esforço computacional e principalmente a eficiência de classificação para que seja possível a implementação em sistemas reais.

De acordo com Santos (2013), dentre as principais vantagens no uso de SI, destaca-se a simplicidade na sua implementação computacional, tornando possível o diagnóstico de falhas ainda em origem de evolução, dispensando o conhecimento do modelo do sistema. Assim, o monitoramento das condições de operação de um MIT possibilitando o diagnóstico de falhas e a previsão das suas condições de operação, são fatores que têm atraído a atenção de vários pesquisadores durante os últimos 20 anos (BELLINI et al., 2008), (ONDEL et al., 2009), (AYDIN; KARAKOSE; AKIN, 2012). Tal fato se deve à considerável influência do MIT sobre a continuidade operacional de muitos processos industriais em função de sua robustez e baixo custo.

1.2 Objetivos

Os objetivos gerais deste trabalho consistem na investigação, desenvolvimento, implementação e validação das abordagens baseadas em SI para o diagnóstico e a multiclassificação de falhas em motores de indução acionados por inversores de frequência.

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

- ❑ Estudar o estado da arte em relação às técnicas inteligentes utilizadas na identificação e predição de falhas em motores elétricos trifásicos alimentados por inversores de frequência;
- ❑ Adaptar a bancada de ensaios para emular, de forma experimental, diversos tipos de falhas em MIT acionados por diferentes modelos de inversores de frequência;
- ❑ Realizar um estudo comparativo entre técnicas inteligentes, tais como Redes Neurais Artificiais (RNA), Lógica Fuzzy (LF) e outras técnicas inteligentes aplicadas à identificação e predição de falhas em motores elétricos de indução trifásicos operando em regime não-senoidal;
- ❑ Disponibilizar um banco de dados experimentais com medidas de grandezas elétricas e mecânicas nas mais diversas condições de falhas em uma ampla faixa de frequências, e, sob diversas condições de conjugado de carga;
- ❑ Projetar estratégias baseadas em SI para identificação de falhas de rotor, estator e rolamentos em motores de indução acionados por inversores de frequência.

Neste contexto, a proposta desta tese visa apresentar estratégias alternativas aos métodos tradicionais baseada em SI para diagnóstico e a multiclassificação de falhas no enrolamento de estator, barras quebradas de rotor e rolamentos em MIT acionados por modelos distintos de inversores de frequência, monitorando as amplitudes dos sinais das correntes no domínio do tempo, utilizando diretamente a forma de onda para classificar as falhas. Para a obtenção dos dados, foram realizados 13574 ensaios experimentais relativos às falhas de curto-circuito de estator, barras quebradas de rotor e rolamentos em motores de diferentes potências, em regime permanente, em uma ampla a faixa de frequências e conjugado de carga. A alta dimensionalidade dos vetores de entrada nos algoritmos foi resolvida por meio da discretização do sinal, capaz de traduzir as informações necessárias sem descaracterizar a forma de onda, diminuindo assim a complexidade computacional de classificação. Desta forma, busca-se diagnosticar o estado do motor, o qual inclui a detecção de falhas incipientes além de prever o modo de operação do MIT.

1.3 Contribuições

A proposta deste trabalho busca contribuir com as pesquisas na área de detecção de falhas dos MIT acionados por inversores de frequência. Assim, objetiva-se minimizar os custos de manutenção e paradas no processo a partir da detecção de falhas ainda em seu estágio inicial, justificando o monitoramento em tempo real, com as seguintes abrangências:

- ❑ Investigar a robustez das técnicas de identificação de falhas em MIT de diferentes potências operando em regime não-senoidal em uma ampla faixa de operação de 12 - 60 Hz, sob diferentes condições de carga, em regime permanente, a partir de dados extraídos da corrente trifásica de estator no domínio do tempo;
- ❑ Gerar um amplo banco de dados relativo a MIT acionados por inversores de frequência, gerado a partir da aquisição e tratamento dos dados experimentais;
- ❑ Apresentar uma contribuição ao estudo e caracterização de falhas de estator, rotor e rolamentos em MIT alimentados por inversores de frequência usando SI validados a partir de sinais obtidos diretamente da máquina;
- ❑ Identificar os algoritmos inteligentes que possam conduzir a melhores resultados no diagnóstico e classificação de falhas definidas no escopo desta tese;
- ❑ Apresentar a multiclassificação de falhas elétricas e mecânicas em MIT acionados por inversores de frequência, que se trata de uma necessidade real da indústria;
- ❑ Investigar aspectos relacionados à influência da taxa de amostragem na aquisição de sinais de corrente em MIT acionados por inversores de frequência;
- ❑ Implementar um sistema adaptativo como suporte para o diagnóstico e a identificação de falhas em MIT acionados por inversores de frequência de modo a possibilitar tomadas de decisão propiciando o aumento da disponibilidade e confiabilidade de operação dos mesmos.

1.4 Organização do Trabalho

Os próximos capítulos desta tese estão organizados da seguinte forma:

- ❑ No Capítulo 2 são revisados os principais trabalhos relacionados ao diagnóstico e identificação de falhas em MIT acionados por inversores de frequência, bem como tratadas as principais falhas em motores elétricos, com foco em falhas de estator, rotor, rolamentos além de falhas no inversor.

- ❑ O Capítulo 3 resume os conceitos fundamentais das técnicas inteligentes utilizadas neste trabalho e apresenta a Transformada Wavelet, utilizada como método alternativo de filtragem dos sinais de corrente estatóricas.
- ❑ No Capítulo 4, de forma sistemática, são discutidos os aspectos relacionados à geração das falhas e a apresentação dos parâmetros utilizados para aplicação das metodologias propostas para construção e avaliação da abordagem proposta.
- ❑ No Capítulo 5 são apresentados e discutidos os resultados com dados experimentais obtidos a partir dos algoritmos de classificação para validação da proposta.
- ❑ Finalmente, no Capítulo 6 as conclusões finais do trabalho e as perspectivas futuras são apresentadas.

Aspectos Relacionados às Falhas em Motores de Indução Trifásicos

Neste capítulo são apresentados trabalhos de autores que investigam o diagnóstico e a classificação de falhas incipientes em MIT acionados por inversores de frequência (BELLINI et al., 2008; WOLBANK et al., 2011; DUQUE-PEREZ et al., 2012), assim como trabalhos envolvendo classificações de falhas no próprio inversor (ESPINOZA-TREJO et al., 2012; TRABELSI; BOUSSAK; CHAARI, 2012). Neste contexto, são abordadas ainda as publicações que utilizam os métodos baseados nos conceitos de SI, além de outras metodologias disponíveis na literatura especializada (WANG et al., 2012; SEERA et al., 2013; SEERA et al., 2014; DAS et al., 2014; SESHADRINATH; SINGH; PANIGRAHI, 2014).

2.1 Falhas em Motores de Indução Alimentados por Inversores de Frequência

Nas aplicações de velocidade relativamente constante os MIT podem ser acionados diretamente pela rede elétrica, na qual os sinais de tensão e corrente são funções senoidais. No entanto, nos casos em que a variação de velocidade é requerida, o acionamento pode ser realizado com auxílio dos inversores de frequência, que regulam a velocidade do rotor, controlando a tensão e a frequência de alimentação da máquina. A utilização dos inversores de frequência no acionamento do MIT possibilita aplicações em escala industrial de forma crescente e confiável (GOUVEA, 2005). Neste caso, as tensões da rede apresentam-se ao motor em uma forma não-senoidal.

Acionamentos alimentados por inversores de frequência influenciam de forma positiva na vida útil do motor. Um exemplo é a partida suave, uma das características deste tipo de acionamento, a qual permite eliminar os altos esforços da partida nos enrolamentos estatóricos e barras do rotor, que são fortemente solicitados no caso de acionamentos diretos na rede elétrica (WEG, 2009). Neste tipo de acionamento existem fatores adicionais, tais

como o surgimento de harmônicos, geração de calor adicional causados por frequências de chaveamento e ondas estacionárias, dentre outros, que podem prejudicar o sistema de isolamento do motor, reduzindo assim sua vida útil (YAHIA et al., 2012). Assim, neste trabalho, será abordado o problema do diagnóstico e classificação de falhas em motores elétricos, os quais são acionados por inversores de frequência e estão sujeitos às mesmas falhas de um motor conectado diretamente na rede.

Muitas pesquisas baseadas em sistemas inteligentes buscam soluções para o diagnóstico de falhas em máquinas elétricas. Estas falhas envolvem desde problemas elétricos, como curto-circuito nos enrolamentos do estator até problemas mecânicos, como falhas nos rolamentos (BACCARINI, 2005), (ARAÚJO et al., 2010), (GEORGAKOPOULOS et al., 2010), (CHEN et al., 2011) (SANTOS; SILVA; SUETAKE, 2012) e (SUETAKE, 2012). O objetivo principal destas pesquisas é a identificação precoce de falhas incipientes, evitando paradas não-programadas por meio de métodos preditivos para diagnóstico de falhas. A correta aplicação destas ferramentas preditivas permite o aumento da confiabilidade e da disponibilidade das máquinas em processos industriais (SIQUEIRA, 2005).

Em Seera et al. (2012), o diagnóstico e a detecção de falhas em MIT utiliza o perfil do sinal de corrente do motor. Tais técnicas utilizam uma combinação de métodos de monitoramento das condições elétricas e mecânicas da máquina. O monitoramento da assinatura de corrente é frequentemente implementado com menor custo em máquinas de diferentes tamanhos e potências devido a sua fácil medição mediante a utilização de transformadores de corrente, dispensando a instalação de sensores adicionais. Ainda, de acordo com o trabalho de Seera et al. (2012), problemas relacionados à qualidade de energia elétrica, cujo conteúdo harmônico é resultante da alimentação de cargas não lineares, pode influenciar na análise dos dados das correntes e ser interpretado como falhas mecânicas.

O trabalho de Ondel et al. (2009) cita que as pesquisas de monitoramento e diagnóstico de falhas se direcionam para inspeção da corrente de estator. Este método utiliza sensores de baixo custo para identificar falhas elétricas e mecânicas em motores de indução. Neste contexto, o artigo de Ondel et al. (2009) apresenta um método de diagnóstico utilizado para detectar e localizar falhas no conjunto inversor-motor. O método utiliza uma técnica para reconhecimento de padrões, em que estes são classificados e comparados com outros padrões de referências coletados em classes (*clusters*), efetuando assim a supervisão do processo inversor-motor, de forma a integrar algumas especificidades que permitem diferenciar automaticamente falhas no inversor ou na máquina de indução.

Os trabalhos de Thorsen e Dalva (1994) e Bellini et al. (2008), permitem comparar a evolução da distribuição de falhas em MIT durante as décadas de 1990 e 2000. Um comparativo entre a porcentagem de falhas apontadas por esses dois artigos está apresentado na Tabela 2.1.

Estes resultados confirmam que mais de 70% das causas de falhas em MIT estão locali-

Tabela 2.1 – Comparação entre porcentagens de falhas em motores elétricos

	Porcentagem de Falhas	
	(THORSEN; DALVA, 1994)	(BELLINI et al., 2008)
Rolamento	51,07%	69%
Estator	15,76%	21%
Anéis/Barras de Rotor	4,70%	7%
Eixo/Acoplamento	2,44%	3%
Falhas externas	15,58%	-
Falhas não especificadas	10,45%	-

Figura 2.1 – Tipos de falhas

zadas respectivamente nos rolamentos, estator e rotor, sendo que as falhas de rolamentos respondem por um percentual superior a 50% das falhas em MIT. Assim, os motores elétricos estão sujeitos a vários tipos de falhas, que podem ser divididas em três grupos distintos: i) falhas elétricas, ii) falhas mecânicas e iii) falhas de componentes eletrônicos.

A literatura pesquisada não apresenta dados específicos da distribuição de falhas em motores acionados por inversores de frequência. No entanto, no trabalho de Bellini et al. (2008), os autores descrevem que a associação dos chaveamentos e harmônicos gerados pelos inversores causam estresse e consequente desgaste do sistema de isolamento. Em resposta a esta condição, alguns fabricantes disponibilizam motores que utilizam materiais de isolamento desenvolvidos especificamente para suportar este desgaste (WEG, 2009). A Figura 2.1 apresenta a classificação dos principais tipos de falhas em MIT.

O motor com falha apresenta indícios de defeitos de várias formas: mudanças nos sinais associados às vibrações mecânicas, variação na temperatura de operação, ruídos

audíveis e alterações no campo eletromagnético, dentre outras (ARAÚJO, 2011). Desta forma, a detecção de falhas pode ser feita por meio da utilização de técnicas de processamento de sinais para extração direta ou indireta das características dos sinais da corrente de alimentação de uma das fases ou da tensão elétrica conforme os trabalhos de Wolbank e Wohrnschimmel (1999), Chua et al. (2010) e Duque-Perez et al. (2012). De forma complementar, também podem ser consideradas as medidas de temperatura conforme Stiebler e Plotkin (2005), vibrações Yilmaz e Ayaz (2009) e Araújo et al. (2010), monitoramento de campo elétrico ou magnético Kim et al. (2008), Lee et al. (2010) e Kim et al. (2011) entre outros parâmetros.

Diversas são as metodologias aplicadas para a identificação de falhas em motores de indução trifásicos. As soluções propostas na literatura podem combinar o uso de métodos como a Transformada Wavelet Discreta (DWT - *Discrete Wavelet Transform*) ou o método de Análise de Assinatura de Corrente do Motor (MCSA - *Motor Current Signature Analysis*) na fase de extração das características dos sinais (CUSIDO et al., 2008; CHUA et al., 2010; DUQUE-PEREZ; MORINIGO-SOTELO; PEREZ-ALONSO, 2011). Cita-se ainda a aplicação de SI baseados em RNA, LF, Algoritmos Genéticos e os sistemas híbridos, para classificação das falhas (ONEL; AYCICEK; SENOLL, 2009; ABU-RUB et al., 2010; CHEN et al., 2011). Uma das principais vantagens no uso de SI refere-se à baixa complexidade computacional na implementação, permitindo determinar com precisão o tipo de falha sem a necessidade de implementar modelos matemáticos complexos (SANTOS; SILVA; SUETAKE, 2012).

2.2 Falhas Elétricas

Nesta seção são abordadas as pesquisas envolvendo o diagnóstico e classificação de falhas de natureza elétrica nos MIT. Na prática, as falhas elétricas encontradas na literatura são relacionadas ao estator e ao rotor.

Falhas no enrolamento de estator correspondem a aproximadamente 21% das causas associadas as paradas indesejadas de motores elétricos de acordo com Bellini et al. (2008), Thorsen e Dalva (1994), Gandhi, Corrigan e Parsa (2011a), e mais recentemente 36 à 40% segundo Barzegaran, Mazloomzadeh e Mohammed (2013), Zarei, Tajeddini e Karimi (2014), Drif e Cardoso (2014). As referidas falhas causam desequilíbrios que se refletem em alterações nas características, tais como: torque, fluxo de campo, correntes do estator, entre outros. Portanto, falhas nos MIT podem ser detectadas ao analisar estes sinais (GANDHI; CORRIGAN; PARSA, 2011b).

As falhas mais comuns associadas aos enrolamentos de estator são: curto-circuito entre fase-terra, fase-fase, curto-circuito entre as bobinas do mesmo enrolamento ou de diferentes fases (TRAN et al., 2013). A deterioração do isolamento do estator normalmente começa com um curto-circuito envolvendo poucas espiras, no entanto, sua evolução é rápida com-

prometendo o funcionamento do motor (BELLINI et al., 2008; GANDHI; CORRIGAN; PARSA, 2011a; DRIF; CARDOSO, 2014). A situação tende a se tornar ainda pior no caso de motores de indução acionados por inversores frequência (DAS et al., 2014).

De acordo com Baccarini et al. (2013) a corrente de curto-circuito é aproximadamente duas vezes a corrente de rotor bloqueado e provoca aquecimento localizado que rapidamente se estende para outros setores do enrolamento. Ainda, conforme Das et al. (2014), as falhas de isolamento entre espiras dos enrolamentos de estator ainda em estágio incipiente, caso não identificadas, podem evoluir causando danos irreversíveis ao motor.

As falhas de isolamento são atribuídas a diferentes razões, possuindo como causa principal as elevações térmicas excessivas (GANDHI; CORRIGAN; PARSA, 2011a), pois a temperatura no enrolamento das máquinas elétricas exerce importante influência para a vida útil do isolamento. De acordo com Stiebler e Plotkin (2005), um aumento de 10 °C acima do limite especificado reduz a vida útil prevista do motor para cerca da metade. Acionamentos em baixas faixas de frequência associados a elevados conjugados de carga favorecem a elevação da temperatura nos enrolamentos do motor e, conseqüentemente, a redução da sua vida útil.

Outras razões para a falha de isolamento incluem surtos de tensão, envelhecimento, vibrações, manuseio mecânico inadequado durante os procedimentos de manutenções, excesso de graxa durante a substituição de rolamentos danificados, além da inevitável degradação natural da isolação (STIEBLER; PLOTKIN, 2005; YANG et al., 2007; BRIZ et al., 2008; STOJCIC et al., 2012). O monitoramento deste tipo de falha é essencial, pois a detecção da falta ainda em seu estágio inicial de evolução permitirá que a máquina seja reutilizada após rebobinamento do estator (SUETAKE, 2012).

Dentre as falhas oriundas de rotor, a quebra das barras e as rachaduras nos anéis finais são responsáveis por aproximadamente 7% das falhas em MIT (BELLINI et al., 2008; THORSEN; DALVA, 1994). Esta classe de falha é caracterizada por vibração excessiva, ruídos e faiscamento durante a partida do motor. Tal falha não leva o motor à parada imediata; ou seja, a máquina pode continuar com seu funcionamento mesmo que haja barras quebradas ou trincadas. Entretanto, deve ser analisado o estado e a gravidade da barra quebrada, visto que a barra pode atingir o estator e romper o isolamento, causando assim um curto entre espiras ou até mesmo entre as fases (JUNIOR, 2008).

A barra quebrada tem impacto no conjugado, gerando uma diferença que possui modulação de duas vezes a frequência de escorregamento (BACCARINI, 2005). De maneira geral, as falhas elétricas nos MIT podem ser originadas de problemas internos da máquina bem como consequência de problemas relacionados a distúrbios de qualidade de energia na rede externa que alimenta o motor.

2.2.1 Falhas de Estator

A seguir são apresentados alguns trabalhos da literatura relacionados à investigação de falhas de estator em motores alimentados por inversores de frequência, com foco nas diversas formas pelas quais são realizadas as extrações das características de falhas, bem como a estratégia de diagnóstico empregada para a classificação.

Em máquinas de indução trifásicas a temperatura do enrolamento pode indicar uma possível falha no estator. Assim, no trabalho de Stiebler e Plotkin (2005) é proposto um método *on-line* para monitoramento da temperatura dos enrolamentos de MIT alimentado por um inversor frequência. O método se fundamenta na injeção de um pulso DC (*Direct Current*) na tensão do estator e usando o método da resistência e dispensando dispositivos externos.

Um outro aspecto a ser analisado nas falhas de estator consiste na análise do material ferromagnético do estator. No artigo de Lee et al. (2010) é proposto um método de monitoramento da qualidade do núcleo do estator para máquinas alimentadas por inversores de frequência. O conceito principal consiste em utilizar o inversor para aplicar um conjunto de sinais de teste para avaliar a qualidade do núcleo por intermédio da aplicação de um campo magnético pulsante de alta-frequência.

No trabalho de Wolbank e Wohrnschimmel (1999) a detecção *on-line* de falhas nos enrolamentos de estator de MIT alimentado por um inversor de frequência é feita por meio da reconstrução da corrente de estator. Os constantes chaveamentos da fonte de tensão dos inversores contribuem para o aumento da temperatura e consequente desgaste do isolamento dos enrolamentos favorecendo assim a ocorrência de falhas de estator.

Em Yang et al. (2007), foi proposta a aplicação de testes de tensão, com o auxílio do inversor de frequência para avaliar a degradação do isolamento do estator em MIT. Estes testes são executados quando o motor não está em funcionamento.

Ainda o trabalho de Drif e Cardoso (2014) propõe o diagnóstico de falhas de estator em motores alimentados tanto de forma direta na rede quanto por inversores de frequência. Os autores propõem a comparação da análise de assinatura de ambas potências instantâneas ativa e reativa obtidas por intermédio das medidas de corrente e tensão, no domínio da frequência.

Métodos computacionais têm sido amplamente estudados para o diagnóstico e classificação de falhas em máquinas elétricas (WANG et al., 2012; SEERA et al., 2014), e os mesmos são capazes de classificar e determinar a origem de falhas ainda em evolução (SEERA et al., 2013; DAS et al., 2014).

Tendo por base as técnicas de processamento de sinais pode-se citar o artigo de Barendse e Pillay (2007) que aborda o conceito de identificação de falhas por meio da análise das correntes durante o regime transitório da máquina utilizando Wavelet. Contudo, o algoritmo de detecção desenvolvido requer que o motor esteja operando com um nível de carga mínima de aproximadamente 30% em relação a carga nominal.

Uma outra técnica para determinação de falhas em estator é fundamentada em componentes fundamentais simétricas. Em Briz et al. (2008) o diagnóstico de falhas é efetuado a partir da injeção de uma portadora de sinal de tensão em alta frequência. Medidas dos resultados da portadora do sinal (componentes de corrente de sequência-negativa e sequência-zero) mostraram-se capazes de identificar as falhas ainda em estágio inicial de evolução.

No trabalho de Dlamini e Barendse (2012), a detecção de falhas entre as espiras do enrolamento de estator de um motor alimentado por inversores de frequência é realizada mediante a análise harmônica da assinatura de corrente do estator. Os autores analisam o motor operando à vazio, com 50% e 100% de conjugado de carga nominal, nas frequências de 30, 50 e 60 Hz, utilizando uma baixa taxa de amostragem para aquisição dos sinais, e posteriormente, interpolando os sinais. Os autores mostram que a confiabilidade das componentes de falhas é afetada pelo nível de severidade da falha e pelas condições de carga sob diferentes frequências de operação.

Muito embora as RNAs e a LF individualmente se apresentem como potenciais candidatos para a solução de várias abordagens e aplicações de reconhecimento de padrões, os sistemas híbridos que combinam a junção destas duas técnicas têm sido investigados no reconhecimento e classificação de padrões de falhas em MIT devido à sua grande adaptabilidade e também devido à sua excelente capacidade de generalização (AMARAL et al., 2007; CHEN et al., 2011; GANDHI; CORRIGAN; PARSA, 2011a).

No artigo de Amaral et al. (2007) é apresentado um sistema ANFIS (*Adaptive Neuro Fuzzy Inference System*) para o diagnóstico de falhas de estator a partir da identificação de características dos vetores das correntes de linha obtidas a partir da transformação das correntes trifásicas de estator para um sistema equivalente de duas fases. O algoritmo propõe um método de reconhecimento de padrões para a identificação de falhas, em que as características são obtidas por meio de processamento de imagens as quais são as entradas do classificador neuro-fuzzy.

Recentemente, Barzegaran, Mazloomzadeh e Mohammed (2013) desenvolveram um método para diagnóstico de falhas de curto-circuito nos enrolamentos de estator por intermédio da utilização de sinais magnéticos, utilizando o método numérico de elementos finitos e RNA.

O trabalho de Das et al. (2010) apresenta resultados experimentais para o monitoramento de pequenas falhas de curto-circuito no enrolamento do estator do motor de indução. A corrente de linha do motor foi analisada utilizando técnicas de processamento de sinais e ferramentas de redução de dados, combinando a transformada de Park e a transformada Wavelet contínua. A técnica SVM foi utilizada para a caracterização de falhas com base nas características de falhas extraídas utilizando a transformada Wavelet.

Em Tran et al. (2013) foi desenvolvida uma aplicação baseada na análise do sinal de corrente durante o regime transitório da máquina. Os sinais de corrente são decompostos

em componentes individuais por meio da expansão Fourier-Bessel, seguido pela aplicação de análise discriminante generalizada para reduzir a alta dimensionalidade das características originais do sinal. Finalmente, utiliza-se o classificador SFAM (*Simplified Fuzzy ARTmap*) para a identificação das condições do motor. Os autores realizaram ainda um estudo comparativo com o método SVM.

Em Seshadrinath, Singh e Panigrahi (2014), a investigação das assinaturas dos sinais de vibração é utilizada para o diagnóstico de múltiplas falhas em motores acionados por inversores de frequência, combinando a transformada Wavelet com os classificadores SVM e k -NN.

Assim, tem-se nesta subseção algumas das possíveis técnicas para implementação de sistemas de identificação e monitoramento de falhas de estator. De uma forma geral, o diagnóstico é efetuado a partir do monitoramento das assinaturas de corrente de estator, mediante métodos não-invasivos de aquisição. A seguir, são apresentados alguns trabalhos relacionados a identificação de falhas em rotor.

2.2.2 Falhas de Rotor

O estudo e o diagnóstico de barras quebradas em MIT têm despertado o interesse cada vez maior dos pesquisadores. Motores de indução trifásicos com gaiola de esquilo apresentam vantagem em relação aos motores de indução com rotor bobinado, pois além de não existir contato elétrico o sistema é mais robusto, confiável e apresenta custo reduzido de aquisição (JUNIOR, 2008). Assim, nesta seção, são apresentados trabalhos relativos à investigação e à estratégia de diagnóstico de falhas de rotor em motores alimentados por inversores de frequência.

Diversos trabalhos na literatura apresentam a abordagem no domínio da frequência para determinação das falhas de rotor. Entre elas pode-se citar o trabalho de Cusido et al. (2008) o qual propôs a combinação das técnicas de densidade espectral de potência e a transformada Wavelet para detecção de barras quebradas de rotor e curto-circuito entre as espiras do estator. O autor concluiu que a análise da assinatura de corrente por meio da utilização da FFT não apresenta bons resultados quando a velocidade e o torque de carga da máquina não são constantes, devido às variações no escorregamento do motor.

Em Duque-Perez et al. (2010), a detecção de barras quebradas de rotor é avaliada em função das características do espectro de frequência dos harmônicos introduzidos pela fonte de alimentação de um inversor. No referido artigo, um motor de indução foi testado utilizando uma fonte de alimentação programável. O estudo demonstrou a possibilidade de utilizar o conteúdo harmônico para monitoramento de um motor alimentado por um inversor que filtre uma determinada faixa de frequências ou que injete harmônicos específicos na forma de onda de alimentação.

No artigo de Georgakopoulos et al. (2010) é estudada a detecção de falhas de rotor de um motor de indução acionado por um inversor com controle escalar V/f . O espectro das

correntes de estator e de alimentação do inversor são avaliados para as componentes de frequência devido às falhas. Por intermédio da análise do espectro da corrente de entrada do inversor é possível detectar e classificar a severidade das falhas. Ainda, em Georgakopoulos, Mitronikas e Safacas (2011), a investigação e a classificação de falhas de barras quebradas de rotor em um motor de indução alimentado por inversor de frequência é feita por meio da análise do espectro da corrente de alimentação. O método foi desenvolvido para controle em malha aberta com frequência variável; ou seja, aplicações de baixo custo em que não é necessário o controle de velocidade.

Em Yahia et al. (2012) foi experimentalmente estudada a capacidade do método tradicional de análise da assinatura de corrente do motor para o diagnóstico de barras de rotor quebradas em um motor alimentado por inversor de frequência em diferentes velocidades e níveis de carga. Os resultados experimentais mostraram que o diagnóstico adequado é muito difícil para baixas velocidades.

Em Faiz, Ghorbanian e Ebrahimi (2012b), é feita uma revisão dos métodos de diagnóstico de falhas em motores de indução alimentados por inversor de frequência comparado a um motor conectado diretamente na linha. Os coeficientes de controle de acionamento, velocidade e torque de referência, a largura de banda do controlador e a carga do motor são os fatores que exercem influência sobre a amplitude dos índices de detecção de falhas. Independentemente do tipo de acionamento, o sinal de corrente do estator é recomendado como sendo o sinal de monitoramento mais apropriado para obter as condições de operação do motor. No caso de motores acionados por inversor, algumas componentes do sinal também podem ser utilizadas para a detecção de falhas. No entanto, a combinação dos sinais de tensão e de corrente do motor são apropriados para o diagnóstico de falhas neste tipo de acionamento.

No trabalho de Cristaldi et al. (2009) é apresentado um algoritmo para monitoramento e identificação *on-line* de falhas de rotor em um motor de indução trifásico acionado por inversor de frequência de pequeno porte por intermédio da análise da corrente no domínio do tempo. Os sinais utilizados foram adquiridos diretamente pelos sensores de monitoramento da corrente instalados na saída do inversor.

Já o trabalho Chua et al. (2010) utiliza um algoritmo híbrido de análise no domínio do tempo-frequência para detecção de barras quebradas de rotor e falhas de rolamentos em motores de indução alimentados por inversor de frequência. Para a extração dos sinais de corrente no domínio do tempo é utilizado o método de Análise de Componente Independente (ICA - *Independent Component Analysis*) combinando com os sinais extraídos por meio da transformada rápida de Fourier (FFT - *Fast Fourier Transform*). Para o monitoramento, é utilizado um sistema Fuzzy que combina a informação obtida no domínio do tempo com o método MCSA.

Uma outra abordagem para a detecção de falhas em rotores de máquinas alimentadas por inversores de frequência é fundamentada na análise da reatância ou da impedância

do motor do ponto de vista do estator. Em Kim et al. (2011) é apresentada uma técnica automática para detecção de falhas do rotor em máquinas de indução alimentadas por inversor de frequência. O conceito principal consiste em utilizar a fonte de tensão do inversor para excitar a máquina com um campo pulsante em várias posições angulares visando observar a variação no padrão de impedância devido às barras quebradas do rotor, quando o motor está parado sem a necessidade de instrumentação adicional.

No artigo de Wolbank et al. (2011) é apresentado um estudo para detecção de barras quebradas de rotor em motores de indução trifásicos alimentados por inversor de frequência sem carga e com velocidade zero. Para o diagnóstico, são considerados os sinais de corrente medidos diretamente pelos sensores de monitoramento de corrente da fonte de alimentação presentes no inversor. A aplicação de uma excitação com pulsos de tensão utilizando o chaveamento do inversor e com base nas medidas de decaimento da corrente resultante os autores do referido artigo identificam a assimetria induzida pela falha nas reatâncias da máquina.

Já no artigo de Nussbaumer, Stojicic e Wolbank (2011) os autores propõem uma abordagem para detecção de falhas em barras de rotor para todas as condições de operação mediante à aplicação de um pulso especial de tensão utilizando o chaveamento do inversor e identificando a reação das correntes. Assim é possível calcular a distribuição espacial do transiente de reatância da máquina, que pode ser utilizado como um indicador de falhas. Para eliminar a influência das condições de carga, uma estratégia de compensação utilizando RNA é apresentada.

Ainda, em Kim e Seok (2011) é apresentada uma abordagem não-paramétrica para o diagnóstico de falhas em barras de rotor por meio da captura de sinais de alta frequência das componentes de falhas de barras quebradas de rotor em motores de indução alimentados por inversor de frequência no domínio do tempo. O modelo mostra que a resistência equivalente do motor pode ser utilizada como um indicador direto de barras quebradas de rotor.

O uso de transformadas tem-se mostrado uma alternativa para a avaliação do estudo das barras de rotor. Pode-se citar o artigo de Garcia-Escudero et al. (2011) que apresenta a detecção prematura de barras quebradas de rotor em motores de indução alimentados por inversores de frequência a qual é realizada mediante a análise da densidade espectral da corrente de linha. Uma técnica de multirresolução utiliza a transformada Wavelet para extrair características importantes do espectro de corrente e gráficos de controle multivariados para monitorar as características extraídas do espectro de falhas.

Já no trabalho de Faiz, Ghorbanian e Ebrahimi (2012a) é descrito um critério para o diagnóstico de falhas de barras quebradas de rotor em motores alimentados com inversores de frequência utilizando a extração do valor de energia da transformada Hilbert-Huang na corrente de falha do motor.

Em Chen et al. (2011) há a utilização de um sistema neuro-fuzzy aliado a filtragem de

partículas de alta ordem para o diagnóstico e a evolução das condições de operação com base no histórico de falhas da máquina.

Recentemente, o trabalho de Duque-Perez et al. (2012) apresenta a análise estatística dos dados espectrais de um motor de indução alimentado por um inversor de frequência a qual é utilizada no desenvolvimento de um sistema especialista para o monitoramento de falhas. Foram utilizados 2 tipos distintos de alimentação: direta e alimentação por meio de inversores de frequência, sendo observado que em ambos os casos a análise da assinatura de corrente do motor apresentou resultados válidos. As análises estatísticas mostraram que o primeiro pico superior da banda lateral é o mais adequado para ser utilizado como uma assinatura de falha.

No trabalho de Takbash, Faiz e Ebrahimi (2013) uma metodologia analítica é proposta para estimar perdas no núcleo de motores de indução acionados diretamente na rede elétrica ou alimentados por inversor de frequência sob condições de rotor com barras quebradas. As perdas são calculadas levando-se em conta os efeitos da distribuição não senoidal da densidade de fluxo magnético e do aumento da amplitude de componentes de banda lateral das correntes de estator, devido às barras quebradas, para calcular as perdas ôhmicas com precisão.

Em Zhu et al. (2014) é proposta a utilização do sinal da corrente harmônica de alimentação do inversor para o diagnóstico de barras quebradas em motores de indução trifásicos, operando a vazio e em regime permanente. A contribuição do método refere-se à extração da envoltória do sinal de corrente de alimentação utilizando a transformada Hilbert, construção do sinal analítico com base no quadrado da envoltória e então executar a análise do espectro do sinal com a FFT. Ainda, o estudo de Maouche et al. (2014) investiga as falhas de barras quebradas por meio da análise FFT dos espectros das potências instantâneas nos seis terminais de um motor alimentado por inversor de frequência.

Esta subseção mostra a relevância do tema, evidenciada pelo elevado número de trabalhos envolvendo o diagnóstico e a classificação de falhas de rotor em motores alimentados por inversores de frequência. Diversas são as técnicas utilizadas tanto na fase de extração das características do sinal de falha, quanto na sua correta classificação. Observa-se ainda a preocupação com os aspectos relacionados à redução do esforço computacional aplicado, visando implementação em tempo real.

2.3 Falhas Mecânicas

Nesta seção serão abordados os trabalhos relacionados ao diagnóstico e a classificação de falhas de origem mecânica em MIT. De acordo com a literatura, as principais falhas mecânicas são relacionadas a rolamentos e a excentricidade.

Dentre as diversas causas de falhas em MIT, as classificadas como problemas de rolamentos são responsáveis por 50% à 70% das causas associadas a paradas indesejadas

de motores elétricos (BELLINI et al., 2008; THORSEN; DALVA, 1994; GANDHI; CORRIGAN; PARSA, 2011a). A origem destas falhas estão comumente associadas às assimetrias rotóricas, mas podem também ser oriundas dos anéis internos, dos anéis externos ou dos elementos girantes do rolamento (SUETAKE, 2012). As correntes induzidas circulantes nos rolamentos por meio dos mancais, devido ao chaveamento dos inversores, também contribui para falhas de rolamentos (MUETZE; BINDER, 2007). O desenvolvimento e a evolução deste tipo de falha ocorre principalmente devido à vibração, desgaste interno, desalinhamento do eixo, excentricidade, corrente no rolamento, poeira, corrosão, lubrificação inadequada, além da sua montagem incorreta (BACCARINI, 2005; ONEL; AYCICEK; SENOLL, 2009; ARAÚJO et al., 2010; SANTOS; SILVA; SUETAKE, 2012).

A excentricidade é uma folga desigual entre o estator e o rotor, comum nos MIT. Falhas por excentricidade são relacionadas ao desalinhamento do eixo de rotação do motor com o centro do estator e pode ser causada pela ovalização do núcleo estatórico e pelo posicionamento incorreto do rotor ou estator durante o processo de montagem. Também são consideradas causas de excentricidade as operações em condições de velocidades críticas e rolamentos danificados ou mal posicionados durante a montagem (BACCARINI, 2005; SUETAKE, 2012).

Além das falhas de rolamentos e de excentricidade, as falhas mecânicas também contemplam as situações de desalinhamento, desbalanceamento e folga mecânica. O monitoramento de falhas mecânicas é da mais alta relevância, pois, o mesmo tem influência direta no desempenho da máquina (ONEL; AYCICEK; SENOLL, 2009; ARAÚJO, 2011). Desta forma, observa-se que o entendimento adequado das técnicas de medição, e seus efeitos sobre os parâmetros de monitoramento podem garantir o aumento na vida útil tanto da máquina quanto das suas partes acopladas.

2.3.1 Falhas de Rolamentos

O rolamento é constituído principalmente pela pista externa, a pista interna, as esferas (elementos rolantes) e a gaiola, a qual é a responsável pelo ajuste da distância entre as esferas. O rolamento é o principal componente dos MIT associados a falhas e consequentes paradas indesejadas de processo. Falhas neste componente podem ser diagnosticadas de forma não-invasiva por intermédio do monitoramento quantitativo de variáveis como vibração, corrente, temperatura, velocidade entre outros (BELLINI et al., 2008; YILMAZ; AYAZ, 2009; ABU-RUB et al., 2010; ARAÚJO, 2011). Especificamente, no caso dos MIT acionados por inversores de frequência, a deterioração dos rolamentos podem ser associadas às correntes de modo comum, que circulam pelos rolamentos em função da carga eletrostática induzida no eixo do motor, as oscilações de conjugado devido às barras quebradas no rotor ou em função dos harmônicos de corrente de baixa ordem (MUETZE; BINDER, 2007; ARAÚJO, 2011).

No artigo de YANG, Yi-long e GONG (2001) são descritos os efeitos do parasitismo capacitivo em motores quando alimentados por inversores de frequência. Dentre as principais faltas relacionadas com o parasitismo destacam-se a queima de enrolamentos, o desgaste prematuro dos rolamentos, o surgimento de correntes de fuga com o terra e as distorções harmônicas de corrente.

As contribuições dos harmônicos na assinatura das correntes de falha causados em acionamentos utilizando inversores de frequência em MIT são tratados no artigo de Akin et al. (2007). De acordo com os autores, a assinatura de falha causada pelos harmônicos do inversor é similar e comparável àquelas geradas pelo harmônico fundamental da corrente de linha. A permeabilidade analítica e as oscilações na densidade de campo são derivadas das falhas de rolamentos. Estas relações são utilizados para determinar as assinaturas de falha para máquinas alimentadas por inversores.

Outro fenômeno associado a falhas de rolamentos são as correntes induzidas em função da característica de chaveamento dos inversores. No trabalho de Muetze e Binder (2007) são discutidas técnicas de modelagem matemática para medição dos diferentes parâmetros de importância para o rolamento, avaliação de danos e os seus efeitos sobre os fenômenos e as grandezas medidas. Os autores classificam as diferentes correntes geradas pelo inversor nos rolamentos em: pequenas correntes capacitivas de rolamento (consideradas desprezíveis); correntes de descarga no rolamento, também conhecidas como usinagem de descarga elétrica (EDM - *Electrical Discharge Machining*); circulação de correntes de alta frequência no rolamento; e finalmente, as correntes de rolamento devido às correntes de terra do rotor. Os dois primeiros tipos de correntes estão relacionadas com a influência da tensão de modo comum. Já as duas últimas são causadas pela interação da tensão de modo comum com as correntes de alta frequência.

Outra técnica alternativa é apresentada no trabalho de Akin et al. (2008), em que é feito o estudo dos efeitos das harmônicas injetadas por inversor de frequência na assinatura de corrente dos motores de indução. É mostrado de forma teórica e experimental que as assinaturas de falhas causadas pelos harmônicos do inversor são comparáveis àquela gerada pela harmônica fundamental da corrente de linha. Assim, analiticamente foram obtidas relações de falhas de rolamentos e excentricidade.

Estratégias baseadas em sistemas inteligentes também têm sido aplicadas na identificação de falhas de rolamentos. No artigo de Yilmaz e Ayaz (2009) é utilizado um sistema composto por três modelos ANFIS para detecção de falhas de rolamentos em motores de indução tendo como entradas para cada modelo os dados de corrente, vibração e temperatura. Individualmente, o modelo ANFIS que utiliza os dados de vibração apresentou os melhores resultados. No entanto, quando utilizadas as três assinaturas em conjunto ocorre um aumento significativo na performance de detecção do método.

Ainda no trabalho de Abu-Rub et al. (2010) é utilizado um modelo ANFIS para o diagnóstico de falhas incipientes de rolamentos em motores de indução trifásicos acionados

por inversores de frequência por meio de simulações. Como entradas foram consideradas a distorção harmônica total do espectro de corrente do estator, a velocidade da máquina e as condições de carga.

Em Onel, Aycicek e Senoll (2009) é descrita a utilização de uma rede de Funções de Base Radial (*Radial Basis Function* - RBF) para detecção automática de falhas de rolamentos em um motor alimentado por um inversor de frequência utilizando a transformada Concordia.

Também são utilizadas as abordagens baseadas na análise de vibração para a determinação de falhas em rolamentos. Entre estas pode-se citar o trabalho de Araújo (2011), em que é apresentada uma análise das possíveis causas de falhas prematuras em rolamentos dos MIT acionados por inversores, contextualizada no estudo de um caso real. As causas potenciais de defeito foram inicialmente tratadas de forma teórica e, num segundo momento, avaliadas experimentalmente, por meio da aquisição e análise de dados de vibração, corrente de estator e correntes de modo comum. Concluiu-se que a presença de correntes de modo comum, nos níveis verificados, é capaz de conduzir os rolamentos do motor à sua falha.

Devido à relevância deste componente no contexto de falhas, as pesquisas direcionam o diagnóstico de forma não-invasiva por meio do monitoramento de variáveis como vibração, temperatura, e especialmente mediante os sinais de corrente associados a sistemas inteligentes como ferramenta de suporte à identificação. Na sequência, são apresentados trabalhos relacionados a identificação de falhas de excentricidade.

2.3.2 Falhas de Excentricidade

Conforme informado na seção introdutória relativa a falhas mecânicas, a excentricidade é um fenômeno associado a uma folga desproporcional entre o estator e o rotor. A excentricidade pode ser classificada como estática, dinâmica ou mista. Na excentricidade estática, o centro de rotação do eixo é deslocado do centro original a uma distância que permanece fixa. Na excentricidade dinâmica, o centro de rotação permanece na posição original, mas o eixo é deslocado. Por outro lado, a excentricidade mista representa o centro e o eixo de rotação deslocados de suas respectivas posições de origem (SANTOS; SILVA; SUETAKE, 2012).

Devido à dinâmica de excentricidade do rotor, a densidade de fluxo magnético possui uma distribuição assimétrica produzindo uma força magnética desequilibrada. No trabalho de Kim et al. (2008) é proposta uma metodologia que utiliza a corrente, o espectro de vibração e a força eletromotriz que se opõe ao fluxo principal de corrente do circuito (*back EMF*). O diagnóstico utilizando sinais de vibração e de corrente é prejudicado pelos harmônicos de chaveamento, pois esta força eletromotriz produzida pelas bobinas é comparada para um rotor em condições normais e também sob excentricidade.

Em Morinigo-Sotelo et al. (2010) são apresentados os resultados de detecção de excentricidade estática e dinâmica em motores alimentados por inversores de frequência por intermédio da análise espectral da corrente de linha. Os autores sugerem que uma condição de monitoramento confiável tem como base a comparação das falhas relacionadas ao conteúdo harmônico de uma mesma fonte de alimentação e assinatura de frequência.

No trabalho de Duque-Perez, Morinigo-Sotelo e Perez-Alonso (2011) é apresentada uma proposta para diagnóstico de falhas de rotor e excentricidade em motores de indução alimentados por fontes de elevado conteúdo harmônico por meio da MCSA. O trabalho mostra que existem áreas do espectro de corrente de estator que são úteis para auxiliar no diagnóstico de falhas, principalmente em torno do 5° harmônico. Os autores também apresentam características sensíveis a falhas em áreas próximas ao 7° e 9° harmônicos.

No trabalho de Hong et al. (2012) os autores apresentam uma técnica para detecção de falhas de excentricidade em motores de indução alimentados por inversores de frequência, utilizando o inversor para excitar o motor com um pequeno pulso CA no campo sobreposto ao campo CC sempre que o motor encontra-se parado. Assim, a mudança no padrão de indutância comparável ao nível CC no campo diferencial é observada como um indicador da excentricidade, sem a necessidade de instalação de hardware adicional.

Dentre os trabalhos citados, na identificação de falhas de excentricidade observa-se a utilização de técnicas distintas em relação as usuais técnicas associadas aos outros tipos de falhas anteriormente discutidos neste capítulo. Na sequência, são apresentados trabalhos relacionados à identificação de falhas no inversor.

2.4 Detecção de Falhas no Inversor

O inversor de frequência é o dispositivo responsável pela variação da velocidade nos MIT. Conforme Santos, Silva e Suetake (2012), tendências tecnológicas e teóricas apontam a investigação do uso de inversores para notificação de falhas de origem interna e externa aos MIT. Nesta seção, são apresentados alguns trabalhos encontrados na literatura que tratam a análise de falhas em inversores de frequência.

Um método para o diagnóstico de falhas de chaveamento em inversores baseado em um algoritmo C-ANFIS é proposto no artigo de Park et al. (2004), baseado na transformação dos sinais de corrente no eixo d-q. Para tanto, foram obtidas as características das trajetórias das correntes de fase d-q para cada modo de falha. Neste estudo não foram considerados elementos tais como torque de carga e parâmetros das variáveis elétrico-mecânicas. O modelo proposto foi facilmente construído utilizando dados de entrada/saída sem a necessidade de modelagem da informação, possibilitando assim a redução do número de regras fuzzy e o tempo de aprendizagem.

Em Guan, Sun e He (2007) é apresentado um método *on-line* para diagnóstico de falhas em inversores que alimentam motores de indução com base na análise de agrupa-

mento subtrativo do vetor corrente do estator e um método de cálculo rápido do vetor de corrente média. Visando comprovar a efetividade do algoritmo para o diagnóstico de falhas, em modo *off-line*, foram analisados os vetores de corrente em condições normais e em condições de falhas do inversor. Para determinar os modos de falhas foram utilizadas as diferentes amplitudes e os ângulos obtidos por meio do agrupamento dos vetores de correntes médias. Os resultados de simulação mostraram que as falhas em inversores podem ser detectadas por volta de 1/4 do período da frequência fundamental.

Já no trabalho proposto por Espinoza-Trejo et al. (2012) o diagnóstico de falhas de circuito-aberto em inversores de frequência que alimentam motores de indução é efetuado com base na perspectiva da dinâmica não-linear do motor de indução por meio das medidas de corrente de estator e velocidade mecânica. Para tal, utilizam-se observadores proporcional-integral não-lineares, permitindo identificar a componente CC dos perfis de falhas.

Por outro lado, o trabalho de Trabelsi, Boussak e Chaari (2012) aborda o diagnóstico de falhas de circuitos abertos em inversores de frequência combinando as informações resultantes das correntes de linha distribuídas no eixo α - β , derivadas dos seus valores médios normalizados. A partir da normalização dos valores médios das correntes de linha é possível identificar falhas simples além de distinguir falhas múltiplas com base na análise das assinaturas do eixo de referência α - β .

Muito embora os inversores sejam um componente adicional no processo de geração de falhas internas e/ou externas aos MIT, os trabalhos apresentados na literatura relatam a importância da sua presença nos sistemas de diagnóstico de falhas em motores elétricos (TRIGEASSOU, 2011). A disponibilidade de processadores digitais e sensores utilizados neste dispositivo abrem caminho para novas perspectivas de investigação e proteção inteligente em motores acionados por inversores de frequência.

2.5 Conclusões Sobre a Revisão da Literatura

Os acionamentos elétricos modernos são comumente formados pela combinação de motores elétricos acionados por meio de inversores de frequência. Conforme Santos, Silva e Suetake (2012) diversos trabalhos fazem referência à crescente presença de inversores nos sistemas de detecção e diagnóstico de falhas nos MIT. Assim, a detecção e diagnóstico de falhas em tais sistemas constituem um objetivo relevante em todas as aplicações industriais, uma vez que podem melhorar a produtividade.

Os inversores de frequência mitigam impactos elétricos na rede e mecânicos na carga, possibilitam economia de energia além da automação de sistemas, que pode ser aprimorada com a associação de sistemas inteligentes operando em uma hierarquia superior. No entanto, os motores acionados por inversores de frequência além das exigências de carga e ambiente ainda são submetidos a consideráveis estresses de tensão devido às altas taxas

de chaveamento dos dispositivos semicondutores.

Da revisão da literatura conclui-se que a maioria das pesquisas relacionados à classificação e diagnóstico de falhas em MIT acionados por inversores de frequência está concentrada em falhas elétricas de estator. Este tipo de falha é agravada pelos constantes chaveamentos da fonte de tensão dos inversores. Tem-se um aumento excessivo da temperatura dos enrolamentos os quais desgastam o isolamento e favorecem ocorrência de falhas além reduzir a vida útil da máquina.

Os métodos tradicionais de análise dos sinais para identificação de falhas em MIT acionados por inversores de frequência apresentam limitações devido ao mascaramento da assinatura da falha que é influenciada pela dinâmica de controle e também pelas alterações de carga. Para minimizar esta limitação, alguns trabalhos mais recentes direcionam a análise por meio da densidade espectral da corrente de linha.

Assim, neste trabalho apresenta-se a proposta de um multiclassificador inteligente capaz classificar falhas incipientes de estator, rotor e rolamentos ainda em fase de evolução em MIT acionados por inversores de frequência. Ainda no contexto desta tese, destacam-se sua contribuição no desenvolvimento contínuo de outras pesquisas e proposição de métodos alternativos para o diagnóstico de falhas na área de máquinas elétricas.

O Capítulo 3 descreve de forma resumida os conceitos gerais dos algoritmos inteligentes FAM, SVM/SMO, k /NN e MLP, bem como a TWD utilizada como filtro digital, utilizados para o desenvolvimento deste trabalho.

Estratégias de Classificação

3.1 Introdução

Métodos computacionais têm sido amplamente aplicados ao diagnóstico e classificação de falhas (WANG et al., 2012; SEERA et al., 2013; BARZEGARAN; MAZLOOMZADEH; MOHAMMED, 2013) e os mesmos são capazes de classificar e determinar com sucesso a origem de falhas ainda em evolução (SESHADRINATH; SINGH; PANIGRAHI, 2014; SEERA et al., 2014; TRAN et al., 2013; ZAREI; TAJEDDINI; KARIMI, 2014; DAS et al., 2014). O diagnóstico pode ser resumido como o processo de identificar e determinar a relação de causa e efeito, em que a sua função consiste em isolar e identificar falhas, bem como suas possíveis causas (BACCARINI; MENEZES; CAMINHAS, 2010; GEORGAKOPOULOS et al., 2010; CHEN et al., 2011; SEERA et al., 2014).

Neste trabalho, visando identificar algoritmos inteligentes que apresentem melhor robustez para a multiclassificação de falhas em MITs alimentados por diferentes modelos de inversores de frequência, são analisados os métodos de classificação FAM, SVM/SMO, PMC e k -NN, para o diagnóstico e a classificação de falhas. Os ensaios realizados combinam a variação do torque de carga e uma ampla faixa de frequência de alimentação da máquina, tendo como entrada para os métodos de classificação os dados das amplitudes das correntes de estator no domínio do tempo. Todas as técnicas inteligentes são comparadas com os mesmos conjuntos de amostras provenientes dos ensaios experimentais, a fim de as caracterizar em falhas de estator, rotor e rolamentos de motores de indução trifásicos, operando em regime permanente.

A classificação de padrões trata de uma forma de analisar os dados extraíndo modelos que descrevam importantes classes características de dados (HAN; KAMBER; PEI, 2011). Uma breve descrição dos algoritmos abordados neste trabalho são apresentados nas subseções seguintes, bem como a Transformada Wavelet (TW), que é utilizada como ferramenta auxiliar na análise de falhas em motores elétricos (LEE et al., 2010; GARCIA-ESCUADERO et al., 2011; EBRAHIMI et al., 2012; SHI et al., 2014; SANTOS; SILVA; SUETAKE, 2013) entre outras aplicações.

Inicialmente, a rede FAM é apresentada, a qual consiste num sistema de aprendizagem supervisionada, capaz de auto-organizar o reconhecimento estável de categorias em respostas aos padrões de entrada arbitrários (CARPENTER et al., 1992). Estas arquiteturas foram baseadas na teoria da ressonância adaptativa (ART - *Adaptive Resonance Theory*) desenvolvida por Carpenter e Grossberg (1987), como uma possível solução para o dilema estabilidade-plasticidade (CARPENTER et al., 1992).

Uma outra abordagem utilizada neste trabalho é o algoritmo SVM/SMO, reconhecido na literatura como um método eficaz na solução de problemas que exigem classificação de padrões. Conforme consta na literatura, o SVM transforma os dados de treinamento para uma dimensão superior, onde se encontra um hiperplano que separa os dados por classe usando conjuntos essenciais de treinamento chamados vetores de suporte (HAN; KAMBER; PEI, 2011; DUDA; HART; STORK, 2001; BISHOP, 2006).

Na sequência, a rede neural PMC é apresentada. Em termos gerais, uma rede neural é um conjunto de unidades de entradas/saídas conectadas, na qual cada conexão possui um peso associado. Os pesos são ajustados durante a fase de treinamento para ajudar a rede na predição do correto rótulo de entrada (HAYKIN, 2008; SILVA; SPATTI; FLAUZINO, 2010).

A quarta estratégia denominada k -NN, que armazena todos os conjuntos de treinamento em um espaço padrão e aguarda a apresentação do conjunto de testes antes de executar a generalização (HAN; KAMBER; PEI, 2011; DUDA; HART; STORK, 2001). O algoritmo dos k vizinhos mais próximos (k -NN) é um método não-paramétrico, baseado na aprendizagem por analogia, ou seja, por meio da comparação de similaridades entre um determinado conjunto de teste com o seu respectivo conjunto de treinamento (HAN; KAMBER; PEI, 2011; DUDA; HART; STORK, 2001). Os conjuntos de treinamento são descritos por n atributos. Cada dado representa um ponto em um espaço n -dimensional, desta forma, todos os dados de treinamento são armazenados em um espaço padrão n -dimensional.

Finalmente, conceitos fundamentais sobre a TW, utilizada como filtro neste trabalho são apresentados. A TW possibilita a representação de um sinal no domínio tempo-frequência, permitindo a análise multirresolução de um sinal, que pode auxiliar na verificação de detalhes não evidenciados com o uso de técnicas usuais de processamento de sinais (MALLAT, 1999).

3.2 Rede *Fuzzy ARTmap*

A rede FAM consiste num sistema de aprendizagem supervisionada, capaz de auto-organizar o reconhecimento estável de categorias em respostas aos padrões de entrada arbitrários com plasticidade (CARPENTER et al., 1992). Estas arquiteturas foram baseadas na teoria da ressonância adaptativa (ART) desenvolvida por Carpenter e Grossberg

(1987), como uma possível solução para o dilema estabilidade-plasticidade (CARPENTER et al., 1992).

Durante a apresentação de novos padrões a um classificador neural, faz-se necessário adaptar os pesos da rede, adicionando uma nova parcela de conhecimento; ou seja, o sistema deve ser capaz de adquirir informação. Ao mesmo tempo, é preciso que o conhecimento acumulado referente aos padrões previamente apresentados seja mantido, ou seja, o classificador deve ser estável.

A rede neural FAM, bem como qualquer outra da família ART, permite obter soluções com rapidez de resposta e flexibilidade na inclusão de novos padrões, mudanças topológicas, etc. Assim, esta estrutura tem a capacidade de continuar a aprender após a inclusão de novos padrões, sem perder a memória relacionada aos padrões anteriores o qual caracteriza a plasticidade (CARPENTER et al., 1992).

A estrutura original de uma rede FAM engloba o treinamento simultâneo de dois módulos *Fuzzy ART*, para a associação de um padrão análogo no modo supervisionado: o *Fuzzy* e o ART. Cada um destes módulos é responsável por associar dois espaços vetoriais distintos, porém relacionados. Em problemas de classificação de padrões, um dos espaços é o denominado espaço dos rótulos, enquanto o outro é o espaço de entrada.

De acordo com Carpenter et al. (1992), o primeiro passo do treinamento da rede consiste na apresentação de cada padrão de entrada para a camada F_1^a . Esta camada é responsável por calcular a codificação complementar do padrão apresentado à rede. Ou seja, o pré-processamento na camada F_1^a transforma o vetor de entrada a de tamanho M em um vetor $I = (a, a^c)$ de tamanho $2M$, em que $a^c = (1 - a)$ é definido como o complemento de a . O vetor de ganhos sinápticos é inicializado $w_{jk} = 1$, onde $j = 1, \dots, N^a$ representa as N^a categorias da rede ART_a e $k = 1, \dots, 2M$ representa cada elemento que compõe os ganhos sinápticos de cada categoria. Além disso, os ganhos sinápticos do *Mapfield* são colocados também em 1 ($w_{jk}^{ab} = 1$). Após o processo de inicialização, o vetor A é enviado à camada F_1^a para que seja calculada a categoria ativa, por meio da função de escolha $T_j(I)$ que pode ser definida pela Equação 3.1:

$$T_j = \frac{|A \wedge w_j^a|}{\alpha + |w_j^a|} \quad (3.1)$$

em que $\wedge$ representa o operador mínimo e $\alpha > 0$ é o parâmetro de escolha, sendo este um pequeno valor positivo.

O processo de escolha é iniciado fazendo com que o maior valor para a função de escolha da categoria seja escolhido mediante do processo de competição (*winner takes all*) em que o vencedor leva tudo, conforme a Equação 3.2:

$$T_{venc} = \max \{T_j\}, j = 1, \dots, N^a \quad (3.2)$$

Após a escolha da categoria vencedora a verificação do critério de similaridade ou condição de ressonância deve ser realizada na camada F_1^a , conforme a Equação 3.3.

$$\frac{|A \wedge w_j^a|}{|A|} \geq \rho_a \quad (3.3)$$

onde ρ_a é o parâmetro de vigilância.

Se o teste da condição de ressonância falhar com a primeira categoria (vencedora), o mecanismo de *reset* é acionado e a categoria vencedora é inibida. Assim, a segunda categoria (segundo lugar) é selecionada e o processo de verificação da condição de ressonância é refeito. Se não for possível encontrar uma categoria que passe no teste de similaridade para o padrão apresentado, uma nova categoria pode ser criada e que inicialmente representa exclusivamente o padrão apresentado. Por outro lado, se a categoria promove uma ressonância com o padrão apresentado o processo de aprendizagem é acionado e as matrizes de peso são atualizadas conforme a Equação 3.4.

$$w_j^a(n+1) = (1 - \beta)w_j^a(n) + \beta(A \wedge w_j^a(n)) \quad (3.4)$$

onde $0 \leq \beta \leq 1$ é a taxa de aprendizado.

Um procedimento similar é realizado na ART_b , gerando N^b categorias que serão associadas às categorias da ART_a por meio do *mapfield* que é responsável por manter a associação de predição entre as categorias das duas redes ART_a e ART_b . Esse módulo implementa o mecanismo de *Match tracking* que promove um aumento do parâmetro de vigilância ρ_a em resposta a uma associação incorreta entre categorias das redes. O processo de treinamento termina quando as mudanças nos ganhos sinápticos permanecem inalteradas durante uma época de treinamento.

Neste trabalho, a rede FAM é comparada com outros métodos de classificação de padrões, tais como SVM/SMO, RNA e k -NN aplicados na identificação de falhas em motores acionados por diferentes modelos de inversores de frequência.

3.3 Máquina de Vetores de Suporte

A técnica SVM é uma metodologia de aprendizagem, que classifica os dados, denominados de padrões, em dois conjuntos (+1 e -1), por meio de um hiperplano separador, que possui margens denominadas de vetores suportes (PLATT, 1998).

Considera-se um conjunto de treinamento de N pontos $(x_i, y_i)_{i=1}^N$ com dado $x_i \in \mathbb{R}^n$, vetores de treinamento, e os correspondentes rótulos de classe $y_i \in (-1, +1)$. A ideia básica do SVM é mapear os dados de treinamento a partir do espaço de entrada em um espaço de características dimensionais maior via função Kernel, e, então construir um hiperplano de separação com margem máxima do espaço de características. O SVM pode ser formulado como um otimizador de programação quadrática que irá encontrar o peso

para o parâmetro w e para o parâmetro *bias* b . Estes dois parâmetros irão maximizar a margem, assegurando que as amostras de treinamento foram bem classificadas. Assim, o SVM calcula o hiperplano de separação ideal, resolvendo o seguinte problema de otimização conforme as Equações 3.5 e 3.6:

$$\frac{\min \|w^2\|}{2} + C \sum_{i=1}^n \xi_i \quad (3.5)$$

sujeito a:

$$\begin{aligned} y_i (w^t \varphi(x_i) + b) &\leq 1 - \xi_i \\ \xi &\geq 0, i = 1, \dots, N \end{aligned} \quad (3.6)$$

em que, $\xi \geq 0$, $i = 1, \dots, N$ são variáveis de folga utilizadas para reduzir o erro de classificação do conjunto de treinamento, o parâmetro de custo C é usado para ajustar a compensação entre a quantidade de erros aceitos e $\varphi(\cdot)$ é a função de transformação. Usando o Multiplicador de Lagrange $\alpha_i \geq 0$, $i = 1, \dots, N$ para resolver o problema de programação quadrática, obtém-se o seguinte problema de otimização denominado dual, dado pelas Equações 3.7 e 3.8:

$$\frac{\max \sum_{i=1}^n \alpha_i - \left(\sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j k(x_i, y_j) \right)}{2} \quad (3.7)$$

sujeito a:

$$\begin{aligned} \sum_{i=1}^n \alpha_i y_i &= 0 \\ 0 &\leq \alpha_i \leq C, i = 1, \dots, N \end{aligned} \quad (3.8)$$

Para a classificação de problemas não-lineares, os dados são primeiramente mapeados em um grande espaço de características dimensionais F pela função de transformação $\varphi \rightarrow \varphi(x) \in F \subset \mathbb{R}^p$. Assim, a função resultante de decisão é dada pela Equação 3.9:

$$f(x) = \text{sign} \left(\sum_{\alpha_i > 0} \alpha_i y_i k(x, x_i) + b \right) \quad (3.9)$$

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

O SVM é fundamentalmente um classificador de duas classes (PLATT, 1998) e (BISHOP, 2006). Assim, vários métodos foram propostos para combinar múltiplos SVMs a duas classes de forma a construir um classificador multiclass (BISHOP, 2006).

Uma das abordagens para treinamento do SVM trata-se da Otimização Mínima Sequencial (SMO) (PLATT, 1998), que leva o conceito de segmentação para o limite extremo e considera apenas dois multiplicadores de Lagrange de cada vez (BISHOP, 2006). Neste caso, o subproblema pode ser analiticamente resolvido, evitando a programação quadrática, resultante da dupla derivação do SVM (KANKAR; SHARMA; HARSHA, 2011).

O algoritmo SVM/SMO tem-se mostrado uma ferramenta promissora na classificação de falhas em máquinas elétricas (TRAN et al., 2013; SESHADRINATH; SINGH; PANIGRAHI, 2014). Neste trabalho, a técnica é usada para identificação de falhas de estator, rotor e rolamentos em máquinas acionadas por diferentes modelos de inversores de frequência.

3.4 Redes Neurais Artificiais

As RNA's são modelos computacionais inspirados no sistema nervoso de seres vivos para o processamento de informações paralelas. Tais modelos são uma composição simples de unidades de processamento interligadas entre si por conexões conhecidas como sinapses artificiais (HAYKIN, 2008).

As redes são modeladas matematicamente e tendem a imitar o processamento de informações por um neurônio cerebral humano, e, desta forma, adquirem a capacidade de aprendizagem e adequação do conhecimento.

O processamento das informações se dá por cálculos matriciais em que os valores apresentados como entradas $(x_1, x_2, \dots, x_n)$ são multiplicados por uma constante, conhecida como peso sináptico $(w_1, w_2, \dots, w_n)$. Estes novos valores, somados entre si, representam todas as informações externas que chegam ao neurônio. Assim, torna-se possível verificar que a saída do corpo celular artificial, denotada por (u) é a soma ponderada das suas entradas. Tal unidade, por sua vez, é processada por uma função de ativação $g(u)$, característica do neurônio e modelo da rede (SILVA; SPATTI; FLAUZINO, 2010). Desta forma, obtém-se uma resposta da rede já treinada, como observado na Figura 3.1.

Uma rede neural extrai seu potencial computacional máximo por meio de sua estrutura e sua habilidade de aprender e generalizar (HAYKIN, 2008), (HAN; KAMBER; PEI, 2011) e (DUDA; HART; STORK, 2001). Tais redes produzem saídas adequadas mesmo recebendo entradas que não estavam no processo de treinamento, assim podendo até interpretar falsas leituras sem alterar resultados. As RNAs podem ser empregadas para classificação de padrões, análise de séries temporais, mineração de dados, agrupamento de dados e estimação de resultados baseadas em um conhecimento previamente adquirido e em sua capacidade de generalização das situações (HAYKIN, 2008) e (SILVA; SPATTI; FLAUZINO, 2010).

O elemento básico de uma rede neural é o neurônio artificial apresentando na Figura 3.1, o qual também é conhecido como nó ou elemento de processamento. O neurônio artificial ilustrado na Figura 3.1 pode ser modelado matematicamente conforme as Equações 3.10 e 3.11:

$$y_j(k) = \sum_{i=1}^n x_i w_i + b \quad (3.10)$$

$$y_j(k) = g_j(y_j(k)) \quad (3.11)$$

Figura 3.1 – Representação do neurônio artificial

em que n é o número de sinais de entrada do neurônio; x_i é o i -ésimo sinal de entrada do neurônio; w_i é o peso associado com o i -ésimo sinal de entrada; b é o limiar relacionado com o neurônio; $v_j(k)$ é a resposta ponderada (soma da junção) do neurônio j -ésimo em relação ao instante k ; $g(\cdot)$ é a função de ativação do neurônio j -ésimo; $y_j(k)$ é o sinal de saída do j -ésimo neurônio em relação ao instante k .

A Figura 3.2 ilustra a estrutura da rede PMC utilizada neste trabalho, a qual foi treinada com o algoritmo *backpropagation* (HAYKIN, 2008). Este algoritmo de treinamento possui dois passos básicos: o primeiro é a propagação, que aplica os valores para as entradas da RNA e verifica o sinal de resposta na camada de saída. Este valor é então comparado com o sinal desejado para esta saída.

O segundo passo ocorre na forma inversa, ou seja, a partir da saída para a camada de entrada. O erro produzido pela rede é utilizado no processo de ajuste dos seus parâmetros internos (pesos e *bias*).

Figura 3.2 – Representação de uma rede PMC

O ajuste dos pesos de saída da rede (w_j) associados com o j -ésimo neurônio de saída é feito calculando o sinal do erro $e_j(k)$ associado a k -ésima iteração ou o k -ésimo vetor de entrada (exemplo de treinamento). Este sinal de erro é obtido pela Equação 3.12:

$$e_j(k) = d_j(k) - y_j(k) \quad (3.12)$$

em que $d_j(k)$ é a resposta desejada para o j -ésimo neurônio de saída. Adicionando todos os erros quadráticos produzidos pelos neurônios da saída da rede em relação à k -ésima

iteração, conforme a Equação 3.13:

$$E(k) = \frac{1}{2} \sum_{j=1}^p e_j^2(k) \quad (3.13)$$

em que p é o número de neurônios de saída.

Para uma configuração de peso ideal, $E(k)$ é minimizado em relação ao peso sináptico w_{ji} . Portanto, os pesos associados com a camada de saída da rede são atualizados por meio da relação definida pela Equação 3.14:

$$w_{ji}(k+1) \leftarrow w_{ji}(k) - \eta \frac{\partial E(k)}{\partial w_{ji}(k)} \quad (3.14)$$

em que w_{ji} é o peso que conecta o j -ésimo neurônio da camada de saída com o i -ésimo neurônio da camada anterior e η é uma constante que determina a taxa de aprendizado do algoritmo *backpropagation*.

Neste trabalho, o algoritmo PMC é usado para identificação de falhas de curto-circuito de estator, barras quebradas de rotor e defeitos de rolamentos em máquinas acionadas por diferentes modelos de inversores de frequência. No contexto de diagnóstico de falhas em máquinas elétricas o uso da RNA tem sido objeto de consideráveis pesquisas recentes (BARZEGARAN; MAZLOOMZADEH; MOHAMMED, 2013; SEERA et al., 2014; GERMEN; BASARAN; FIDAN, 2014).

3.5 k Vizinhos mais Próximos

O algoritmo dos k vizinhos mais próximos (k -NN) é um método não-paramétrico, baseado na aprendizagem por analogia, ou seja, por intermédio da comparação de similaridades entre um determinado conjunto de teste com o seu respectivo conjunto de treinamento (HAN; KAMBER; PEI, 2011; DUDA; HART; STORK, 2001). Os conjuntos de treinamento são descritos por n atributos. Cada dado representa um ponto em um espaço n -dimensional. Desta forma, todos os dados de treinamento são armazenados em um espaço padrão n -dimensional. Para um dado conjunto desconhecido, o classificador k -NN procura o espaço padrão para os k conjuntos de treinamento próximos ao conjunto desconhecido. Estes k conjuntos de treinamento são os k -vizinhos mais próximos deste conjunto desconhecido.

A proximidade é definida em termos de uma métrica de distância, tal como a distância Euclidiana. A distância Euclidiana entre dois pontos ou conjuntos de dados, $X_1 = (x_{11}, x_{12}, \dots, x_{1n})$ e $X_2 = (x_{21}, x_{22}, \dots, x_{2n})$, é dada pela Equação 3.15:

$$dist(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (3.15)$$

Ou seja, para cada atributo numérico, a diferença entre os valores correspondentes a X_1 e X_2 , eleva e acumula esta diferença. A raiz quadrada considera a contagem total da distância acumulada. A normalização $\min_A$ e $\max_A$, por exemplo, pode ser utilizada para transformar um valor v de um atributo numérico A para v' na faixa de $[0, 1]$, conforme a Equação 3.16:

$$v' = \frac{v - \min_A}{\max_A - \min_A} \quad (3.16)$$

em que, $\min_A$ e $\max_A$ são respectivamente, os valores mínimo e máximo do atributo A .

Para a classificação k -NN ao conjunto desconhecido é atribuída a classe mais comum entre seus k -vizinhos mais próximos. Quando $k = 1$, o conjunto desconhecido é atribuído à classe do conjunto de treinamento mais próxima do seu espaço padrão. O algoritmo possui apenas um parâmetro livre (o número de k -vizinhos) que é controlado pelo usuário visando obter uma melhor classificação (DUDA; HART; STORK, 2001).

3.6 Transformada Wavelet Discreta

Neste trabalho, a TWD é utilizada como uma alternativa aos filtros analógicos tradicionais, bem como métodos baseados na transformada Fourier que sofrem inconvenientes tais como a largura fixa da janela, além problemas relacionados à dispersão espectral e resolução, o que os torna inadequados para análise de sinais não-estacionários (CUSIDO et al., 2008; SESHADRINATH; SINGH; PANIGRAHI, 2014). Assim como no trabalho de Seshadrinath, Singh e Panigrahi (2014), a estratégia adotada nesta tese baseia-se em um modelo que faz a decomposição de sinais utilizando um banco de filtros do tipo wavelet.

A TWD é utilizada em diversas aplicações de processamento de sinais, tais como compressão de vídeo, reconhecimento de padrões, análise numérica (WEEKS, 2012), na análise de falhas em motores elétricos (LEE et al., 2010; GARCIA-ESCUADERO et al., 2011; EBRAHIMI et al., 2012; SHI et al., 2014) entre outras aplicações. Os trabalhos de Santos, Silva e Suetake (2013) e Schmitt et al. (2013) também com o propósito de diagnosticar falhas em motores elétricos por meio da análise do sinal de corrente utilizaram a família de wavelets Daubechies.

Esta transformada baseia-se na decomposição de um sinal entre versões deslocadas e escalonadas da Wavelet original, permitindo distintas resoluções de tempo e frequência (MALLAT, 1999). No processamento de sinais de multirresolução, são utilizados bancos de filtros, os quais resultam em uma transformação do sinal para o plano tempo-frequência (MALLAT, 1999). Assim, antes de descrever o modelo, apresenta-se uma breve descrição dos princípios da TWD e de banco de filtros.

Estes bancos de filtros são sistemas capazes de decompor os sinais em banda de frequência, e ainda, reconstruí-los com grande perfeição. Tais bancos são formados por filtros $L(z)$, passa-baixas, e $H(z)$, passa-altas. Assim, considerando uma taxa de aquisição igual

a 25000 amostras/s tem-se um sinal com 75.000 pontos, sendo possível obter coeficientes de aproximação e de detalhe, cada um com 37.500 pontos, respectivamente, como pode ser visualizado na Figura 3.3.

Figura 3.3 – Exemplo de uma decomposição por transformada Wavelet - Adaptado de (MALLAT, 1999)

A função destes filtros é separar o sinal em bandas de frequência de tamanho igual, isto é, fazer com que cada saída seja constituída da metade do conteúdo da frequência, porém, com a mesma quantidade de dados do sinal $x(k)$. Para isso, é aplicado o operador *downsampling* na saída dos filtros, fazendo com que os sinais sejam subamostrados por um fator de 2. Estes coeficientes resultantes, $y_l(k)$ e $y_h(k)$, são chamados de coeficientes wavelet e contêm os detalhes e as aproximações do sinal original; ou seja, representam as componentes de baixa e de alta frequência do sinal $x(k)$.

A TWD pode ser utilizada para realizar sucessivas decomposições das aproximações, de modo que um sinal é dividido em outras componentes de resolução menor, assim, é obtida a árvore de decomposição wavelet, como pode ser observado na Figura 3.4.

A Figura 3.4 ilustra três níveis da análise de multirresoluções. As saídas dos filtros $L(z)$ e $H(z)$ do terceiro nível aumentam a resolução do tempo e diminuem o conteúdo da frequência, caracterizando assim no aumento do tamanho da janela usada na análise dos coeficientes wavelet (MALLAT, 1999).

Já a reconstrução de um sinal utilizando os componentes wavelet é o processo inverso ao descrito anteriormente. Se todos os componentes são utilizados nesse processo, obtém-se novamente o sinal original. Este processo é realizado sobreamostrando cada coeficiente por um fator de 2, seguido de convolução com os filtros de reconstrução criados com os filtros de decomposição, $L(z)$ e $H(z)$ (MALLAT, 1999).

Figura 3.4 – Expansão de uma DWT em três níveis - Adaptado de (MALLAT, 1999)

Devido à sobreamostragem, os sinais reconstruídos têm o mesmo tamanho que o sinal original. Porém, é possível reconstruir um sinal com o mesmo número de amostras do sinal original, utilizando somente o coeficiente de aproximação que interessa ao sistema de identificação de falhas do motor. Assim, a partir do sinal de interesse, é obtido um sinal reconstruído sem ruídos, sem perda de características de falha e com o mesmo número de amostras do sinal original.

Assim como os trabalhos de Ebrahimi et al. (2012), Shi et al. (2014), Seshadrinath, Singh e Panigrahi (2014), no contexto desta tese, a importância da eficiente representação dos sinais faz com que a TW se torne uma ferramenta muito útil no processamento e filtragem dos sinais corrente dos MITs alimentados por inversores de frequência.

3.7 Considerações Finais

Foram apresentados neste Capítulo os tópicos referentes a técnicas inteligentes FAM, SVM/SMO, MLP e k -NN, bem como suas arquiteturas e processos de treinamento. Assim, a motivação pela utilização destes algoritmos deve-se ao fato de que trabalhos apresentados na literatura relacionada a classificadores multi-classes apontaram vantagens destas estratégias sobre a estatística tradicional e outros métodos de classificação inteligente aplicados no diagnóstico e classificação de falhas em motores elétricos (GANDHI; CORRIGAN; PARSA, 2011b; TRAN et al., 2013; DAS et al., 2014; LEE et al., 2014; BACCARINI et al., 2013; SEERA et al., 2014; SESHADRINATH; SINGH; PANIGRAHI, 2014).

Desta forma, fica evidenciada a possibilidade de um processamento de informações por meio de técnicas inteligentes para a resolução de problemas ligados à classificação de padrões de falhas em motores elétricos.

No Capítulo 4 são detalhados os aspectos relacionados à reprodução de falhas em laboratório, aquisição, rotinas de tratamento, bem como aspectos relativos à definição dos parâmetros empregados nos algoritmos inteligentes visando atingir os melhores índices de multiclassificação.

Metodologia

Neste capítulo são descritos os principais componentes utilizados no processo de aquisição experimental dos dados utilizados na implementação do sistema de classificação de falhas em MIT alimentados por inversores de frequência. A Figura 4.1 ilustra a estrutura geral de desenvolvimento do trabalho, que será discutida neste Capítulo. São abordados ainda, os aspectos gerais relacionados à metodologia de inserção das falhas, bem como a descrição dos procedimentos de tratamento e discretização dos sinais das correntes trifásicas de estator, utilizadas como entradas dos classificadores inteligentes.

Figura 4.1 – Estrutura geral de desenvolvimento do trabalho

4.1 Bancada Experimental de Ensaio

Os dados experimentais utilizados neste trabalho foram coletados da bancada de ensaios experimentais do Laboratório de Sistemas Inteligentes da Universidade Tecnológica Federal do Paraná - Campus Cornélio Procópio (UTFPR) e também a partir da bancada montada no Laboratório de Máquinas Elétricas da Universidade de Valladolid - Espanha (UVa).

4.1.1 Bancada Experimental - Laboratório de Sistemas Inteligentes UTFPR

A bancada do laboratório de Sistema Inteligentes foi projetada para o monitoramento da tensão, da corrente, da vibração, do torque e da velocidade de um motor de indução trifásico. As placas de condicionamento de sinais dos sensores *Hall* condicionam as tensões de fase e correntes de linha que são repassadas às entradas analógicas da placa de aquisição de dados.

Figura 4.2 – Bancada experimental do laboratório de Sistemas Inteligentes da UTFPR: (1) Variadores de Tensão, (2) Carga da Máquina CC, (3) Gerador de Corrente Contínua, (4) Torquímetro, (5) Sensor de Vibração, (6) Motor de Indução, (7) *Display* do Torquímetro, (8) Contator para Geração Automática de Curto-Circuito de Estator, (9) Placa de Aquisição, (10) Fonte CC, (11) Inversor Schneider ATV12H075M2, (12) Inversor Siemens Sinamics G110 e (13) Inversor Siemens Micromaster 440

As falhas de estator, rotor e rolamento, foram coletadas na bancada experimental do Laboratório de Sistemas Inteligente da Universidade Tecnológica Federal do Paraná - Campus Cornélio Procópio. A configuração da bancada possibilita efetuar simulação

das condições de funcionamento dos motores, tais como: alimentação direta ou utilização de inversores de frequência, variação na tensão de alimentação para motores alimentados diretamente na rede, variação na carga e operação com defeitos controlados.

A configuração da bancada de ensaios está na Figura 4.2, a qual dispõe de um motor de indução acoplado a um gerador de corrente contínua de 2 kW de potência, 250 V de tensão nominal de campo e 250 V de tensão nominal de armadura, que faz a imposição do conjugado no eixo do motor. Ainda é possível observar os variadores de tensão independentes por fase utilizados para o desbalanço das tensões.

As placas de condicionamento de sinal utilizam sensores de efeito *Hall*, que estabelecem as informações de alimentação da máquina por uma corrente induzida de baixa amplitude, reproduzindo os sinais senoidais.

Os sinais de corrente e tensão são medidos no painel de alimentação da máquina, em que placas individuais monitoram a corrente de linha e a tensão de fase, observada na Figura 4.3. O sinal de -10 V a 10 V disponibilizado pelas referidas placas são dados de entrada da Placa de Aquisição de Dados (PAD) em canais analógicos.

Figura 4.3 – Placas de condicionamento de sinais dos sensores *Hall*

Através da interface de comunicação com um computador, provida pela PAD, as informações de sinais são recebidas e armazenadas por meio do *software Matlab®* em forma de planilhas. Os dados são identificados por data, número de aquisição, e a condição de defeito do motor sob análise.

A PAD utilizada neste processo é da *National Instruments™* modelo *USB 6221*, a qual dispõe de 16 entradas analógicas (16-bit 250 kS/s) e permite a comunicação simplificada com o computador por meio de cabo USB.

A bancada conta ainda com um torquímetro de dupla faixa de atuação com sensor de velocidade integrado. O dispositivo da marca *Kistler*, modelo 4503A50W, permite a leitura de sinais analógicos ou digitais até 50 N.m e 7000 rpm. Juntamente com os demais sinais de monitoramento do motor, estes são disponibilizados para arquivamento, análise

e processamento. Uma descrição detalhada da bancada pode ser encontrada em Goedel (2007).

4.1.2 Bancada Experimental - Laboratório de Máquinas Elétricas UVa

Com base no convênio interinstitucional entre a Universidade de São Paulo/São Carlos e a UVa/Valladolid, foram realizados experimentos controlados visando estimar a evolução de uma falha de rolamento em ambiente de laboratório na instituição espanhola.

A configuração da bancada de ensaios é mostrada na Figura 4.4, em que um motor de indução (Motor 5) alimentado de forma direta ou por um inversor de frequência (Allen Braddley - Power Flex 40 ou WEG - CFW08 Plus), acoplado a um freio magnético Telemecanic para realização de ensaios a vazio e também em condições de plena carga.

Para a coleta dos dados de tensões e correntes de linha foram empregadas placas de condicionamento de sinal utilizando sensores de efeito *Hall* (LEM), e uma PAD modelo PCI-6250 M (16 entradas analógicas - 16-bit 1 MS/s) da *National Instruments*TM. A taxa de aquisição considerada para todos os testes foi de 25.000 amostras/s, e um tempo de aquisição de 25 segundos, considerando desde o regime transitório até o permanente. Para medir a velocidade foi utilizado um sensor óptico Datalogic modelo S60-PA-5-W08-NH.

Figura 4.4 – Bancada experimental do laboratório de Máquinas Elétricas da UVa: (1) Motor de indução, (2) Freio magnético, (3) Sensor de óptico, (4) Placa de Aquisição, (5) Inversor Allen Braddley e (6) Inversor WEG

4.1.3 Banco de dados

Para a criação do banco de dados utilizado neste trabalho foram geradas informações dos motores operando em condições sem defeito e em condições de defeitos de curto-circuito de estator, barras quebradas de rotor e rolamentos. Foram analisadas e armazenadas variáveis elétricas e mecânicas tais como: torque, velocidade, tensões e correntes.

As características básicas dos motores utilizados neste trabalho estão descritas na Tabela 4.1. No laboratório de Sistemas Inteligentes da UTFPR, para os ensaios de curto-circuito de estator foram utilizados os Motores 1 e 2 da linha *standard* e os Motores 3 e 4 da linha de alto rendimento para os ensaios de barras quebradas de rotor e rolamentos. Já o Motor 5, do fabricante AEG, foi utilizado para os ensaios de desgaste de rolamento realizados no Laboratório de Máquinas Elétricas da UVa.

Tabela 4.1 – Características dos motores utilizados no trabalho

Parâmetros	Motor 1	Motor 2	Motor 3	Motor 4	Motor 5
Fabricante	WEG	WEG	WEG	WEG	AEG
Potência (kW)	0,74	1,47	0,74	1,47	0,75
Frequência (Hz)	60	60	60	60	50
Tensão de alimentação (V)	220/380	220/380	220/380	220/380	230/400
Corrente de alimentação (A)	3,02/1,75	5,98/3,46	3,02/1,75	5,98/3,46	3,55/2,05
Número de pólos	4	4	4	4	4
Número de ranhuras	36	36	36	36	-
Fases rebobinadas	3	3	-	-	-
Nível de curto-circuito (%)	1, 3, 5 10, 15 e 20	1, 3, 5 10, 15 e 20	-	-	-
Velocidade (rpm)	1730	1750	1730	1750	1700
Torque nominal (N.m)	4,1	8,2	4,1	8,2	4,2
Número de barras de rotor	44	-	44	-	-

A conexão dos motores foi configurada em delta (Δ) com a tensão de alimentação de linha dos inversores de frequência em 220 V equilibrada. Assim, a tensão no barramento CC dos inversores de frequência é de aproximadamente 311 V. A estratégia de acionamento dos inversores de frequência é a escalar sem realimentação de velocidade. Os modelos dos inversores utilizados neste trabalho, bem como suas características básicas estão descritos na Tabela 4.2.

Tabela 4.2 – Características básicas dos inversores de frequência

Parâmetros	Sinamics G110	Micromaster MM440	ATV12H075M2	Power Flex 40	CFW08 Plus
Fabricante	Siemens	Siemens	Schneider	Allen Braddley	WEG
Aceleração (s)	3	3	3	10	10
Desaceleração (s)	3	3	3	3	3
Tipo de controle	V/f	V/f-Vetorial	V/f	V/f-Vetorial	V/f-Vetorial
Freq. chaveam. (kHz)	8	8	4	4 e 5	5

A Tabela 4.3 resume as características gerais das condições adotadas para criação do banco de dados de falhas utilizado no contexto deste trabalho. Durante a coleta dos sinais de corrente dos motores 1, 2, 3 e 4 foram utilizadas duas estratégias distintas de filtragem, a saber: analógica (filtro RC) e digital (DWT). Para os ensaios realizados na UVa utilizando o Motor 5, foi empregado o filtro FIR digital. Ao todo, foram adquiridos 2058 sinais de motores sem defeitos, 3362 sinais com falhas de curto-circuito de estator, 3729 sinais com falhas de barras quebradas de rotor e 4425 sinais com falhas de rolamentos.

Tabela 4.3 – Número de aquisições por classe de defeitos

Motor	Condição	Filtro analógico	Filtro digital
Motor 1 (0,74 kW)	Sem defeito	231	251
	1% curto-circuito estator	222	229
	3% curto-circuito de estator	222	219
	5% curto-circuito de estator	222	223
	10% curto-circuito de estator	220	223
Motor 2 (1,47 kW)	Sem defeito	160	234
	1% curto-circuito estator	162	234
	3% curto-circuito de estator	162	234
	5% curto-circuito de estator	162	234
	10% curto-circuito de estator	160	234
Motor 3 (0,74 kW)	Sem defeito	260	207
	1 barra quebrada de rotor	260	204
	2 barras quebradas de rotor	260	203
	4 barras quebradas de rotor	260	204
	2/2 barras quebradas de rotor	257	202
Motor 4 (1,47 kW)	Sem defeito	237	238
	1 barra quebrada de rotor	237	237
	2 barras quebradas de rotor	234	234
	4 barras quebradas de rotor	235	234
	2/2 barras quebradas de rotor	234	234
Motor 3 (0,74 kW)	Sem defeito	260	207
	Desgaste 15 minutos	228	255
	Desgaste 30 minutos	228	255
	Desgaste 60 minutos	229	255
	Desgaste 90 minutos	228	256
Motor 4 (1,47 kW)	Sem defeito	237	238
	Desgaste 15 minutos	240	237
	Desgaste 30 minutos	239	235
	Desgaste 60 minutos	235	235
	Desgaste 90 minutos	235	235
Motor 5 (0,75 kW)	Sem defeito	-	240
	Com defeito	-	600
Número total de aquisições por tipo de filtro		6259	7075
Número total de aquisições		13574	

4.2 Aquisição e Tratamento dos Sinais

A frequência fundamental atuante na tensão de alimentação dos MIT acionados por inversor de frequência exerce impacto direto na amplitude e no período dos sinais de corrente, tornando ainda mais difícil o desenvolvimento de um sistema de diagnóstico e classificação de falhas no domínio do tempo.

Para obter a classificação quanto ao funcionamento adequado dos motores, foram amostrados os sinais das corrente de linha do estator, considerando taxas de amostragem fixa, para o caso dos experimentos realizados com filtro digital. Para os experimentos realizados utilizando o filtro analógico, considerou-se uma taxa de amostragem dinâmica, mantendo-se o mesmo número de pontos por ciclo da amostra em análise independente da frequência fundamental utilizada na alimentação dos MIT.

O tamanho das amostras é fixado de acordo com o número de canais utilizados e o tempo de aquisição, o que pode também ser limitado pela capacidade de memória do computador utilizado. As taxas de aquisição ajustadas na PAD foram variadas em função da frequência de alimentação, descritas na Tabela 4.4, visando otimizar o tamanho dos vetores de entrada nos experimentos realizados com filtro analógico.

Tabela 4.4 – Faixa de variação de frequência em função da taxa de amostragem MIT de 0,74 e 1,47 kW

Grandezas	Faixa de variação									
Frequência (Hz)	12	18	24	30	36	42	48	54	60	
Taxa de amostragem (kamostras/s)	3	4,5	6	7,5	9	10,5	12	13,5	15	

O tempo de coleta de dados fica caracterizado pela necessidade de cada processo, podendo ser mudado de acordo com a dinâmica dos motores ou as variações das grandezas e condições observadas.

Assim, para este trabalho, foram realizadas amostragens com intervalo de tempo de 3 segundos para os ensaios de curto-circuito e 6 segundos para os ensaios com barras quebradas de rotor e rolamentos realizados no Laboratório de Sistemas Inteligentes da UTFPR. Para cada experimento realizado com o motor de 0,74 kW variou-se o torque de carga em 0,5-1,0-1,5-2,0-2,5-3,0-3,5-4,0-4,5 e 5,0 N.m. No caso do motor de 1,47 kW, as seguintes condições de torque de carga foram empregadas: 0,5-1,0-2,0-3,0-4,0-5,0-6,0-7,0-8,0 e 9,0 N.m. A frequência síncrona dos inversores foi variada na faixa de 12 a 60 Hz, com intervalos de 6 Hz entre cada amostra. Uma vez que as medidas foram realizadas com o motor em regime permanente, o tempo de aquisição usado é suficiente para retratar os sinais a serem processados sem sobrecarregar as aquisições com vetores de tamanhos excessivos.

Assim, visando obter uma análise mais detalhada, no caso dos experimentos efetuados aplicando a DWT como filtro, a taxa de amostragem foi fixada em 25.000 amostras/s. A aplicação da Transformada Wavelet possibilita o ajuste do tamanho da janela de processamento para várias componentes de frequência.

A partir do conjunto de dados descrito na Tabela 4.3, foram escolhidos de forma aleatória, para representar cada ensaio apenas um semi-ciclo do sinal positivo, sendo extraídos 50 pontos por semi-ciclo de cada um dos sinais de corrente (I_a , I_b , I_c), de acordo com os trabalhos desenvolvidos por Godoy et al. (2014) e Godoy et al. (2015b). Nos referidos sinais considera-se a amplitude de cada ponto apresentado como entrada do algoritmo de classificação, conforme o método proposto por Nascimento et al. (2011) e mais recentemente utilizado em Palacios et al. (2014) e Palácios et al. (2015).

Neste sinal, cada semi-ciclo é dividido em um número de amostras necessárias a serem apresentadas às entradas dos métodos de classificação em estudo, a partir da discretização linear do sinal. A Figura 4.5 apresenta a metodologia utilizada neste trabalho.

Testes efetuados visando definir o número de pontos que melhor representam o semi-ciclo do sinal de corrente foram efetuados considerando 10, 25, 50 e 75 pontos. Os melhores resultados são estabelecidos quando foram definidos 75 pontos por semi-ciclo, seguido pelos resultados utilizando 50 pontos, que apresentaram resultados ligeiramente inferiores. Para os testes, considerando 10 e 25 pontos, os índices de classificação obtidos foram considerados degradados para os testes realizados neste trabalho. Assim, com o objetivo de exigir um menor esforço de processamento, foi definida a utilização das amplitudes

normalizadas de 50 pontos por semi-ciclo de cada sinal de corrente como dado de entrada dos algoritmos de classificação. Assim, cada semi-ciclo positivo do sinal é representado por 50 valores discretizados do sinal, capazes de traduzir a informação necessária sem descaracterizar a forma de onda.

Figura 4.5 – Modelagem dos dados de entrada - discretização da corrente

De posse dos dados e com uma rotina de importação adequada, estes são manipulados e avaliados no *software Matlab*®. A Figura 4.6 ilustra a rotina de aquisição, tratamento e classificação dos dados utilizados neste trabalho.

Como os sinais são oriundos das correntes de uma máquina trifásica, faz-se necessário a montagem de um vetor coluna com os pontos de cada fase do sistema coletado, subsequentes um do outro, criando assim uma matriz de 150 pontos de entrada. Para a criação das matrizes de teste e validação foram utilizadas três amostras dos sinais das correntes trifásicas de cada ensaio, selecionadas de forma aleatória. Devido à defasagem das correntes e a análise ser de cada semi-ciclo de onda, são considerados os valores absolutos dos sinais amostrados, conforme observado na Figura 4.7.

Os MIT quando acionados por inversores de frequência, têm seus sinais de tensão e corrente distorcidos por ruídos provenientes dos chaveamentos do inversor. Para tanto, foram aplicadas diferentes estratégias de amostragem, bem como a aplicação de estratégias analógica e digital de filtragem, visando eliminar componentes harmônicas indesejáveis no sinal das correntes de estator dos MIT em estudo neste trabalho.

Figura 4.6 – Rotina de aquisição, tratamento e classificação dos dados

Figura 4.7 – Organização dos dados de entrada com os sinais das correntes discretizados e normalizados

4.2.1 Filtro RC Analógico

Os inversores de frequência têm formas de onda de saída ou quase quadrada, ou modulada por largura de pulso (SEDRA; SMITH, 1995). A fim de atenuar o conteúdo harmônico

dessas ondas, é necessário utilizar um filtro. Existem várias formas de projetar um filtro, no entanto, neste trabalho optou-se pela utilização do filtro analógico RC passa baixa devido à sua simplicidade e baixo custo. A Figura 4.8 apresenta o diagrama esquemático do filtro analógico RC paralelo, utilizado neste trabalho.

Figura 4.8 – Filtro RC passa baixa

As frequências acima da frequência de corte serão atenuadas. Assim, tem-se:

$$f_c = \frac{1}{2\pi RC}, \quad (4.1)$$

em que R o valor da resistência e C o valor do capacitor.

O filtro RC foi projetado levando-se em consideração a maior frequência de falhas, que refere-se aos defeitos de rolamentos, que podem atingir um valor máximo de 1.110 Hz (FERNÁNDEZ-FRANCOS et al., 2013). Assim, o filtro foi projetado e o diagrama de Bode foi traçado considerando os parâmetros $R = 560 \, \Omega$, e $C = 220 \, nF$. Calculando a frequência de corte conforme a Equação 4.1, obtém-se uma frequência de corte f_c em torno 1291 Hz. A função de transferência do filtro é dada pela Equação 4.2.

$$G(s) = \frac{v_{out}(s)}{v_{in}(s)} = \frac{1}{RCs + 1}, \quad (4.2)$$

em que v_{in} o valor da tensão de entrada e v_{out} o valor da tensão de saída.

A frequência de corte calculada acima pode ser verificada também utilizando o diagrama de Bode conforme a Figura 4.9. Nota-se que, por definição, a frequência f_c é encontrada no ponto do diagrama de magnitude que apresenta atenuação de -3 dB, bem como no ponto do diagrama de fase que apresenta atraso de aproximadamente -45° .

4.2.2 Filtro DWT Digital

O sinal de corrente obtido pelo motor foi filtrado pela DWT utilizando as funções da família Daubechies. Este trabalho considerou a vigésima ordem das wavelets Daubechies. A DWT foi executada até o seu quinto nível, pois nesta configuração, o sinal já se encontrava limpo. Além disso, neste nível, é possível reconstruir o sinal original utilizando a aproximação 5 (A5) sem perder nenhuma característica do sinal, devido à frequência das falhas mais comuns de curto-circuito de estator e barras quebradas de rotor variar na faixa entre 0 a 400 Hz (BACCARINI, 2005; ZHU et al., 2014). No caso das falhas de rolamentos,

Figura 4.9 – Diagrama de Bode - Filtro RC passa baixa

foi considerado nível de aproximação 3 (A3), uma vez que a maior frequência de falha de rolamentos pode atingir um valor máximo de 1.110 Hz (FERNÁNDEZ-FRANCOS et al., 2013). A Figura 4.10 ilustra a decomposição da DWT considerada neste trabalho.

Figura 4.10 – Decomposição multinível da DWT utilizada no trabalho

As Figuras 4.11 e 4.12 ilustram, respectivamente, os resultados obtidos na etapa de tratamento dos sinais, para o motor sem defeito e o motor com barras quebradas de rotor. A escolha deste suporte permite que os sinais sejam filtrados sem perder as suas características, possibilitando assim um melhor desempenho no tratamento dos sinais de corrente tanto no domínio do tempo quanto da frequência.

O tamanho de cada amostra é determinado por três semiciclos completos do sinal no domínio tempo, sem sobreposição de informação. Em seguida, o processo de extração de

Figura 4.11 – Sinal original e sinal reconstruído - fase A - motor sem defeito

Figura 4.12 – Sinal original e sinal reconstruído - fase A - motor com 2 barras de rotor quebradas

característica foi executado, gerando novas amostras de dados, as quais foram normalizadas.

A principal desvantagem do filtro DWT refere-se ao alto custo computacional (OPENHEIM; SCHAFER, 2010). Neste caso, a metodologia defendida para um sistema de identificação e classificação de falhas é formada por procedimentos que abrangem o processamento do sinal, extração de características e análise para identificação do estado do motor. O diagnóstico é realizado pelos classificadores de padrões inteligentes.

4.2.3 Filtro FIR Digital

O conceito básico do projeto de janela é escolher adequadamente a frequência seletiva do filtro e, em seguida, truncar sua resposta ao impulso para obter uma fase linear e um filtro FIR causal (do inglês *Finite Impulse Response*) (INGLE; PROAKIS, 1997). Portanto, a ênfase neste método está na seleção de uma função de janelamento apropriada e um filtro ideal adequado. Um filtro de frequência seletiva ideal pode ser denotado por $H_d(e^{j\omega})$, que possui um ganho de magnitude unitária e características de fase linear ao longo de sua banda de passagem e resposta zero ao longo de sua banda de corte (INGLE; PROAKIS, 1997). A largura de banda ideal de um filtro passa baixa $\omega_c < \pi$ é dada pela Equação

4.3:

$$H_d(e^{j\omega}) = \begin{cases} 1.e^{-j\alpha\omega}, & |\omega| \leq \omega_c \\ 0, & \omega_c < |\omega| \leq \pi \end{cases}, \quad (4.3)$$

em que ω_c é chamado de frequência de corte, α é o atraso da amostra e ω é a frequência. A resposta ao impulso deste filtro é infinita e dada pela Equação 4.4:

$$\begin{aligned} h_d(n) &= F^{-1} [H_d(e^{j\omega})] = \frac{1}{2\pi} \int_{-\pi}^{\pi} H_d(e^{j\omega}) e^{j\omega n} d\omega, \\ &= \frac{1}{2\pi} \int_{-\omega_c}^{\omega_c} 1.e^{-j\alpha\omega} e^{j\omega n} d\omega, \\ &= \frac{\sin[\omega_c(n-\alpha)]}{\pi(n-\alpha)}, \end{aligned} \quad (4.4)$$

Para obter um filtro FIR a partir de $h_d(n)$, faz-se necessário truncar $h_d(n)$ em ambos os lados. Um filtro FIR causal de fase linear $h(n)$ de M , é dado pela Equação 4.5::

$$h_d(n) = \begin{cases} h_d(n), & 0 \leq n \leq M-1 \\ 0, & \text{outro lugar} \end{cases} \quad \text{e} \quad \alpha = \frac{M-1}{2}, \quad (4.5)$$

Esta operação é chamada de janelamento. Em geral, $h(n)$ pode ser pensado como sendo formado pelo produto de $h_d(n)$ e uma janela $\omega(n)$ conforme a Equação 4.6:

$$h(n) = h_d(n)\omega(n), \quad (4.6)$$

em que $\omega(n)$ é alguma função simétrica com respeito a α no intervalo de $0 \leq n \leq M-1$, e 0 fora deste intervalo. Dependendo como seja obtido $\omega(n)$, torna-se possível o projeto de diferentes tipos de janelas, conforme a Equação 4.7:

$$\omega(n) = \begin{cases} 1, & 0 \leq n \leq M-1 \\ 0, & \text{caso contrário} \end{cases} = \mathfrak{R}_M(n), \quad (4.7)$$

que trata-se de uma janela retangular.

No domínio da frequência, a resposta $H(e^{j\omega})$ do filtro FIR causal é dada pela convolução de $H_d(e^{j\omega})$ e a resposta da janela $W(e^{j\omega})$, conforme a Equação 4.8

$$\omega(n) = H_d(e^{j\omega})W(e^{j\omega}) = \frac{1}{2\pi} \int_{-\pi}^{\pi} W(e^{j\lambda}) H_d(e^{j(\omega-\lambda)}) d\lambda, \quad (4.8)$$

Ainda, de acordo com Ingle e Proakis (1997), as vantagens dos filtros FIR são as seguintes:

- ❑ Resposta de fase linear e, portanto sem distorção e com aritmética real;
- ❑ Não tem problemas de estabilidade;
- ❑ Implementação eficiente por meio da utilização da Transformada de Fourier de tempo discreto.

Assim, neste trabalho foi definida a utilização de um filtro digital FIR passa baixa, projetado a partir de um janelamento Hamming, utilizando $N = 32$, com atenuação na banda de passagem em 3 dB, e atenuação da banda de rejeição em aproximadamente -9 dB, fixando a frequência da banda de rejeição em torno de 1500 Hz. A implementação foi efetuada utilizando o *software Matlab*®.

A partir de todas as especificações do projeto do filtro digital FIR definidas, a simulação do filtro produziu o sinal de resposta conforme a Figura 4.13.

Figura 4.13 – Curva de resposta Filtro FIR

4.3 Geração dos Dados Experimentais - Curto-Circuito de Estator - Laboratório de Sistemas Inteligentes UTFPR

As falhas de estator são responsáveis por aproximadamente 21 % das causas associadas a paradas não programadas na indústria (BELLINI et al., 2008). Assim, dentro do contexto

desta tese, busca-se emular as situações de curto-circuito entre espiras do enrolamento de estator.

Mais especificamente, para o caso em estudo neste trabalho, as correntes foram medidas em 2 MIT de diferentes tamanhos, de 0,74 e 1,47 kW, 4 pólos, 220/380 V, com os enrolamentos de estator rebobinados, em que várias derivações de diferentes bobinas foram construídas. O estator de ambos os MIT possui 6 bobinas, isoladas com verniz, respeitadas as medidas originais e a classe de isolamento do motor. Todas as três fases do enrolamento do estator foram montadas de forma a possibilitar a geração artificial de falhas de isolamento entre espiras, permitindo assim ensaios com 1%, 3%, 5%, 10%, 15% e 20% de curto-circuito de estator. A Figura 4.14 ilustra o diagrama de acionamento considerado neste trabalho.

Figura 4.14 – Diagrama de acionamento

Assim, neste trabalho, são emuladas as falhas de estator as quais são resultantes da deterioração do isolamento entre as bobinas individuais, isto é, em essência, um curto-circuito no enrolamento de fase do estator. Este fato altera a simetria da corrente do estator para uma forma assimétrica (DLAMINI; BARENDSE, 2012).

Na prática, tais alterações são avaliadas a partir da realização de testes de isolamento do enrolamento do estator com a carcaça da máquina, bem como testes de isolamento entre fases (SEERA et al., 2012). Um fato a ser observado é que a assimetria nos enrolamentos do estator permite que a máquina continue trabalhando, mas com o torque reduzido. A assimetria acentuada é facilmente detectada pelo aumento da corrente de alimentação da máquina, exigindo a intervenção imediata.

Os motores foram ensaiados em ambiente de laboratório, ou seja, em perfeitas condições de operação. Neste contexto, a base de dados experimentais é constituída por 2268

ensaios experimentais realizados nos motores operando em regime permanente, sob circunstâncias de cargas constantes. Para o caso em estudo, foram considerados acionamentos utilizando-se três inversores de frequência distintos visando a validação da estratégia proposta para diferentes modelos e marcas de inversores comercialmente disponíveis numa faixa de frequência de 12 a 60 Hz.

A reconstrução desta falha foi proposta por Broniera (2014), em que é relatado todo o procedimento para inserção artificial deste defeito. Esta consiste na simulação do rompimento do isolamento do fio que compõe a bobina do estator.

A Figura 4.15 apresenta um motor de 0,74 kW, da marca WEG que foi rebobinado com *taps* de derivação dos enrolamentos. O dispositivo com as chaves *on/off*, mostrado no detalhe desta figura é acoplada aos bornes de ligação dos *taps* de derivação. Quando as chaves são acionadas é possível selecionar a ocorrência de curto-circuito entre as espiras com taxas de 1%, 3%, 5%, 10%, 15% ou 20% de uma mesma bobina.

Figura 4.15 – Estator do motor de indução rebobinado com *taps*

4.4 Geração dos Dados Experimentais - Barras Quebradas de Rotor - Laboratório de Sistemas Inteligentes UTFPR

O rotor tipo gaiola dos motores de indução é composto por um conjunto interligado de barras formando uma bobina curto-circuitada, favorecendo assim a distribuição homogênea do fluxo magnético em toda a peça (FITZGERALD; JR.; UMANS, 2006).

Neste trabalho, as correntes foram medidas em um motor de indução trifásico com especificações conforme a Tabela 4.1 - Motores 3 e 4, utilizando 5 diferentes rotores para emular em laboratório as falhas de barras quebradas de rotor.

Para a reprodução deste defeito, utilizou-se um procedimento de cisalhamento das barras que compõem a gaiola do rotor. A quebra é realizada com a perfuração por uma furadeira de bancada utilizando uma broca com diâmetro suficientemente maior que a barra. Este procedimento é apresentado por Suetake (2012), tendo como resultado um conjunto de rotores para os ensaios em bancada. As quebras foram feitas para 1 até 4 barras com disposição em sequência e também opostas na circunferência do rotor, conforme a Figura 4.16.

Figura 4.16 – Rotor com quebra forçada das barras

Este tipo de falha normalmente é atribuída ao excesso de vibração, desalinhamento ou excentricidade (SUETAKE, 2012). A carga excessiva no eixo também é capaz de provocar a ruptura ou trinca. Em adicional, fatores como altas temperaturas que podem ser consequência dos outros problemas, ou mesmo fadiga do motor, também podem provocar este tipo de defeito (BACCARINI, 2005).

As quebras de barras de rotor contribuem com aproximadamente 5% das falhas em MIT (THORSEN; DALVA, 1994; BELLINI et al., 2008). Suas principais consequências refletem no aumento da oscilação do conjugado, vibração excessiva, ruído, centelhamento, além de baixa dinâmica de partida (SUETAKE, 2012; BACCARINI, 2005).

A indicação desta classe de defeitos em MIT alimentados por inversores de frequência é influenciada pela dinâmica de controle e pelas alterações de carga (NUSSBAUMER; STOJICIC; WOLBANK, 2011).

A dificuldade em detectar defeitos nos rotores está justamente na classificação das frequências características presentes nos sinais. Para minimizar este problema e obter uma ferramenta eficiente de detecção de falhas, os sistemas inteligentes têm sido também utilizados para mapear estes processos considerados complexos (CHUA et al., 2010), (NUSSBAUMER; STOJICIC; WOLBANK, 2011) e (CHEN et al., 2011).

Mais especificamente este trabalho utiliza-se de duas arquiteturas distintas de amostragem e filtros para aquisição e tratamento dos sinais de corrente de estator de MIT alimentados por diferentes modelos de inversores de frequência, operando em regime permanente no domínio do tempo.

4.5 Geração dos Dados Experimentais - Rolamentos - Laboratório de Máquinas Elétricas UVa

Os rolamentos do motor de indução trifásico são os elementos que apresentam o maior índice de falhas, sendo responsáveis por aproximadamente 69% (BELLINI et al., 2008) das causas associadas a paradas indesejadas de motores elétricos. Este tipo de falha é associada a causas tais como: desalinhamento da máquina, montagem incorreta do rolamento, contaminação, corrosão, lubrificação insuficiente ou excessiva, sobrecarga mecânica, entre outras (MUETZE; BINDER, 2007; ONEL; AYCICEK; SENOLL, 2009; SANTOS; SILVA; SUE-TAKE, 2012; ALI et al., 2015).

A literatura consultada mostra que alguns trabalhos científicos, tais como Kankar, Sharma e Harsha (2011), Zarei, Tajeddini e Karimi (2014), utilizam procedimentos artificiais de inserção de falhas buscando controlar as diversas variáveis e assim tentar reproduzir as características associadas as falhas de rolamentos.

Assim, a abordagem para inserção de falha de rolamentos utilizada no Laboratório de Máquinas Elétricas da UVa, considera a evolução progressiva do desgaste de um rolamento causada pela contaminação da lubrificação durante a montagem, buscando assim a similaridade do processo de desgaste do rolamento pelo uso excessivo, lubrificação inadequada e excesso de carga no eixo, fatores estes que conduzem o rolamento à sua consequente degradação. Este tipo de situação é comumente encontrada no ambiente industrial.

A metodologia aplicada para estimação da evolução desta falha consiste na análise da amplitude dos sinais de corrente no domínio do tempo. Para a aquisição destes sinais foi utilizada a bancada de ensaios mostrada na Figura 4.4. A taxa de amostragem foi de 25.000 amostras/s. Visando maior detalhamento dos sinais a partir de sua aquisição desde o transitório até o regime permanente, o tempo de aquisição foi definido em 25 segundos.

A rotina de comunicação da PAD com o computador foi desenvolvida utilizando o *software Matlab*[®], e os dados adquiridos são armazenados em forma de planilhas, as quais são identificadas pelo motor, modelo do inversor, nível de carga, condição do rolamento e número da aquisição sob análise.

Para os testes foi utilizado o rolamento fixo de uma carreira de esferas, modelo SKF Explorer 6004, com especificações conforme descrito na Tabela 4.5.

Na Tabela 4.6, são descritas cada uma das condições de testes adotadas. Foram aquisitadas 40 amostras considerando rolamento sem defeito sendo 20 amostras para o

Tabela 4.5 – Especificações do rolamento modelo SKF Explorer 6004

Parâmetros	Especificações
Diâmetro do furo (mm)	20
Diâmetro externo (mm)	42
Largura (mm)	12
Carga Dinâmica (kN)	9,95
Carga estática (kN)	5
Velocidade de referência (r/min)	38000
Velocidade limite (r/min)	24000

motor operando a vazio e 20 amostras para o motor operando com 100% do conjugado de carga. Na sequência, 100 amostras aquisitadas para a condição com defeito das quais 50 amostras para o motor operando a vazio e 50 amostras para o motor operando com 100% do conjugado de carga.

Tabela 4.6 – Descrição das condições de testes adotadas

Teste	Inversor	Frequência	Freq. Chaveamento	Condição	Nr. de Aquisições
1	Allen Braddley	50 Hz	4 kHz	Sem defeito	40
				Com defeito	100
2	Allen Braddley	25 Hz	4 kHz	Sem defeito	40
				Com defeito	100
3	Allen Braddley	75 Hz	4 kHz	Sem defeito	40
				Com defeito	100
4	Allen Braddley	50 Hz	5 kHz	Sem defeito	40
				Com defeito	100
5	WEG	50 Hz	5 kHz	Sem defeito	40
				Com defeito	100
6	Direto na rede	50 Hz	-	Sem defeito	40
				Com defeito	100

Inicialmente, foram aquisitadas todas as amostras do motor operando com rolamento sem defeitos. Para a inserção da falha considerou-se a retirada da blindagem lateral protetora e contaminação da lubrificação (graxa SKF) do rolamento dianteiro da máquina com carbeto de silício (SiC), que trata-se de um material cerâmico de elevada resistência a erosão, corrosão e alta ciclagem térmica, conforme Figura 4.17.

De acordo com Ali et al. (2015), o processo de degradação de um rolamento é muito complexo, especialmente o processo de degradação natural. Assim, a partir da contaminação da lubrificação do rolamento com SiC, foram iniciados os testes visando estimar a evolução gradual da degradação de um rolamento ao longo do tempo.

Imediatamente após a contaminação da lubrificação do rolamento dianteiro do motor foram realizados os primeiros ensaios considerados como estágio inicial de evolução de uma falha incipiente de rolamento. Então, foram coletadas 5 amostras para cada uma das condições definidas para os testes 1 a 6, respectivamente para o motor operando desde o transitório até o regime permanente, operando a vazio e com plena carga.

Na sequência, visando obter a evolução de diferentes estágios de desgaste, o motor foi acionado diretamente na rede operando a vazio de forma ininterrupta por um intervalo de 12 horas. De forma complementar, foram monitoradas as correntes, bem como efetuadas as análises de termografia visando acompanhar a influência da evolução da falha na

Figura 4.17 – Contaminação do rolamento dianteiro com SiC

temperatura de operação da máquina em comparação com outras duas máquinas de especificações similares, no entanto, com rolamentos sem contaminação no lubrificante. Todas as termografias utilizaram a mesma faixa de escala: 20 – 45 °C, considerando uma emissividade de 95 % e uma transmissão de 100 %. Para temperatura de fundo é considerado o valor de 22 °C.

Após o completo resfriamento do motor, novas aquisições para cada uma das condições de testes foram executadas. Este procedimento foi repetido durante um período de 9 dias, em que ocorreu o bloqueio do rolamento. Assim, este período de tempo foi definido como condição limite para operação segura do equipamento. Cada um dos 10 dias de testes representa um grau de evolução no desgaste do rolamento em estudo neste trabalho.

A Figura 4.18 mostra o rolamento após o período de execução dos testes. Visualmente fica perceptível a deterioração do rolamento em função da grande presença de cavacos de aço (anéis interno/externo, bem como nas esferas), característica similar a observada em peças com desgaste excessivo, por tempo de operação ou ausência de lubrificação.

4.6 Geração dos Dados Experimentais - Rolamentos - Laboratório de Sistemas Inteligentes UTFPR

De forma similar, a metodologia para inserção de falha de rolamentos utilizada no Laboratório de Sistemas Inteligentes, também visa aprofundar a investigação de uma falha causada pelo desgaste gradual de um rolamento ao longo do tempo de operação da máquina. Para execução destes testes foi efetuada a substituição do lubrificante por pasta abrasiva, marca Brasilex, composta de carbono, silício, graxa e óleo. Conforme mostra a Figura 4.19, sendo consideradas 4 situações distintas de desgaste, a saber: desgaste

Figura 4.18 – Desgaste do rolamento após período de execução dos testes

inicial, desgaste médio, desgaste avançado e desgaste severo. Para a geração de cada um destes níveis de desgaste, foram utilizados conjuntos de rolamentos novos, em que após a remoção das blindagens de proteção lateral os rolamentos foram contaminados com pasta abrasiva. Na sequência, o motor foi acionado diretamente na rede operando a vazio de forma ininterrupta para cada um dos períodos de desgaste definidos, a saber: 15, 30, 60 e 90 minutos, respectivamente. Este mesmo procedimento foi adotado para geração de defeitos nos rolamentos utilizados nos Motores 3 e 4.

Para os testes foi utilizado o rolamento rígido de esferas, modelos NSK 6204 2Z e 6205 2Z, com especificações conforme descrito na Tabela 4.7.

Tabela 4.7 – Especificações dos rolamentos NSK 6204 2Z e 6205 2Z

Parâmetros	Especificações	
	NSK 6204	NSK 6205
Diâmetro do furo (mm)	20	25
Diâmetro externo (mm)	47	52
Largura (mm)	14	15
Carga dinâmica (kN)	13,5	14,8
Carga estática (kN)	6,55	7,8
Velocidade de referência (r/min)	32000	28000
Velocidade limite (r/min)	17000	14000

Durante o período de desgaste, foram monitoradas as correntes de estator e a temperatura da máquina visando assegurar a correta operação da máquina. Uma vez concluído o período definido de desgaste, os rolamentos foram retirados e lavados com solvente visando completa remoção de quaisquer resíduos da pasta abrasiva. Uma vez limpos, os rolamentos foram secos com ar comprimido, novamente lubrificados e montados nas má-

quinas para sequência dos ensaios e aquisição de sinais. Após cada processo de desgaste, visualmente é perceptível a formação de folgas entre as partes componentes do rolamento, característica esta similar a observada nas peças com desgaste excessivo por tempo de operação ou falta de lubrificação.

Figura 4.19 – Contaminação do rolamento dianteiro com pasta abrasiva

4.7 Estruturas de Classificação

Para classificação quanto à correta operação dos motores, foram implementadas diferentes estratégias inteligentes de classificação, escolhidas com base nos métodos recentemente aplicados na classificação de falhas em MIT (GANDHI; CORRIGAN; PARSA, 2011b; TRAN et al., 2013; DAS et al., 2014; LEE et al., 2014; BACCARINI et al., 2013; SEERA et al., 2014; SESHADRINATH; SINGH; PANIGRAHI, 2014).

Os dados são aleatoriamente apresentados às estruturas de classificação, de tal forma que os algoritmos de preparação dos dados garantam que as amostras apresentadas representem todo o domínio de operação do motor. Os dados experimentais foram divididos em dois grupos: treinamento e validação. Existem diferentes números de amostras para os diversos cenários de teste.

Os conjuntos de aprendizado foram submetidos para execução na ferramenta WEKA (HALL et al., 2009). *Waikato Environment for Knowledge Analysis* - WEKA, é uma ferramenta de KDD - *Knowledge Discovery in Databases* que contempla uma série de algoritmos de preparação de dados, de aprendizagem de máquina (mineração) e de validação de resultados, permitindo assim treinar e testar diferentes estratégias de classificação de forma interativa (HALL et al., 2009). O sistema permite que os algoritmos forneçam relatórios com dados analíticos e estatísticos do domínio de operação.

Um dos dados estatísticos fornecidos pela ferramenta para análise dos resultados trata-se do coeficiente Kappa, que pode ser definido como uma medida de associação utilizada

para descrever ou testar o grau de concordância, ou confiabilidade e precisão, na classificação. O trabalho de Landis e G. (1977) caracteriza diferentes faixas para os valores de Kappa, segundo o grau de concordância que eles sugerem. Assim, valores maiores que 0,79 indicam excelente concordância, enquanto que valores inferiores a 0,40 representam baixa concordância, conforme demonstrado na Tabela 4.8.

Tabela 4.8 – Tabela para interpretação da estatística Kappa

Valores de Kappa	Interpretação
< 0	Nenhuma concordância
0 - 0,19	Pobre concordância
0,20 - 0,39	Fraca concordância
0,40 - 0,59	Moderada concordância
0,60 - 0,79	Substancial concordância
0,80 - 1,00	Perfeita concordância

Os algoritmos avaliados neste trabalho foram configurados para treinamento supervisionado, sendo que as características e topologias dos classificadores FAM, SVM/SMO, k -NN e PMC são descritas nos parágrafos abaixo, respectivamente, mantendo-se fixos os mesmos parâmetros e especificações para todas as condições avaliadas.

Para treinamento e teste em todos os casos, cada classificador foi avaliado por meio do método de validação cruzada em k -partições, usando $k = 10$. Desta forma, cada classificador foi treinado com $(k - 1)$ sub-conjuntos escolhidos aleatoriamente, em seguida, testados com o sub-conjunto restante. Ressalta-se que para cada cenário de teste todos os classificadores utilizaram a mesma base de dados experimentais.

Para o método de FAM, a definição do parâmetro de vigilância (ρ) foi estabelecida a partir de testes realizados considerando uma variação 0,6-1,0. Os melhores resultados foram obtidos quando ρ foi definido como 0,75. Elevados valores neste parâmetro impactaram na formação de um número maior de categorias na camada de saída, os quais degradaram os resultados de classificação para as amostras avaliadas neste trabalho. A taxa de aprendizagem (β) foi definida como 1,0, visando aprendizagem rápida. Conforme (CARPENTER et al., 1992), o parâmetro de escolha (α) foi mantido como um pequeno valor próximo a 0. Assim, neste trabalho (α) ficou definido como 0,001.

O classificador SVM/SMO utiliza o algoritmo de otimização mínimo sequencial de John Platt para treinamento (PLATT, 1998). Esta implementação substitui globalmente todos os valores em falta e transforma atributos nominais para binários, além de efetuar a normalização dos dados.

Conforme Samanta e Nataraj (2009), foram efetuadas as possíveis combinações dos parâmetros de regularização do SVM/SMO, e os melhores resultados foram obtidos quando o erro no parâmetro tolerância recebeu o valor de 0,001 e Gama (γ) como 0,01. O parâmetro γ controla a flexibilidade da função de kernel. Pequenos valores permitem que o classificador ajuste todos os rótulos com o risco de sobre ajustamento *overfitting*, en-

quanto maiores valores podem reduzir o kernel para uma função constante dificultando o processo de aprendizado. O parâmetro de margem (C) que determina um ponto de equilíbrio razoável entre a maximização da margem e a minimização do erro, controlando a influência de cada vetor, foi definido como 1.0. Quanto maior o valor do parâmetro C , maior será a penalização associada aos erros cometidos. O polinômio Kernel representa a semelhança de vetores em um espaço característico sobre polinômios das variáveis originais (ALPAYDIN, 2010).

O algoritmo de treinamento da rede PMC é o *backpropagation*, que tem a função de encontrar as derivadas da função de erro com relação aos pesos e bias da RNA. Para definir a configuração do número de neurônios na camada intermediária, testes foram realizados considerando 10, 25, 50, 76 e 100 neurônios. Neste trabalho, o número de neurônios na camada intermediária não mostrou impacto direto em uma alta taxa de precisão da classificação, no entanto, confirmou sua forte influência sobre o tempo necessário para criação dos modelos. Os melhores resultados foram estabelecidos quando foram utilizados 76 neurônios na camada intermediária (GODOY et al., 2015a). Conforme (GHATE; DUDUL, 2009; GODOY et al., 2014) observa-se que a função de ativação tangente hiperbólica na camada intermediária e função de ativação linear na camada de saída apresentaram os melhores resultados. O parâmetro taxa de aprendizado apresenta forte influência sobre o tempo de treinamento, e foi variado de 0,1-0,4 sem impacto significativo sobre os resultados de classificação. Assim, neste trabalho este parâmetro foi definido como 0,2.

Em adicional, para os dados coletados no laboratório de Máquinas Elétricas da UVA, foi considerada utilização de uma rede PMC implementada como aproximador funcional, para estimar o tempo de vida útil do rolamento, com 1 única camada neural escondida composta por 76 neurônios, utilizando funções de ativação do tipo sigmoide, treinamento supervisionado, algoritmo de treinamento Levenberg-Maquardt, 150 entradas e 1 neurônio na camada de saída com função de ativação do tipo transferência linear.

Para a rede atuando como multiclassificador, são utilizados 5 neurônios na camada de saída. Especificamente, no caso da rede atuando com apenas com dois padrões (motor sem defeito e motor com defeito), a rede utiliza 1 neurônio na camada de saída e os demais parâmetros permanecem inalterados.

Para a definição da configuração do número de vizinhos para o método k -NN foram realizados testes considerando uma variação de 1 até 15 vizinhos. No entanto, observou-se os melhores resultados quando foram estabelecidos $1 \leq k \leq 4$. Para o intervalo de valores entre $5 \leq k \leq 15$ os índices resultantes da classificação foram degradados para os testes realizados neste trabalho. Assim, a configuração do classificador k -NN foi definida como sendo apenas 1 vizinho utilizado. O algoritmo de busca utilizado é baseado no método de cálculo da distância Euclideana.

Para todos os testes computacionais efetivados neste trabalho, foi utilizado um computador composto por um processador Intel (R) Core i7 4770 3.46 GHz, memória RAM

de 16GB e HD de 500GB.

Em se tratando da utilização de sinais reais de correntes elétricas de máquinas de diferentes potências, a normalização dos dados considerou o valor de pico da onda de cada ensaio. Conforme Malange (2010) a normalização dos dados evita a proliferação de categorias. Após a normalização foram formados os vetores de entrada dos classificadores. Para formatação dos vetores de saída desejada, é empregada a codificação binária para a saída com 1 bit. Na classificação de motor sem defeito e motor com defeito foram utilizados 2 bits, e para multiclassificação do nível de severidade das falhas foram utilizados 5 bits na camada de saída.

4.8 Considerações Finais

Neste Capítulo foi apresentada a discussão sobre a inserção artificial de algumas das principais falhas encontradas nos MIT, sendo destacadas as falhas de curto-circuito no enrolamento de estator, barras quebradas de rotor e de rolamentos, responsáveis por mais de 70% do total de falhas encontradas em MIT (THORSEN; DALVA, 1994; BELLINI et al., 2008).

Ainda, neste Capítulo, foram discutidos os aspectos relacionados às bancadas experimentais utilizadas para coleta e aquisição dos dados experimentais, além da apresentação do método de tratamento dos dados experimentais empregado neste trabalho. Por fim, foram apresentados os parâmetros utilizados nos classificadores.

No Capítulo 5, serão apresentados e discutidos os resultados obtidos a partir dos diversos conjuntos de dados experimentais adquiridos dos diversos MIT em estudo neste trabalho.

Resultados Experimentais

Neste capítulo, são descritos os principais resultados obtidos utilizando os algoritmos de classificação FAM, SVM/SMO, k -NN e PMC, treinados a partir das amplitudes dos sinais de correntes trifásicas de estator, no domínio do tempo, obtidas por meio de ensaios experimentais utilizando diferentes modelos de inversores de frequência e MIT de diferentes potências.

No contexto desta tese, a metodologia apresentada foi utilizada para diagnóstico e classificação de motor sem defeito, motor com defeitos de curto-circuito de estator, motor com defeitos de barras quebradas de rotor e defeitos de rolamentos. Para tanto, foram consideradas estratégias de classificação simples (motor sem defeito e motor com defeito), bem como avaliação dos algoritmos funcionando como multiclassificadores de defeitos.

Em adicional, os MIT quando acionados por inversores de frequência, têm seus sinais de tensão e corrente distorcidos por ruídos provenientes dos chaveamentos dos transístores de potência. Para tanto, foram comparadas diferentes estratégias de amostragem, bem como aplicação de estratégias analógica e digital de filtragem dos sinais de correntes.

Na sequência, são apresentados os resultados comparativos de classificação obtidos pelos diferentes algoritmos inteligentes de classificação estudados neste trabalho. Em todos os experimentos realizados nesta tese os motores foram submetidos à variação de frequência de 12 a 60 Hz considerando ainda variação do conjugado de carga de $10\% < T_n < 110\%$ do conjugado nominal da máquina em operação.

5.1 Resultados de Classificação - Falhas de Curto-Circuito de Estator

Nesta Seção são apresentados os resultados obtidos pelos classificadores no diagnóstico de falhas de curto-circuito de enrolamento de estator, utilizando como entradas as amplitudes das correntes trifásicas dos MIT acionados por modelos distintos de inversores de frequência, conforme descrito no Capítulo 4.

As estratégias de classificação propostas foram submetidas ao treinamento com os sinais de entrada conforme descrito na Subseção 4.2, na qual as amplitudes dos sinais das correntes trifásicas formam uma matriz de 150 pontos, em que cada ponto é apresentado como uma entrada dos algoritmos de classificação, resultando assim em 3 amostras referentes a cada ensaio experimental realizado.

5.1.1 Classificações de Curto-Circuito de Estator - Filtro Analógico

As Tabelas 5.1 e 5.2 apresentam os resultados de classificação do conjunto composto por 1096 ensaios experimentais, coletados de todos os inversores para o Motor 1. Tem-se assim 3288 amostras utilizadas para treinamento e validação dos classificadores configurados para a classificação de motor sem defeito/motor com defeito utilizando filtragem analógica.

Tabela 5.1 – Resultados experimentais - Classificação de falhas de curto-circuito de estator (Motor 1)

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	74,40	85,53	85,25	86,55
Instâncias incorretamente classificadas (%)	25,60	14,47	14,75	13,45
Estatística Kappa	0,30	0,48	0,54	0,58
Erro absoluto médio	0,25	0,14	0,14	0,13
Erro quadrático	0,50	0,38	0,38	0,32
Erro absoluto relativo (%)	79,77	45,09	46,02	43,04
Erro quadrático relativo (%)	126,33	94,99	95,85	82,31
Tempo para criação do modelo (s)	0,46	2,35	0,02	326,6

Na Tabela 5.1, é possível observar que os algoritmos PMC, k -NN e SVM/SMO obtiveram precisão global superior a 85%, além de apresentarem moderada concordância com os resultados obtidos nos testes. O algoritmo FAM obteve 74,4% de precisão global e fraca concordância com os resultados obtidos nos testes.

A matriz de confusão mostrada na Tabela 5.2 quantifica quantos exemplos da base de dados utilizada foram classificados de forma correta pelo modelo construído (representado na diagonal principal) em oposição às classificações preditas para cada classe. Os valores contidos na diagonal principal da matriz indicam os acertos no reconhecimento dos padrões, que estão sendo indicados pelas respectivas colunas e linhas.

Tabela 5.2 – Matriz de confusão (Motor 1) - Classificação de curto-circuito de estator

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	366	294	307	353	423	237	439	221
Falha	548	2080	123	2505	248	2380	221	2407

A partir da Tabela 5.2, é possível observar que os algoritmos SVM/SMO, PMC e k -NN apresentam precisão superior a 90% para classificação de motor com defeito de curto-circuito de estator. No caso do motor sem defeito, a precisão é de 66,5% e 64,1%, respectivamente para os algoritmos PMC e k -NN.

Para o mesmo conjunto de dados, as Tabelas 5.3 e 5.4 exibem os resultados obtidos considerando a multiclassificação de falhas de curto-circuito de estator para o Motor 1.

Tabela 5.3 – Resultados experimentais - Multiclassificação de falhas de curto-circuito de estator (Motor 1)

Atributos	FAM	SVM/SMO	k-NN	PMC
Instâncias corretamente classificadas (%)	62,05	66,36	76,15	82,21
Instâncias incorretamente classificadas (%)	37,95	33,64	23,84	17,79
Estatística Kappa	0,52	0,57	0,70	0,77
Erro absoluto médio	0,15	0,25	0,09	0,08
Erro quadrático	0,38	0,341	0,30	0,23
Erro absoluto relativo (%)	47,44	80,23	29,92	25,59
Erro quadrático relativo (%)	97,41	85,40	77,14	59,09
Tempo para criação do modelo (s)	1,47	3,75	0,01	305,15

Ao longo desta ampla faixa, observa-se a partir da Tabela 5.3 que o algoritmo PMC novamente apresentou melhor precisão global, atingindo 82,21% de acerto, confirmando assim a capacidade de generalização do método proposto para diferentes modelos de inversores com frequências de chaveamento distintas, em uma ampla faixa de frequências e conjugado de carga. O algoritmo k -NN demonstrou precisão global de 76,15%, seguido pelos algoritmos SVM/SMO e FAM, respectivamente, com 66,36%, e 62,05%, ambos com moderada concordância.

Tabela 5.4 – Matriz de confusão (Motor 1) - Multiclassificação de curto-circuito de estator

Classes Preditas										
FAM						SVM/SMO				
Classes	Normal	1%	3%	5%	10%	Normal	1%	3%	5%	10%
Normal	353	235	58	13	1	447	194	19	0	0
1%	238	311	93	9	6	300	294	60	3	0
3%	71	107	362	114	6	43	105	420	87	5
5%	14	22	128	440	56	2	20	150	447	41
10%	1	7	12	57	574	0	0	10	67	574
k-NN						PMC				
Classes	Normal	1%	3%	5%	10%	Normal	1%	3%	5%	10%
Normal	422	206	32	0	0	477	172	7	3	1
1%	208	395	48	6	0	177	432	34	9	5
3%	38	52	504	66	0	9	33	576	40	2
5%	3	6	80	556	15	0	0	57	589	14
10%	0	1	3	20	627	0	0	1	21	629

A partir da Tabela 5.4, é possível distinguir claramente a existência de faixas independentes de falhas de curto-circuito de estator. Na faixa entre 5% e 10% de curto-circuito de estator, ambos os algoritmos PMC e k -NN apresentam precisão superior a 85%. Já nos algoritmos FAM e SVM/SMO, este mesmo índice de precisão pode ser atribuído apenas para falhas de 10%. Ambos FAM e SVM/SMO, apresentam precisão superior a 70% para classificação de falhas de 5%.

Novamente, observa-se dificuldade na diferenciação entre motor não defeituoso e 1% de falha de curto-circuito. Neste cenário, o algoritmo PMC apresenta precisão superior a 70% para classificação de falhas ainda em fase prematura de evolução, confirmando em uma ampla faixa de frequências a eficácia deste método. A precisão dos algoritmos FAM

e SVM é superior a 50% de acerto do motor não defeituoso e superior a 45% de acerto para falha de 1% de curto-circuito de estator.

Em relação ao tempo de execução gasto pelos algoritmos para construção dos modelos, os classificadores k -NN e FAM destacam-se pelos baixos tempos de processamento. O algoritmo PMC consome maior tempo computacional para construção do modelo, no entanto, o mesmo apresenta índice de precisão superior em comparação com os demais algoritmos avaliados neste trabalho.

As Tabelas 5.5 e 5.6 exibem os resultados de classificação do conjunto de dados constituído por 1172 ensaios experimentais, para o Motor 2 acionado por todos os inversores, gerando 3516 amostras utilizadas para classificação motor sem defeito/motor com defeito.

Tabela 5.5 – Resultados experimentais - Classificação de falhas de curto-circuito de estator (Motor 2)

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	75,76	84,92	86,74	88,48
Instâncias incorretamente classificadas (%)	24,24	15,08	13,26	11,51
Estatística Kappa	0,35	0,45	0,57	0,64
Erro absoluto médio	0,24	0,15	0,13	0,124
Erro quadrático	0,49	0,38	0,36	0,30
Erro absoluto relativo (%)	76,03	47,30	41,66	38,89
Erro quadrático relativo (%)	123,34	97,28	91,19	76,26
Tempo para criação do modelo (s)	0,47	2,46	0,04	296,92

A Tabela 5.5, mostra que os algoritmos PMC, k -NN e SVM/SMO, trabalhando na configuração de classificação motor com defeito ou motor sem defeito, apresentam precisão global superior a 84,92%. O algoritmo PMC apresenta substancial concordância com os resultados obtidos nos testes, enquanto os algoritmos k -NN e SVM/SMO apresentam moderada concordância. O algoritmo FAM obteve 75,76% de precisão global e fraca concordância.

Tabela 5.6 – Matriz de confusão (Motor 2) - Classificação de curto-circuito de estator

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	447	252	314	385	455	244	506	193
Falha	600	2217	145	2672	222	2595	212	2605

A Tabela 5.6, permite observar que os algoritmos SVM/SMO, PMC e k -NN possuem precisão superior a 92% para classificação de motor com defeito de curto-circuito de estator. Os algoritmos PMC, k -NN e FAM obtiveram respectivamente 72,4%, 65,1% e 63,9% de precisão na indicação para o motor sem defeito.

Considerando o mesmo conjunto de dados, as Tabelas 5.7 e 5.8 exibem os resultados da multiclassificação de falhas de curto-circuito de estator para o Motor 2.

A análise da Tabela 5.7 permite observar que novamente o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 83,39% de acerto e substancial concordância com os resultados obtidos nos testes, confirmando assim a capacidade de

Tabela 5.7 – Resultados experimentais - Multiclassificação de falhas de curto-circuito de estator (Motor 2)

Atributos	FAM	SVM/SMO	k-NN	PMC
Instâncias corretamente classificadas (%)	65,95	67,80	79,74	83,39
Instâncias incorretamente classificadas (%)	34,04	32,19	20,25	16,60
Estatística Kappa	0,57	0,59	0,74	0,79
Erro absoluto médio	0,13	0,25	0,08	0,07
Erro quadrático	0,36	0,34	0,28	0,22
Erro absoluto relativo (%)	42,55	79,94	25,43	24,67
Erro quadrático relativo (%)	92,25	85,07	71,09	58,30
Tempo para criação do modelo (s)	1,52	3,64	0,01	321,28

generalização do método proposto para diferentes modelos de inversores com frequências de chaveamento distintas, em uma ampla faixa de frequências. Os algoritmos k -NN, SVM/SMO e FAM apresentaram respectivamente 79,74%, 67,80% e 65,95% de precisão global, com substancial concordância no caso do algoritmo k -NN, e moderada concordância para os algoritmos SVM/SMO e FAM.

Em comparação com os métodos k -NN, FAM e SVM/SMO, observa-se o alto tempo computacional gasto pelo algoritmo PMC para construção dos modelos, fato este compensado pela elevada taxa de precisão individual por classe avaliada para os diferentes tipos de inversores de frequência operando em todas as faixas de frequência, principalmente, em comparação com os classificadores SVM/SMO e FAM.

Tabela 5.8 – Matriz de confusão (Motor 2) - Multiclassificação de curto-circuito de estator

		Classes Preditas									
		FAM					SVM/SMO				
Classes	Normal	1%	3%	5%	10%		Normal	1%	3%	5%	10%
Normal	398	257	31	10	3		425	260	14	0	0
1%	238	361	90	12	4		299	370	36	0	0
3%	39	67	450	140	9		24	102	473	106	0
5%	8	20	131	494	52		3	18	160	504	20
10%	0	0	8	78	616		0	0	8	82	612
		k-NN					PMC				
Classes	Normal	1%	3%	5%	10%		Normal	1%	3%	5%	10%
Normal	449	240	10	0	0		514	172	7	5	1
1%	201	469	33	2	0		130	553	21	0	1
3%	13	45	600	47	0		2	44	606	52	1
5%	1	3	89	605	7		1	9	83	590	22
10%	0	0	1	20	681		0	0	1	32	669

A partir da análise da Tabela 5.8, é possível distinguir claramente a existência de faixas de falhas independentes obtidas a partir dos algoritmos de classificação comparados neste trabalho. Nos algoritmos PMC e k -NN a precisão para classificação de falhas de 3%, 5% e 10% de curto-circuito de estator é superior a 85%.

Nos algoritmos FAM e SVM/SMO, este índice de precisão somente pode ser atribuído para falhas de 10%. Os classificadores FAM e SVM/SMO apresentam precisão superior a 60% para classificação de falhas de 5%.

No caso dos algoritmos FAM e SVM/SMO a precisão é superior a 50% para o motor não defeituoso e 45% para classificação de falhas de 1% de curto-circuito de estator.

Em adicional, foram também efetuadas análises visando avaliar a eficiência de classificação sob condições distintas de operação: (i) motor operando na faixa de 12 - 36 Hz, (ii) motor operando na faixa de 36 - 60 Hz; (iii) bem como verificar os resultados de classificação considerando dados do motor acionado por um único inversor de frequência.

Os resultados obtidos para o Motor 1 e o Motor 2, tratados de forma separada, operando na faixa de 12 a 36 Hz, indicam precisão superior a 85% para classificação de falhas de 5% e 10% de curto-circuito de estator para os algoritmos PMC, k -NN e SVM/SMO, que ainda apresentam precisão superior a 70% para classificação de falhas de 3% de curto-circuito. Neste mesmo cenário, a precisão do algoritmo FAM é superior a 51%.

No caso da falha de 1%, o índice de precisão muito embora seja ligeiramente confundido com o motor não defeituoso, os resultados obtidos pelo algoritmo PMC indicam precisão superior a 70%.

Já o algoritmo FAM obteve índice de precisão superior a 50% para classificação de motor sem defeito e com falha de 1% de curto-circuito de estator, no entanto, este classificador apresenta precisão de 87,7% para classificação de falhas de 10%.

Em relação aos resultados obtidos a partir da análise dos Motores 1 e 2 operando na faixa de 36 - 60 Hz, observa-se precisão superior a 90% para classificação de falhas de 5% e 10% de curto-circuito de estator para os algoritmos PMC, k -NN e SVM/SMO, que ainda apresentam precisão superior a 80% para classificação de falhas de 3% de curto-circuito de estator. Observa-se ainda que os algoritmos PMC e k -NN também possuem precisão superior a 60% para classificação de falhas ainda em fase prematura de evolução; a saber 1% de falha de curto-circuito de estator.

Novamente, a precisão do algoritmo FAM foi superior a 50% para motor sem defeito e falha de 1% de curto-circuito de estator. Elevados índices de precisão são obtidos apenas para classificação de falhas de 10% de curto-circuito de estator, em que foram atingidos índices superiores a 94%.

Para os casos em que os motores foram acionados apenas por um único inversor de frequência, os melhores resultados foram obtidos a partir dos dados experimentais coletados utilizando o inversor Siemens MM4400, em que foram obtidos índices de precisão global superiores a 72%, 80%, 90% e 95%, respectivamente para os algoritmos FAM, k -NN, SVM/SMO e PMC. Os menores índices foram obtidos a partir dos dados coletados a partir do inversor Siemens G110, que apresentou índices globais de classificação superiores a 54%, 65%, 72% e 73%, respectivamente para os algoritmos FAM, SVM/SMO, PMC e k -NN.

Todos estes resultados confirmam que a estratégia proposta neste trabalho permite a classificação de falhas de curto-circuito de estator em motores acionados por inversores de frequência de diferentes modelos e fabricantes, independente da velocidade de operação ou nível de carga empregado.

5.1.2 Classificações de Curto-Circuito de Estator - Filtro Digital

Nesta subseção são apresentados os resultados de classificação considerando a utilização da TWD como filtro digital. Os parâmetros definidos para a execução deste teste foram descritos na Subseção 4.7. As estratégias de classificação propostas foram submetidas ao treinamento com os sinais de entrada tratados com filtro digital conforme descrito na Seção 4.2.2.

As Tabelas 5.9 e 5.10 exibem os resultados de classificação do conjunto também composto por 1149 ensaios experimentais para o Motor 1. Tem-se assim um conjunto de 3447 amostras utilizadas para treinamento e validação dos classificadores.

Tabela 5.9 – Resultados experimentais - Classificação de falhas de curto-circuito de estator (Motor 1) - Filtro Digital

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	72,90	86,51	88,01	90,80
Instâncias incorretamente classificadas (%)	27,10	13,49	11,99	9,20
Estatística Kappa	0,28	0,59	0,66	0,72
Erro absoluto médio	0,27	0,13	0,12	0,10
Erro quadrático	0,52	0,36	0,34	0,27
Erro absoluto relativo (%)	79,32	39,49	35,15	29,71
Erro quadrático relativo (%)	125,97	88,88	83,74	65,99
Tempo para criação do modelo (s)	0,33	1,86	0,02	418,8

A Tabela 5.9, mostra que os algoritmos PMC, *k*-NN e SVM/SMO, trabalhando na configuração de multi-classificação de defeitos de curto-circuito de estator, apresentam precisão global superior a 86%. Os algoritmos PMC e *k*-NN apresentam substancial concordância com os resultados obtidos nos testes, enquanto o algoritmo SVM/SMO apresenta moderada concordância com os resultados obtidos nos testes. O algoritmo FAM obteve 72,90% de precisão global, e fraca concordância com os resultados obtidos nos testes.

Tabela 5.10 – Matriz de confusão (Motor 1) - Classificação de curto-circuito de estator - Filtro Digital

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	402	351	489	264	582	171	585	168
Falha	583	2111	201	2493	242	2452	149	2545

A Tabela 5.10 demonstra que o algoritmo PMC possui precisão de 94,50% para classificação motor com defeito, e 77,7% para classificação de motor sem defeito. Neste cenário, os algoritmos SVM/SMO e *k*-NN atingem respectivamente 92,5% e 91% de precisão na indicação de motor com defeito. O algoritmo FAM apresenta 78,4% de precisão para motor com defeito e 53,4% para classificação de motor com defeito de curto-circuito de estator.

As Tabelas 5.11 e 5.12, apresentam os resultados de multiclassificação do conjunto composto por 1149 ensaios experimentais coletados de todos os inversores para o Motor 1, gerando assim um conjunto de 3447 amostras utilizadas para treinamento e validação dos classificadores.

Tabela 5.11 – Resultados experimentais - Multiclassificação de falhas de curto-circuito de estator (Motor 1) - Filtro Digital

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	61,63	69,36	78,99	82,62
Instâncias incorretamente classificadas (%)	38,27	30,64	21,01	17,38
Estatística Kappa	0,52	0,61	0,73	0,78
Erro absoluto médio	0,153	0,25	0,08	0,07
Erro quadrático	0,39	0,34	0,28	0,23
Erro absoluto relativo (%)	47,85	80,00	26,38	24,44
Erro quadrático relativo (%)	97,83	85,10	72,42	58,85
Tempo para criação do modelo (s)	1,06	4,25	0,01	425,76

Analisando a Tabela 5.11 é possível observar que também no caso da aplicação do filtro TWD, o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 82,62% de acerto e substancial concordância com os resultados obtidos nos testes, confirmando assim a capacidade de generalização do método proposto para diferentes modelos de inversores com frequências de chaveamento distintas, em uma ampla faixa de frequências. Os algoritmos k -NN, SVM/SMO e FAM apresentaram respectivamente 78,99%, 69,36% e 61,63% de precisão global, com substancial concordância no caso do algoritmo k -NN, e moderada concordância para os algoritmos SVM/SMO e FAM.

Tabela 5.12 – Matriz de confusão (Motor 1) - Multiclassificação de curto-circuito de estator - Filtro Digital

Classes Preditas										
FAM						SVM/SMO				
Classes	Normal	1%	3%	5%	10%	Normal	1%	3%	5%	10%
Normal	409	292	40	11	1	613	133	6	1	0
1%	211	371	91	11	3	313	303	61	9	1
3%	84	110	363	100	15	62	79	446	81	4
5%	21	33	123	432	60	9	20	139	467	34
10%	1	3	20	89	553	0	1	16	87	562
k -NN						PMC				
Classes	Normal	1%	3%	5%	10%	Normal	1%	3%	5%	10%
Normal	597	127	26	3	0	555	184	8	6	0
1%	175	449	59	4	0	154	513	12	7	1
3%	33	66	523	44	6	10	54	570	37	1
5%	15	11	69	538	36	3	8	46	592	20
10%	1	0	10	39	616	0	1	4	43	618

Na Tabela 5.12, distinguem-se faixas de falhas independentes obtidas a partir dos algoritmos de classificação comparados neste trabalho. No algoritmo PMC a precisão para a classificação de falhas de 3%, 5% e 10% de curto-circuito de estator é superior a 85%. No caso do algoritmo k -NN o índice de precisão para esta mesma faixa é superior a 77%.

Já os algoritmos FAM e SVM/SMO, apresentam índices de precisão superiores a 85% somente para as falhas de 10% de curto-circuito de estator. Neste cenário, o desempenho para identificação de motor sem defeito foi de 81,4% para o algoritmo SVM/SMO, seguido pelos algoritmos k -NN e PMC, respectivamente com 79,3% e 77,3% de precisão.

Em relação ao tempo computacional, em comparação com os métodos k -NN, FAM e SVM/SMO, observa-se que o algoritmo PMC demanda tempo para construção dos mode-

los, fato este compensado pela elevada taxa de precisão individual por classe avaliada para os diferentes tipos de inversores de frequência operando em todas as faixas de frequência, principalmente, em comparação com os classificadores SVM/SMO e FAM.

As Tabelas 5.13 e 5.14 exibem os resultados de classificação de um conjunto de dados constituído por 1180 ensaios experimentais, resultado assim em 3450 amostras utilizadas para treinamento e validação dos classificadores operando na classificação simples de falha (motor com defeito / motor sem defeito) para o Motor 2.

Tabela 5.13 – Resultados experimentais - Classificação de falhas de curto-circuito de estator (Motor 2) - Filtro Digital

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	75,47	84,34	85,68	87,53
Instâncias incorretamente classificadas (%)	24,53	15,66	14,32	12,47
Estatística Kappa	0,31	0,44	0,56	0,61
Erro absoluto médio	0,24	0,15	0,14	0,13
Erro quadrático	0,49	0,39	0,37	0,32
Erro absoluto relativo (%)	76,35	48,73	44,65	41,92
Erro quadrático relativo (%)	123,59	98,74	94,41	80,11
Tempo para criação do modelo (s)	0,34	3,18	0,01	421,6

A Tabela 5.13 mostra que os algoritmos PMC, k -NN e SVM/SMO, trabalhando na configuração de multi-classificação de defeitos de curto-circuito de estator, apresentam precisão global superior a 84%. O algoritmo PMC apresenta substancial concordância com os resultados obtidos nos testes, enquanto os algoritmos k -NN e SVM/SMO apresentam moderada concordância com os resultados obtidos nos testes. O algoritmo FAM obteve 75,47% de precisão global, e fraca concordância com os resultados obtidos nos testes.

Tabela 5.14 – Matriz de confusão (Motor 2) - Classificação de curto-circuito de estator - Filtro Digital

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	378	315	304	389	469	224	491	202
Falha	531	2226	151	2606	270	2487	228	2529

A Tabela 5.14 demonstra que o algoritmo PMC possui precisão de 91,7% para classificação motor com defeito e 70,9% para classificação do motor sem defeito. Neste cenário, os algoritmos SVM/SMO e k -NN atingem respectivamente 94,5% e 90,2% de precisão na indicação de motor com defeito. O algoritmo FAM apresenta 54,5% de precisão para motor sem defeito e 80,7% para classificação de motor com defeito de curto-circuito de estator.

As Tabelas 5.15 e 5.16 exibem os resultados de classificação do conjunto constituído por 1180 ensaios experimentais, na mesma faixa de frequência e conjugado de carga dos ensaios anteriores. Assim, tem-se 3450 amostras utilizadas para treinamento e validação dos classificadores operando na multiclassificação de falhas de curto-circuito de estator para o Motor 2.

A Tabela 5.15, permite observar que os algoritmos PMC e k -NN, trabalhando na configuração de multiclassificação de falhas de curto-circuito de estator para o Motor

Tabela 5.15 – Resultados experimentais - Multiclassificação de falhas de curto-circuito de estator (Motor 2) - Filtro Digital

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	64,98	68,02	76,23	78,31
Instâncias incorretamente classificadas (%)	35,02	31,98	23,77	21,69
Estatística Kappa	0,56	0,60	0,70	0,72
Erro absoluto médio	0,14	0,25	0,09	0,09
Erro quadrático	0,37	0,34	0,30	0,25
Erro absoluto relativo (%)	43,77	80,11	77,02	64,46
Erro quadrático relativo (%)	93,56	85,25	77,05	64,46
Tempo para criação do modelo (s)	1,58	4,92	0,01	428,6

2 apresentam precisão global superior a 84,92%. Ambos PMC, *k*-NN e SVM/SMO algoritmos apresentam substancial concordância com os resultados obtidos nos testes. O algoritmo FAM obteve novamente o menor índice de precisão global atingindo 64,98% e moderada concordância com os resultados obtidos nos testes.

Tabela 5.16 – Matriz de confusão (Motor 2) - Multiclassificação de curto-circuito de estator - Filtro Digital

Classes Preditas										
FAM						SVM/SMO				
Classes	Normal	1%	3%	5%	10%	Normal	1%	3%	5%	10%
Normal	392	253	36	9	3	469	196	27	1	0
1%	216	372	67	14	3	329	267	74	2	0
3%	51	85	408	132	14	57	75	484	74	0
5%	9	21	141	467	52	12	6	146	509	17
10%	0	2	14	86	603	0	0	7	80	618
<i>k</i> -NN						PMC				
Classes	Normal	1%	3%	5%	10%	Normal	1%	3%	5%	10%
Normal	463	211	19	0	0	469	199	14	7	4
1%	230	415	26	1	0	184	429	40	13	6
3%	31	63	539	56	1	5	32	591	60	2
5%	6	7	104	570	3	4	2	113	550	21
10%	0	0	3	59	643	0	0	2	40	663

Na Tabela 5.16 observa-se que o algoritmo PMC atingiu precisões de 67,7%, 63,8%, 85,7%, 79,7% e 94% respectivamente para classificação de motor sem defeitos, falhas de 1%, 3%, 5% e 10% de curto-circuito de estator. Índices ligeiramente inferiores foram obtidos pelo algoritmo *k*-NN, que foi apresentou desempenho superior apenas para identificação de falhas de 5% de curto-circuito de estator, atingindo nesta classe precisão igual a 82,6%.

Os algoritmos FAM e SVM/SMO obtiveram índices de precisão superiores a 85% somente para as falhas de 10% de curto-circuito de estator. Neste cenário, o desempenho para identificação de motor sem defeito foi de 67,7% para o algoritmo SVM/SMO, seguido pelos algoritmos *k*-NN e PMC, com 66,8% e 56,6% de precisão, respectivamente.

5.1.3 Comparativo entre Filtro Analógico e Filtro Digital - Falhas de Curto-Circuito de Estator

O gráfico apresentado na Figura 5.1, descreve os índices de precisão individuais por classe de falhas obtidos para o Motor 1, para cada um dos métodos avaliados. Os re-

sultados obtidos em todos os cenários mostram que, independentemente do tipo de filtro aplicado, os algoritmos SVM/SMO, k -NN e PMC possuem precisão superior a 90% para classificação de motor com defeito. No caso da classificação de motor sem defeito, os melhores resultados foram obtidos pelos algoritmos k -NN e PMC, que atingiram índices de precisão superiores a 70% de acerto, considerando a aplicação do filtro wavelet.

Figura 5.1 – Precisão de classificação - falhas de estator (Motor 1) - filtro analógico x digital

No gráfico da Figura 5.2, são descritos os índices de precisão para multiclassificação do nível de severidade das falhas obtida para o Motor 1 ao longo da faixa de 12 a 60 Hz, para cada um dos métodos avaliados. O algoritmo PMC obteve os melhores índices de precisão por nível de severidade de curto-circuito estator, com resultados ligeiramente superiores para identificação de motor normal e 1% de curto-circuito de estator para as classificações realizadas com auxílio do filtro digital. Já no caso da indicação das falhas de 3%, 5% e 10% a precisão de classificação utilizando o filtro analógico foi ligeiramente superior. Os resultados obtidos em todos os cenários mostram que, independentemente do tipo de filtro aplicado, os algoritmos k -NN e PMC possuem precisão superior a 60% para multiclassificação de falhas de curto-circuito de estator.

Já o gráfico apresentado na Figura 5.3, descreve os índices de precisão individuais por classe de falhas obtidos para o Motor 2, para cada um dos métodos avaliados. Os resultados mostram que independente do tipo de filtro aplicado, os algoritmos SVM/SMO, k -NN e PMC possuem precisão superior a 90% para classificação do motor com defeito. No caso da classificação de motor sem defeito, o melhor resultado foi obtido pelo algoritmo PMC, que obteve índices de precisão superiores a 70% de acerto, em ambos os cenários.

Ainda a Figura 5.4, descreve os índices de precisão da multiclassificação por nível de severidade das falhas obtidos para o Motor 2 ao longo da faixa de 12 a 60 Hz, para cada um dos métodos avaliados. A classificação das falhas de 3%, 5% e 10% de curto-circuito

Figura 5.2 – Precisão de multiclassificação - falhas de estator (Motor 1) - filtro analógico x digital

Figura 5.3 – Precisão de classificação - falhas de estator (Motor 2) - filtro analógico x digital

de estator foi superior com o filtro analógico. Nesta faixa, os algoritmos k -NN e PMC obtiveram índices de precisão superiores a 80%. Novamente, no caso da identificação de motor normal e 1% de curto-circuito de estator os melhores resultados foram obtidos com auxílio do filtro digital para os algoritmos k -NN e PMC. O algoritmo PMC com filtro analógico mostrou precisão superior a 70% para multiclassificação do nível de severidade das falhas de curto-circuito de estator.

Em relação ao tempo computacional, na comparação com os métodos k -NN, FAM e SVM/SMO, observa-se que o algoritmo PMC consome demasiado tempo para construção dos modelos, fato este compensado pela elevada taxa de precisão individual por classe avaliada para os diferentes tipos de inversores de frequência operando em todas as faixas

Figura 5.4 – Precisão de multiclassificação - falhas de estator (Motor 2) - filtro analógico x digital

de frequência, principalmente, em comparação com os classificadores SVM/SMO e FAM. Observa-se ainda que o tempo computacional é maior para as classificações utilizando filtro digital.

5.2 Resultados de Classificação - Falhas de Barras Quebradas de Rotor

Nesta seção são apresentados os resultados obtidos pelos classificadores no diagnóstico de falhas de barras quebradas de rotor, utilizando como entradas as correntes trifásicas dos MIT acionados por modelos distintos de inversores de frequência. As estratégias de classificação propostas foram submetidas ao treinamento com os sinais de entrada e parâmetros utilizados nos classificadores conforme descrito no Capítulo 4. Na sequência, são apresentados os resultados de classificação considerando os sinais de corrente trifásicas de estator utilizados como entrada para os classificadores submetidos a filtragem analógica e digital. Da forma similar ao apresentado na Seção 5.1, os motores analisados nesta seção foram submetidos a uma ampla variação de conjugado da carga ($10\% < T_n < 110\%$) operando com variação de frequência de 12 a 60 Hz.

5.2.1 Classificações de Barras Quebradas de Rotor - Filtro Analógico

As Tabelas 5.17 e 5.18 apresentam os resultados de classificação do conjunto composto por 1274 ensaios experimentais coletados com o Motor 3 acionado pelos inversores do LSI.

Gera-se assim um conjunto de 3822 amostras utilizadas para o treinamento e a validação dos classificadores.

Tabela 5.17 – Resultados experimentais - Classificação de falhas de barras quebradas de rotor (Motor 3) - Filtro Analógico

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	77,15	86,58	91,47	89,27
Instâncias incorretamente classificadas (%)	22,84	13,42	8,52	10,72
Estatística Kappa	0,37	0,43	0,73	0,63
Erro absoluto médio	0,23	0,13	0,08	0,12
Erro quadrático	0,48	0,36	0,29	0,29
Erro absoluto relativo (%)	72,82	42,79	27,27	40,72
Erro quadrático relativo (%)	120,70	92,73	73,74	73,46
Tempo para criação do modelo (s)	0,35	11,51	0,01	388,62

A Tabela 5.17 permite observar que o algoritmo *k*-NN apresentou maior precisão global atingindo 91,47% de acerto, enquanto o algoritmo PMC atingiu 89,27% de precisão global. O índice Kappa de ambos os algoritmos sugere substancial concordância com os resultados obtidos nos testes, confirmando assim a capacidade de generalização do método. Os algoritmos SVM/SMO e FAM, respectivamente, atingiram precisão global de 86,57% e 77,15%.

Tabela 5.18 – Matriz de confusão (Motor 3) - Classificação de barras quebradas de rotor - Filtro Analógico

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	464	280	254	490	620	124	470	274
Falha	593	2485	23	3055	202	2876	136	2942

A Tabela 5.18 permite observar que o algoritmo *k*-NN apresenta precisão igual a 83,3% para classificação de motor sem defeito e 93,4% de precisão para classificação de motor com defeito. Já o algoritmo PMC apresenta precisão de 63,2% para classificação de motor sem defeito e 95,6% para classificação de motor com defeito de barras quebradas de rotor. Os algoritmos FAM e SVM/SMO apresentaram 62,4% e 34,1% para motor sem defeito e 80,7% e 99,3% para motor com defeito de barras quebradas de rotor, respectivamente.

As Tabelas 5.19 e 5.20 apresentam os resultados de multiclassificação do conjunto composto por 1274 ensaios experimentais coletados de todos os inversores, para o Motor 3.

Tabela 5.19 – Resultados experimentais - Multiclassificação de falhas de barras quebradas de rotor (Motor 3) - Filtro Analógico

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	40,94	31,16	50,44	40,58
Instâncias incorretamente classificadas (%)	59,05	68,84	49,66	59,42
Estatística Kappa	0,26	0,10	0,37	0,24
Erro absoluto médio	0,23	0,30	0,19	0,25
Erro quadrático	0,48	0,40	0,44	0,38
Erro absoluto relativo (%)	74,11	94,67	62,25	82,25
Erro quadrático relativo (%)	121,75	100,47	111,45	97,55
Tempo para criação do modelo (s)	5,98	7,16	0,01	423,03

Neste cenário, observa-se a partir da Tabela 5.19 que os algoritmos possuem precisão global inferior a 50% na configuração de multiclassificação de defeitos de barras quebradas de rotor, evidenciando assim a dificuldade no diagnóstico da severidade de barras quebradas de rotor a partir da simples utilização dos sinais de corrente de estator no domínio do tempo.

Tabela 5.20 – Matriz de confusão (Motor 3) - Multiclassificação de barras quebradas de rotor - Filtro Analógico

Classes preditas										
FAM						SVM/SMO				
Classes	Normal	1 B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal	540	76	47	40	41	282	389	18	54	1
1 B	80	390	182	159	107	28	710	42	121	17
2 B	44	203	253	163	108	44	581	28	101	17
4 B	66	165	167	239	140	25	545	36	158	13
2/2 B	53	144	137	135	143	26	462	31	80	13
<i>k</i> -NN						PMC				
Classes	Normal	1 B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal	627	48	30	18	21	542	108	40	36	18
1 B	63	492	176	108	79	100	465	146	121	86
2 B	48	181	329	128	85	72	255	202	154	88
4 B	49	170	168	282	108	53	250	158	223	93
2/2 B	41	128	122	123	198	69	115	115	127	119

Muito embora os resultados globais não apresentem elevado índice de precisão, ainda assim é possível observar por intermédio da Tabela 5.20, que o algoritmo *k*-NN apresenta precisão igual a 84,3% para classificação de motor sem defeito, seguido pelos algoritmos FAM e PMC respectivamente com 76,2% e 72,8% de precisão.

As Tabelas 5.21 e 5.22 apresentam os resultados de classificação do conjunto composto por 1177 ensaios experimentais para o Motor 4, gerando assim um conjunto de 3531 amostras para treinamento e validação dos classificadores.

Tabela 5.21 – Resultados experimentais - Classificação de falhas de barras quebradas de rotor (Motor 4) - Filtro Analógico

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	63,07	79,69	74,62	77,59
Instâncias incorretamente classificadas (%)	36,93	20,30	25,37	22,41
Estatística Kappa	0,04	0	0,14	0,11
Erro absoluto médio	0,36	0,20	0,25	0,27
Erro quadrático	0,60	0,45	0,50	0,43
Erro absoluto relativo (%)	114,06	62,71	78,42	84,71
Erro quadrático relativo (%)	151,06	112,01	125,18	107,26
Tempo para criação do modelo (s)	0,45	74,75	0,01	368,24

Observa-se a partir da Tabela 5.21 que o algoritmo SVM/SMO apresentou melhor precisão global, atingindo 79,69% de acerto. No entanto, a estatística Kappa indica não haver qualquer concordância além do puro acaso. O algoritmo PMC obteve 77,59% de acerto global, seguido pelos algoritmos *k*-NN e FAM, respectivamente com 74,62 e 63,07%, todos com ambos com ligeira concordância entre os resultados obtidos nos testes.

A partir da Tabela 5.22 é possível observar que o algoritmo PMC atingiu precisões de 93,3% para classificação de motor com falha e apenas 16% de precisão para classificação de

Tabela 5.22 – Matriz de confusão (Motor 4) - Classificação de barras quebradas de rotor - Filtro Analógico

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	250	467	0	717	194	523	115	602
Falha	837	1977	0	2814	373	2441	189	2625

motor sem falha. O algoritmo k -NN, obteve precisão de 86,7% para classificação de motor com falha e 27,1% para classificação de motor sem defeito. Já o algoritmo SVM/SMO classificou 100% das amostras como motor com falha de barras de rotor. O algoritmo FAM apresentou o maior índice de precisão para motor saudável, obtendo 34,9% de precisão.

As Tabelas 5.23 e 5.24 apresentam os resultados da multiclassificação de barras quebradas de rotor para o conjunto composto por 1177 ensaios experimentais para o Motor 4, operando em regime permanente nas diversas condições de carga, gerando assim um conjunto de 3531 amostras para treinamento e validação.

Tabela 5.23 – Resultados experimentais - Multiclassificação de falhas de barras quebradas de rotor (Motor 4) - Filtro Analógico

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	26,59	22,17	34,35	30,81
Instâncias incorretamente classificadas (%)	73,40	77,83	65,65	69,18
Estatística Kappa	0,08	0,02	0,14	0,13
Erro absoluto médio	0,29	0,31	0,26	0,28
Erro quadrático	0,54	0,41	0,51	0,42
Erro absoluto relativo (%)	91,76	98,72	82,09	90,51
Erro quadrático relativo (%)	135,47	104,11	128,01	105,41
Tempo para criação do modelo (s)	3,96	6,48	0,01	373,57

Para a multiclassificação de barras quebradas de rotor, observa-se a partir da Tabela 5.23, que os algoritmos possuem precisão global inferior a 34% de defeitos. Para ambos os algoritmos, a estatística Kappa não indica concordância, evidenciando assim a dificuldade para multiclassificar a severidade das barras quebradas de rotor a partir da simples utilização dos sinais de corrente de estator no domínio do tempo.

Tabela 5.24 – Matriz de confusão (Motor 4) - Multiclassificação de barras quebradas de rotor

		Classes Preditas									
		FAM					SVM/SMO				
Classes		Normal	1 B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal		189	152	118	135	123	190	202	125	86	114
1 B		123	233	143	100	118	189	203	140	66	119
2 B		131	153	177	140	101	158	194	124	89	137
4 B		140	123	155	154	124	177	160	125	117	117
2/2 B		134	152	114	113	186	167	168	143	72	149
		k -NN					PMC				
Classes		Normal	1B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal		199	111	129	162	116	214	112	171	108	112
1 B		79	271	139	123	105	105	219	170	78	145
2 B		87	103	256	156	100	90	91	312	107	102
4 B		95	107	179	213	102	131	108	199	134	124
2/2 B		88	108	129	100	274	110	122	158	100	209

Na Tabela 5.24, é possível observar que o algoritmo k -NN atingiu precisões de 27,8%, 37,8%, 36,5%, 30,6% e 39,2% respectivamente para classificação de motor sem defeitos,

falhas de 1, 2, 4 e 2/2 barras quebradas de rotor. Índices ligeiramente inferiores foram obtidos pelo algoritmo PMC, que apresentou desempenho superior para o motor operando em condições normais e motor com 2 barras quebradas de rotor, atingindo nestas classes precisão igual a 29,8% e 44,4%, respectivamente.

Para os casos em que os Motores 3 e 4 foram acionados apenas por um único inversor de frequência, considerando classificação simples (motor com defeito/motor sem defeito), os melhores resultados foram obtidos a partir dos dados experimentais coletados utilizando o inversor Siemens MM440, sendo obtida precisão global de 80,9 %.

5.2.2 Classificações de Barras Quebradas de Rotor - Filtro Digital

Nesta subseção são apresentados os resultados de classificação considerando a utilização da TWD como filtro digital. Os parâmetros definidos para execução destes testes foram descritos na Subseção 4.7. As estratégias de classificação propostas foram submetidas ao treinamento com os sinais de entrada tratados com filtro digital conforme descrito na Seção 4.2.2.

As Tabelas 5.25 e 5.26 apresentam os resultados de classificação do conjunto composto por 1019 ensaios experimentais referentes a todos os inversores para o Motor 3. Tem-se assim um conjunto de 3057 amostras utilizadas para treinamento e validação dos classificadores.

Tabela 5.25 – Resultados experimentais - Classificação de falhas de barras quebradas de rotor (Motor 3) - Filtro Digital

Atributos	FAM	SVM/SMO	k-NN	PMC
Instâncias corretamente classificadas (%)	72,98	79,66	87,34	84,59
Instâncias incorretamente classificadas (%)	27,02	20,31	12,65	15,40
Estatística Kappa	0,26	0	0,61	0,46
Erro absoluto médio	0,27	0,20	0,12	0,17
Erro quadrático	0,51	0,45	0,3557	0,35
Erro absoluto relativo (%)	83,42	62,72	39,17	52,71
Erro quadrático relativo (%)	129,19	112,02	88,40	87,52
Tempo para criação do modelo (s)	0,28	48,08	0,03	314,66

Ao longo destes testes, observa-se a partir da Tabela 5.25 que o algoritmo *k*-NN apresentou a melhor precisão global, atingindo 87,34% de acerto e substancial concordância com os resultados obtidos nos testes, confirmando assim a capacidade de generalização do método proposto para diferentes modelos de inversores com frequências de chaveamento distintas, em uma ampla faixa de frequências e conjugado de carga, utilizando o filtro TWD durante a etapa de pré-processamento dos sinais de corrente.

O algoritmo PMC apresentou precisão global de 84,59%, seguido pelos algoritmos SVM/SMO e FAM, respectivamente com 79,68% e 72,98%.

A Tabela 5.26, mostra que o classificador *k*-NN possui precisão de 72,15% para classificação de motor sem defeito e 91,2% para classificação de motor com barras quebradas

Tabela 5.26 – Matriz de confusão (Motor 3) - Classificação de barras quebradas de rotor - Filtro Digital

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	323	298	0	621	448	173	298	323
Falha	528	1908	0	2436	214	2222	148	2288

de rotor, seguido pelo classificador PMC que apresenta precisão de 48% para motor sem defeitos e 93,9% para motor com barras quebradas de rotor.

O classificador SVM/SMO atinge 100% de precisão na indicação de motor com barras de rotor quebradas. Entretanto, na classificação de motor sem defeito o método errou 100% das amostras testadas. O classificador FAM apresenta 52,4% para motor sem defeito e 78,3% de precisão para identificação de motor com barras quebradas de rotor.

As Tabelas 5.27 e 5.28 apresentam os resultados de classificação do conjunto composto por 1019 ensaios experimentais coletados de todos os inversores na faixa de 12 a 60 Hz, para o Motor 3 operando em regime permanente nas diversas condições de carga, gerando assim um conjunto de 2093 amostras utilizadas para o treinamento e a validação dos classificadores.

Tabela 5.27 – Resultados experimentais - Multiclassificação de falhas de barras quebradas de rotor (Motor 3) - Filtro Digital

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	40,00	31,99	56,65	50,67
Instâncias incorretamente classificadas (%)	59,99	68,00	43,34	49,32
Estatística Kappa	0,25	0,14	0,45	0,38
Erro absoluto médio	0,24	0,30	0,17	0,21
Erro quadrático	0,48	0,40	0,416	0,37
Erro absoluto relativo (%)	74,99	94,11	54,26	66,98
Erro quadrático relativo (%)	122,46	100,09	104,00	93,94
Tempo para criação do modelo (s)	1,49	5,61	0,01	285,19

A Tabela 5.27 mostra os resultados obtidos para os algoritmos trabalhando como multiclassificadores. Novamente, é possível observar que a aplicação do filtro TWD nos sinais de corrente de estator possibilita incremento a precisão global de classificação. No entanto, a precisão global dos algoritmos foi inferior a 60%. Os algoritmos *k*-NN e PMC atingiram precisão global de 56,65% e 50,67% respectivamente. O índice Kappa obtido pelo classificador *k*-NN indica moderada concordância entre resultados obtidos nos testes.

A matriz de confusão da Tabela 5.28, mostra que o algoritmo *k*-NN possui precisão de 71,8% para diagnóstico de motor sem defeito, 56,5% para identificação de motor com defeito de 1 barra de rotor e respectivamente 55,8%, 51,3% e 47,2% de precisão para diagnóstico de falhas de 2, 4 e 2/2 (diametralmente opostas) barras quebradas de rotor. Neste mesmo cenário, o algoritmo PMC apresenta precisão de 61,8% para motor sem defeito e 35,5%, 42,7%, 54,9% e 58,2% respectivamente, para 1, 2, 4 e 2/2 (diametralmente opostas) barras quebradas de rotor.

No caso da classificação simples de barras quebradas de rotor, o desempenho obtido com a aplicação do filtro analógico é ligeiramente superior ao obtido com o filtro digital.

Tabela 5.28 – Matriz de confusão (Motor 3) - Multiclassificação de barras quebradas de rotor - Filtro Digital

		Classes preditas									
		FAM					SVM/SMO				
Classes	Normal	1 B	2 B	4 B	2/2 B		Normal	1 B	2 B	4 B	2/2 B
Normal	320	98	64	75	64		312	96	59	60	94
1 B	99	220	138	60	95		231	104	81	86	110
2 B	64	116	229	91	109		179	111	118	73	128
4 B	80	70	110	241	111		183	85	54	159	131
2/2 B	71	105	118	96	213		153	72	53	40	285
		<i>k</i> -NN					PMC				
Classes	Normal	1 B	2 B	4 B	2/2 B		Normal	1 B	2 B	4 B	2/2 B
Normal	446	76	37	34	28		384	61	57	64	55
1 B	81	346	107	39	39		93	218	157	66	78
2 B	48	97	340	52	72		80	113	260	58	98
4 B	56	58	93	314	91		78	44	55	336	99
2/2 B	42	72	98	105	286		63	51	68	70	351

No entanto, para a multiclassificação de defeitos, o filtro digital apresenta desempenho superior. Tais características aplicam-se tanto para classificação considerando apenas um inversor quanto para classificações considerando os três modelos de inversores investigados neste trabalho. Independentemente do tipo de filtro aplicado, o algoritmo *k*-NN apresenta os maiores índices de precisão, seguido pelos classificadores PMC, FAM e SVM/SMO.

As Tabelas 5.29 e 5.30 apresentam os resultados de classificação do conjunto composto por 1177 ensaios experimentais coletados para o Motor 4, gerando assim um conjunto de 3531 amostras utilizadas para treinamento e validação dos classificadores.

Tabela 5.29 – Resultados experimentais - Classificação de falhas de barras quebradas de rotor (Motor 4) - Filtro Digital

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	63,72	79,69	74,87	77,62
Instâncias incorretamente classificadas (%)	36,28	20,30	25,12	22,38
Estatística Kappa	0,08	0	0,20	0,07
Erro absoluto médio	0,36	0,20	0,25	0,27
Erro quadrático	0,60	0,45	0,50	0,42
Erro absoluto relativo (%)	112,5	62,71	77,63	86,44
Erro quadrático relativo (%)	149,72	112,01	124,55	106,85
Tempo para criação do modelo (s)	0,34	62,58	0,01	353,43

Analisando a Tabela 5.29 é possível observar que o algoritmo SVM apresenta melhor precisão global de classificação, atingindo 79,69% de precisão global, seguido pelos algoritmos PMC, *k*-NN e FAM, respectivamente com 77,62%, 74,87% e 63,72% de precisão global. Entretanto, todos os classificadores obtiveram um baixo índice Kappa, o que indica não haver qualquer concordância dos resultados.

Tabela 5.30 – Matriz de confusão (Motor 4) - Classificação de barras quebradas de rotor - Filtro Digital

		Classes preditas							
		FAM		SVM/SMO		<i>k</i> -NN		PMC	
Classes		Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal		248	469	0	717	245	472	78	639
Falha		812	2002	0	2814	415	2399	151	2663

A Tabela 5.30, demonstra que os melhores resultados foram obtidos pelo algoritmo k -NN que obteve precisão de 34,2% para classificação do motor sem defeito, e 85,3% para classificação de motor com defeito. O algoritmo SVM/SMO não obteve sucesso na classificação de nenhuma amostra do motor sem defeito. O algoritmo FAM obteve 34,6% de precisão para motor sem defeito e 71,1% para classificação de motor sem defeito de barras quebradas de rotor.

Nas Tabelas 5.31 e 5.32 são apresentados os resultados considerando a classificação do nível de severidade da falha a qual é composta por 1177 ensaios para o Motor 4, gerando assim um conjunto de 3531 amostras utilizadas para treinamento e validação dos classificadores.

Tabela 5.31 – Resultados experimentais - Multiclassificação de falhas de barras quebradas de rotor (Motor 4) - Filtro Digital

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	28,83	22,57	37,10	28,29
Instâncias incorretamente classificadas (%)	71,17	77,43	62,90	71,70
Estatística Kappa	0,11	0,03	0,21	0,10
Erro absoluto médio	0,28	0,31	0,25	0,29
Erro quadrático	0,53	0,41	0,50	0,41
Erro absoluto relativo (%)	88,96	98,10	78,66	93,17
Erro quadrático relativo (%)	133,39	103,53	125,30	104,63
Tempo para criação do modelo (s)	2,99	6,17	0,01	361,03

Analisando a Tabela 5.31 é possível observar que o algoritmo k -NN apresenta melhor precisão global de classificação, atingindo 37,10% de precisão global, seguido pelos algoritmos PMC, k -NN e FAM, respectivamente com 28,29%, 28,3% e 22,57% de precisão global. Novamente, todos os classificadores obtiveram um baixo índice Kappa, indicando não haver qualquer concordância dos resultados obtidos além do puro acaso.

Tabela 5.32 – Matriz de confusão (Motor 4) - Multiclassificação de barras quebradas de rotor - Filtro Digital

Classes Preditas										
FAM							SVM/SMO			
Classes	Normal	1 B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal	214	101	129	144	129	128	291	145	79	74
1 B	109	228	137	106	137	95	326	177	58	61
2 B	136	152	165	142	107	109	279	157	84	73
4 B	162	108	137	181	108	128	270	149	88	61
2/2 B	118	131	114	106	230	93	278	171	59	98
k -NN							PMC			
Classes	Normal	1B	2 B	4 B	2/2 B	Normal	1 B	2 B	4 B	2/2 B
Normal	251	87	119	155	105	210	90	174	120	123
1 B	81	277	133	107	119	131	193	146	70	177
2 B	79	115	252	166	90	177	101	202	121	101
4 B	142	96	153	226	79	185	89	175	127	120
2/2 B	96	119	102	78	304	115	110	122	85	267

A matriz de confusão da Tabela 5.32, mostra que o algoritmo k -NN possui precisão de 35% para diagnóstico de motor sem defeito, 38,6% para identificação de motor com defeito de 1 barra de rotor e respectivamente 35,9%, 32,5% e 43,5% de precisão para diagnóstico de falhas de 2, 4 e 2/2 (diametralmente opostas) barras quebradas de rotor. Neste mesmo

cenário, o algoritmo PMC apresenta precisão de 29,3% para motor sem defeito e 26,9%, 28,8%, 18,2% e 38,5% respectivamente, para 1, 2, 4 e 2/2 (diametralmente opostas) barras quebradas de rotor.

Para os casos em que os motores foram acionados apenas por um único inversor de frequência, considerando classificação simples (motor com defeito/motor sem defeito), os melhores resultados foram obtidos a partir dos dados experimentais coletados utilizando o inversor Schneider ATV12H075M2, sendo obtida precisão global de 80,6 %.

5.2.3 Comparativo entre Filtro Analógico e Filtro Digital - Falhas de Barras Quebradas de Rotor

O gráfico apresentado na Figura 5.5 descreve os índices de precisão individuais por classe de falhas obtidos para o Motor 3. O classificador k -NN obteve os melhores índices de classificação, atingindo precisão superior a 80%, no caso da configuração utilizando filtro analógico. Novamente, os resultados confirmam que o classificador SVM/SMO obteve os piores desempenhos de classificação. No caso dos dados treinados a partir da aplicação do filtro digital, o algoritmo SVM/SMO obteve 100% de erro.

Figura 5.5 – Precisão de classificação - barras quebradas de rotor (Motor 3) - filtro analógico x digital

Ainda em relação ao Motor 3, o gráfico da Figura 5.6, descreve os índices de precisão da multiclassificação por nível de severidade das falhas obtidos para o Motor 3 ao longo da faixa de 12 a 60 Hz, para cada um dos métodos avaliados. Neste cenário, os melhores índices foram obtidos pelo algoritmo k -NN treinado com dados obtidos a partir da aplicação do filtro digital. No caso da multiclassificação do nível de severidade das falhas de barras quebradas de rotor, os piores índices de precisão foram obtidos pelo classificador SVM/SMO. Novamente, os algoritmos k -NN e PMC apresentam os melhores índices de

desempenho, independentemente do tipo de filtro aplicado. Considerando a classificação de motor sem defeito, com o filtro analógico, foi possível obter índices superiores a 70% com os algoritmos FAM, k -NN e PMC.

Figura 5.6 – Precisão de multiclassificação - barras quebradas de rotor (Motor 3) - filtro analógico x digital

No caso do Motor 4, o gráfico da Figura 5.7 apresenta os índices de precisão individuais por classe de falhas para cada um dos métodos avaliados. Os resultados obtidos em todos os cenários mostram que independente do tipo de filtro aplicado, os resultados para diagnóstico de motor sem defeitos foram baixos. O algoritmo FAM obteve 70% de precisão para indicação de motor sem defeitos, no entanto, sua precisão para indicação de motor com defeitos foi inferior a 35%. O algoritmo SVM/SMO obteve os piores índices de classificação.

Já o gráfico da Figura 5.8, apresenta os índices de precisão para multiclassificação do nível de severidade das falhas de rotor para o Motor 4. No geral, os índices de precisão foram inferiores a 45% independente do método de classificação ou tipo de filtro utilizado. Novamente, os piores resultados de classificação são atribuídos ao classificador SVM/SMO e os melhores índices foram obtidos pelo classificador k -NN.

Assim, os resultados apresentados com base no emprego da análise das amplitudes dos sinais no domínio do tempo, aplicados aos classificadores de padrões FAM, SVM/SMO, k -NN e PMC apresentam baixas taxas de acerto em comparação com os resultados obtidos na classificação de defeitos de curto-circuito de estator.

Figura 5.7 – Precisão de classificação - falhas de rotor (Motor 4) - filtro analógico x digital

Figura 5.8 – Precisão de multiclassificação - falhas de rotor (Motor 4) - filtro analógico x digital

5.3 Resultados de Classificação - Falhas de Rolamentos - Laboratório de Sistemas Inteligentes

Nesta Seção são apresentados os resultados obtidos pelos classificadores no diagnóstico de falhas de rolamentos, considerando procedimento de geração das falhas conforme descrito na Seção 4.6.

Assim, seguindo os mesmos aspectos metodológicos utilizados nas Seções 5.1 e 5.2, as estratégias de classificação propostas foram submetidas ao treinamento com os sinais de entrada conforme descrito no Capítulo 4. Para tal, as amplitudes dos sinais das correntes trifásicas formam uma matriz de 150 pontos, em que cada ponto é apresentado como uma

entrada dos algoritmos de classificação, resultando assim em 3 amostras referentes a cada ensaio experimental realizado.

5.3.1 Classificações Rolamentos - Filtro Analógico

As Tabelas 5.33 e 5.34 apresentam os resultados de classificação do conjunto composto por 1173 ensaios experimentais, coletados de todos os inversores para o Motor 3. Tem-se assim 3519 amostras utilizadas para treinamento e validação dos classificadores configurados para a classificação de motor sem defeito / motor com defeito.

Tabela 5.33 – Resultados experimentais - Classificação de falhas de rolamentos (Motor 3) - Filtro Analógico

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	91,62	97,19	98,78	99,44
Instâncias incorretamente classificadas (%)	8,38	2,81	1,22	0,56
Estatística Kappa	0,65	0,87	0,95	0,97
Erro absoluto médio	0,08	0,02	0,01	0,01
Erro quadrático	0,28	0,16	0,11	0,06
Erro absoluto relativo (%)	34,59	11,60	5,16	2,46
Erro quadrático relativo (%)	83,20	48,20	37,75	20,09
Tempo para criação do modelo (s)	0,24	1,82	0,01	308,89

A partir da Tabela 5.33 é possível observar que o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 99,44% de precisão global, seguido pelos algoritmos k -NN, SVM/SMO e FAM, respectivamente com 98,78%, 97,19% e 91,62% de precisão global. Com exceção do classificador FAM, todos os classificadores obtiveram alto índice Kappa, indicando perfeita concordância dos resultados obtidos nos testes.

Tabela 5.34 – Matriz de confusão (Motor 3) - Classificação de falhas de rolamentos - Filtro Analógico

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	357	139	401	95	482	14	481	15
Falha	156	2868	4	3020	29	2994	5	3019

A matriz de confusão da Tabela 5.34, mostra que o algoritmo PMC possui precisão de 97% para o diagnóstico de motor sem defeito e 99,8% para identificação de motor com defeito de rolamento. O algoritmo k -NN apresenta precisão de 97,2% para motor sem defeito e 99% de precisão para indicação do motor com defeito. Neste mesmo cenário, os classificadores SVM/SMO e FAM também obtiveram elevados índices de precisão, obtendo respectivamente 80,8 % e 72,3 % para indicação de motor sem defeito e 99,9 %, 94,8 % para indicação de motor com defeito de rolamentos.

No caso da multiclassificação, foram consideradas 4 situações distintas de desgaste, a saber: desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Assim, as Tabelas 5.35 e 5.36 apresentam os resultados obtidos para o Motor 3 considerando a multiclassificação da evolução de uma falha de rolamento.

Tabela 5.35 – Resultados experimentais - Multiclassificação de falhas de rolamentos (Motor 3) - Filtro Analógico

Atributos	FAM	SVM/SMO	k-NN	PMC
Instâncias corretamente classificadas (%)	36,96	37,01	44,14	41,10
Instâncias incorretamente classificadas (%)	63,04	62,99	55,85	58,90
Estatística Kappa	0,20	0,20	0,30	0,26
Erro absoluto médio	0,25	0,29	0,22	0,24
Erro quadrático	0,50	0,38	0,47	0,38
Erro absoluto relativo (%)	79,23	91,13	70,24	76,84
Erro quadrático relativo (%)	125,88	96,90	118,96	96,42
Tempo para criação do modelo (s)	2,23	3,9	0,01	318,38

Os resultados apresentados na Tabela 5.35 mostram que o algoritmo k -NN apresenta melhor desempenho global de classificação, atingindo 44,14% de precisão global, seguido pelos algoritmos PMC, SVM/SMO e FAM, respectivamente com 41,10%, 37,01% e 36,96 % de precisão global. Para estes testes, todos os classificadores obtiveram baixos índices de concordância. Este fato confirma que os classificadores não conseguiram diferenciar com sucesso as diversas classes estabelecidas na metodologia proposta para determinação da evolução do desgaste de uma falha de rolamento.

Tabela 5.36 – Matriz de confusão (Motor 3) - Multiclassificação de falhas de rolamentos - Filtro Analógico

Classes	Classes previstas									
	FAM					SVM/SMO				
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
Normal	405	22	26	25	18	473	5	7	5	6
Inicial	10	212	164	189	175	9	285	168	169	119
Médio	11	164	223	197	155	11	230	200	172	137
Avançado	14	153	168	254	173	8	265	167	202	120
Severo	7	198	166	184	207	9	267	155	188	143
Classes	k -NN					PMC				
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
Normal	481	1	2	7	5	481	2	5	6	2
Inicial	5	230	135	160	220	8	205	178	210	149
Médio	4	127	278	172	169	7	109	317	159	158
Avançado	9	150	145	296	162	6	164	203	250	139
Severo	7	185	140	161	269	6	157	209	196	194

A matriz de confusão da Tabela 5.36 mostra que o algoritmo PMC manteve precisão de 97% para o diagnóstico do motor sem defeito. Este resultado é similar ao obtido na classificação de motor com defeito / motor sem defeito. No entanto, para a multiclassificação de severidade das falhas os índices de precisão obtidos foram respectivamente 27,3%, 42,3%, 32,8% e 25,8% para classificação de rolamento com nível de desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Nos testes efetuados com o algoritmo k -NN também foi mantido o mesmo nível de precisão para indicação de motor sem defeito; a saber: 97%. Em relação as classificações para evolução do desgaste foram obtidos índices de precisão de 30,7%, 37,1%, 38,8% e 35,3%, respectivamente. Novamente os algoritmos SVM/SMO e FAM também mantiveram similares os índices de precisão para indicação de motor sem defeito, sendo obtidos respectivamente 90,6% e 95,4%.

As Tabelas 5.37 e 5.38 apresentam os resultados de classificação do conjunto composto por 1186 ensaios experimentais para o Motor 4, considerando as mesmas condições descri-

tas para o Motor 3, com os classificadores configurados para diagnosticar motor operando sem falha ou motor operando com falha de rolamento.

Tabela 5.37 – Resultados experimentais - Classificação de falhas de rolamentos (Motor 4) - Filtro Analógico

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	71,83	79,84	83,89	85,57
Instâncias incorretamente classificadas (%)	28,17	20,16	16,11	15,43
Estatística Kappa	0,20	0	0,45	0,47
Erro absoluto médio	0,28	0,20	0,16	0,16
Erro quadrático	0,53	0,44	0,40	0,36
Erro absoluto relativo (%)	87,47	62,59	50	50,71
Erro quadrático relativo (%)	132,29	111,90	100,01	92,07
Tempo para criação do modelo (s)	0,37	30,18	0,01	350,86

Por meio da análise dos resultados mostrados na Tabela 5.37 é possível observar que o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 85,75% de precisão global, seguido pelos algoritmos k -NN, SVM/SMO e FAM, respectivamente com 83,89%, 79,84% e 71,83% de precisão global. Os classificadores PMC e k -NN apresentam índice Kappa que demonstra moderada concordância em relação aos resultados obtidos nos testes. Já o resultado apresentado pelo classificador SVM/SMO indica não haver qualquer concordância dos resultados obtidos além do puro acaso.

Tabela 5.38 – Matriz de confusão (Motor 4) - Classificação de falhas de rolamentos - Filtro Analógico

Classes preditas								
FAM			SVM/SMO		k-NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	313	404	0	717	356	361	362	355
Falha	598	2243	0	2841	212	2629	194	1647

A matriz de confusão da Tabela 5.38, mostra que o algoritmo PMC obteve precisão de 50,5% para diagnóstico de motor sem defeito e 93,2% para identificação de motor com defeito de rolamento. O algoritmo k -NN apresenta precisão de 49,7% para motor sem defeito e 92,5% de precisão para indicação de motor com defeito. O classificador FAM obteve respectivamente 43,7% e 79% de precisão para indicação de motor sem defeito e motor com defeito de rolamento. Já o algoritmo SVM/SMO obteve 100% de erro na classificação de motor sem defeito.

Nas Tabelas 5.39 e 5.40 são apresentados os resultados de classificação do conjunto composto por 1186 ensaios experimentais para o Motor 4.

Na Tabela 5.39 é possível observar que o algoritmo PMC apresenta melhor precisão global de classificação de severidade, atingindo 36,22% de precisão global, seguido pelos algoritmos k -NN, FAM e SVM/SMO, respectivamente com 34,76%, 26,58% e 26,51% de precisão global. Neste cenário de multiclassificação de falhas de rolamentos, as estratégias PMC e k -NN obtiveram índice Kappa que demonstra moderada concordância em relação aos resultados obtidos nos testes. Já os resultados obtidos pelos classificadores SVM/SMO e FAM indica não haver qualquer concordância dos resultados.

Tabela 5.39 – Resultados experimentais - Multiclassificação de falhas de rolamentos (Motor 4) - Filtro Analógico

Atributos	FAM	SVM/SMO	k-NN	PMC
Instâncias corretamente classificadas (%)	26,58	26,51	34,76	36,22
Instâncias incorretamente classificadas (%)	73,42	73,49	65,23	63,77
Estatística Kappa	0,08	0,08	0,18	0,20
Erro absoluto médio	0,29	0,30	0,26	0,26
Erro quadrático	0,54	0,40	0,51	0,41
Erro absoluto relativo (%)	91,76	96,46	81,57	84,09
Erro quadrático relativo (%)	135,47	101,78	127,60	103,49
Tempo para criação do modelo (s)	2,85	6,31	0,01	365,82

Tabela 5.40 – Matriz de confusão (Motor 4) - Multiclassificação de falhas de rolamentos - Filtro Analógico

Classes	Classes previstas									
	FAM					SVM/SMO				
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
Normal	298	119	91	97	112	427	86	49	98	57
Inicial	83	181	144	148	155	188	139	141	146	97
Médio	84	145	172	148	165	185	170	121	157	81
Avançado	102	155	164	138	149	189	147	123	166	83
Severo	111	132	172	136	157	225	154	116	123	90
Classes	k-NN					PMC				
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
Normal	357	86	88	97	89	518	31	51	57	60
Inicial	46	228	153	149	135	67	130	164	159	191
Médio	51	164	205	146	148	66	119	220	161	148
Avançado	64	120	154	211	159	57	117	153	204	177
Severo	50	116	152	154	236	89	100	154	148	217

A matriz de confusão da Tabela 5.40, mostra que o algoritmo PMC obteve precisão de 72,2% para diagnóstico de motor sem defeito, no entanto, para a multiclassificação de severidade os índices de precisão obtidos foram respectivamente 18,3%, 30,8%, 28,8% e 30,6% para classificação de rolamento com nível de desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Nos testes efetuados com o algoritmo *k*-NN para os mesmos cenários foram obtidos índices de precisão de 49,8%, 32,12%, 28,7%, 29,8% e 33%, respectivamente. Os algoritmos SVM/SMO e FAM obtiveram índices de precisão para indicação de motor sem defeito de 59,6% e 41,6%.

Em relação aos testes de classificações considerando exclusivamente dados de um único inversor, especificamente no caso de classificação de motor sem falha/motor com defeito de rolamentos, foram obtidos índices de precisão superiores a 89,9% para indicação de motor sem defeito e percentuais superiores a 92,2% para os casos de motor operando com defeito de rolamentos. No caso dos classificadores PMC e *k*-NN foram obtidos índices Kappa superiores a 0,8, o que indica perfeita concordância com os resultados obtidos nos testes. Ainda na multiclassificação de severidade das falhas de rolamento, considerando o inversor MM440, com o algoritmo PMC foram atingidos percentuais de 85,7% para indicação de motor sem defeito e respectivamente 38%, 47,3%, 36,4% e 37,7% para classificação de rolamento com nível de desgaste inicial, desgaste médio, desgaste avançado e desgaste severo.

5.3.2 Classificações de Falhas de Rolamentos - Filtro Digital

Nesta subseção são apresentados os resultados de classificação de falhas de rolamentos considerando a utilização da TWD como filtro digital e os parâmetros definidos para execução deste teste foram descritos na Subseção 4.2. As estratégias de classificação propostas foram submetidas ao treinamento com os sinais de entrada tratados com filtro digital conforme descrito na Seção 4.2.2.

As Tabelas 5.41 e 5.42 exibem os resultados de classificação do conjunto também composto por 1228 ensaios experimentais coletados de todos os inversores na faixa de 12 a 60 Hz, para o Motor 3, operando em regime permanente para as diversas condições de carga. Tem-se assim um conjunto de 3684 amostras utilizadas para treinamento e validação dos classificadores utilizados neste trabalho os quais estão configurados para classificação de motor operando sem falha ou motor operando com falha de rolamento.

Tabela 5.41 – Resultados experimentais - Classificação de falhas de rolamentos (Motor 3) - Filtro Digital

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	88,70	94,21	97,69	99,07
Instâncias incorretamente classificadas (%)	11,30	5,79	2,31	0,93
Estatística Kappa	0,65	0,79	0,92	0,96
Erro absoluto médio	0,11	0,05	0,02	0,01
Erro quadrático	0,33	0,24	0,15	0,08
Erro absoluto relativo (%)	38,37	19,64	7,93	3,65
Erro quadrático relativo (%)	87,62	62,70	39,59	23,24
Tempo para criação do modelo (s)	0,29	1,25	0,03	310,49

A partir da Tabela 5.41 é possível observar que o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 99,07% de precisão global, seguido pelos algoritmos *k*-NN, SVM/SMO e FAM, respectivamente com 97,69%, 94,21% e 88,70% de precisão global. Os classificadores PMC e *k*-NN apresentam índice Kappa superiores a 0,92, indicando perfeita concordância em relação aos resultados obtidos nos testes. Neste cenário, o classificador SVM/SMO obteve índice Kappa igual a 0,79, o que indica substancial concordância com os resultados obtidos nos testes.

Tabela 5.42 – Matriz de confusão (Motor 3) - Classificação de falhas de rolamentos - Filtro Digital

Classes preditas								
FAM			SVM/SMO		k-NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	545	115	514	146	642	18	642	18
Falha	301	2723	67	2957	67	2957	16	3008

A matriz de confusão da Tabela 5.42, mostra que o algoritmo PMC atingiu precisão de 99,5% para diagnóstico de motor sem defeito e 97,3% para identificação de motor com defeito de rolamento. O algoritmo *k*-NN apresenta precisão de 97,3% para motor sem defeito e 97,8% de precisão para indicação de motor com defeito. O classificador FAM obteve respectivamente 77,9% e 97,8% de precisão para indicação de motor sem defeito e motor com defeito de rolamento. Já o algoritmo SVM/SMO obteve 82,6% de precisão para

classificação de motor sem defeito e 90% de precisão para indicação de motor operando com defeito de rolamento.

As Tabelas 5.43 e 5.44 apresentam os resultados de classificação de severidade do mesmo conjunto de dados anterior, para o Motor 3, considerando os classificadores configurados para a multiclassificação do nível de degradação de uma falha de rolamento.

Tabela 5.43 – Resultados experimentais - Multiclassificação de falhas de rolamentos (Motor 3) - Filtro Digital

Atributos	FAM	SVM/SMO	k-NN	PMC
Instâncias corretamente classificadas (%)	35,83	38,81	42,96	42,10
Instâncias incorretamente classificadas (%)	64,16	61,19	57,04	57,90
Estatística Kappa	0,20	0,23	0,28	0,27
Erro absoluto médio	0,25	0,28	0,22	0,23
Erro quadrático	0,50	0,38	0,47	0,40
Erro absoluto relativo (%)	80,26	90,56	71,38	73,62
Erro quadrático relativo (%)	126,70	96,62	119,35	102,41
Tempo para criação do modelo (s)	0,2	1,93	0,02	341,8

Na Tabela 5.43 é possível observar que o algoritmo k -NN obteve melhor precisão global de classificação, atingindo 42,96%, seguido pelos algoritmos PMC, SVM/SMO e FAM, respectivamente com 42,10%, 38,81% e 35,83% de precisão global. Neste cenário de multiclassificação de falhas de rolamentos os classificadores obtiveram índice Kappa que demonstra fraca concordância em relação aos resultados obtidos nos testes.

Tabela 5.44 – Matriz de confusão (Motor 3) - Classificação de falhas de rolamentos - Filtro Digital

Classes	Classes previstas									
	FAM					SVM/SMO				
Normal	538	28	32	37	25	596	13	14	27	10
Inicial	23	206	134	174	213	33	323	108	160	126
Médio	32	163	189	178	188	51	234	148	156	161
Avançado	29	184	175	181	193	45	228	115	196	178
Severo	18	156	182	200	206	49	241	132	173	167
Classes	k -NN					PMC				
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
Normal	640	10	3	2	5	636	6	10	6	2
Inicial	15	234	154	173	174	13	290	141	126	180
Médio	24	176	240	161	149	8	212	213	151	166
Avançado	19	169	169	249	156	14	227	169	178	174
Severo	5	184	174	179	220	7	214	158	149	234

A matriz de confusão da Tabela 5.44, mostra que o algoritmo k -NN obteve precisão de 97% para diagnóstico de motor sem defeito. No entanto, para a multiclassificação de severidade os índices de precisão obtidos foram respectivamente 31,2%, 32%, 32,7% e 28,9% para classificação de rolamento com nível de desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Neste cenário, o algoritmo PMC para obteve índices de precisão de 96,4%, 38,7%, 28,4%, 23,4% e 30,7%, respectivamente. Os algoritmos SVM/SMO e FAM obtiveram índices de precisão para indicação de motor sem defeito de 90,3% e 81,5%.

As Tabelas 5.45 e 5.46 apresentam os resultados de classificação do conjunto composto por 1180 ensaios experimentais para o Motor 4. Nestas tabelas tem-se a classificação de motor operando sem falha ou motor operando com falha de rolamento.

Tabela 5.45 – Resultados experimentais - Classificação de falhas de rolamentos (Motor 4) - Filtro Digital

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	85,87	94,01	95,67	98,50
Instâncias incorretamente classificadas (%)	14,13	5,99	4,33	1,50
Estatística Kappa	0,59	0,80	0,86	0,95
Erro absoluto médio	0,14	0,05	0,04	0,01
Erro quadrático	0,37	0,24	0,20	0,11
Erro absoluto relativo (%)	44,54	18,88	13,72	5,45
Erro quadrático relativo (%)	94,40	61,47	52,20	28,29
Tempo para criação do modelo (s)	0,16	1,51	0,01	320,01

A Tabela 5.45 mostra que o algoritmo PMC apresenta melhor precisão global de classificação, obtendo 98,50%. Na sequência, os melhores resultados foram obtidos pelos algoritmos *k*-NN, SVM/SMO e FAM, respectivamente com 95,67%, 94,01% e 85,87% de precisão global. Os classificadores PMC, *k*-NN e SVM/SMO apresentam índice Kappa superiores a 0,80, indicando perfeita concordância em relação aos resultados obtidos nos testes. Neste mesmo cenário, o classificador FAM obteve índice Kappa igual a 0,59, o que indica moderada concordância com os resultados obtidos nos testes.

Tabela 5.46 – Matriz de confusão (Motor 4) - Classificação de falhas de rolamentos - Filtro Digital

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	545	154	546	153	646	53	664	35
Falha	346	2495	59	2782	100	2741	18	2823

A matriz de confusão da Tabela 5.46, mostra que o algoritmo PMC atingiu precisão de 95% para diagnóstico de motor sem defeito e 99,4% para identificação de motor com defeito de rolamento. O algoritmo *k*-NN apresenta precisão de 92,4% para motor sem defeito e 96,5% de precisão para indicação de motor com defeito. O classificador SVM/SMO obteve respectivamente 78,1% e 97,7% de precisão para indicação de motor sem defeito e motor com defeito de rolamento. Já o algoritmo FAM obteve 78% de precisão para classificação do motor sem defeito e 87,8% de precisão para indicação de motor operando com defeito de rolamento.

As Tabelas 5.47 e 5.48 apresentam os resultados de classificação do conjunto de dados do Motor 4, utilizadas para treinamento e validação dos classificadores configurados para a multiclassificação do nível de degradação de uma falha de rolamento.

Na Tabela 5.47 é possível observar que o algoritmo PMC obteve melhor precisão global de classificação de severidade, atingindo 42,31%, seguido pelos algoritmos *k*-NN, SVM/SMO e FAM, respectivamente com 42%, 37,48% e 34,88% de precisão global. Neste cenário de multiclassificação de falhas de rolamentos os classificadores obtiveram índice

Tabela 5.47 – Resultados experimentais - Multiclassificação de falhas de rolamentos (Motor 4) - Filtro Digital

Atributos	FAM	SVM/SMO	k-NN	PMC
Instâncias corretamente classificadas (%)	34,88	37,48	42	42,31
Instâncias incorretamente classificadas (%)	65,12	62,52	58	57,69
Estatística Kappa	0,20	0,21	0,27	0,27
Erro absoluto médio	0,26	0,29	0,23	0,24
Erro quadrático	0,51	0,38	0,48	0,39
Erro absoluto relativo (%)	81,39	91,41	72,53	75,17
Erro quadrático relativo (%)	127,58	97,10	120,31	98,69
Tempo para criação do modelo (s)	0,53	5,64	0,03	317,8

Kappa inferior a 0,30, o que demonstra fraca concordância em relação aos resultados obtidos nos testes.

Tabela 5.48 – Matriz de confusão (Motor 4) - Multiclassificação de falhas de rolamentos - Filtro Digital

Classes	Classes previstas									
	FAM					SVM/SMO				
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
Normal	507	45	42	43	62	646	16	6	20	11
Inicial	31	201	164	151	164	75	158	183	187	108
Médio	42	169	154	165	184	84	137	214	181	98
Avançado	28	167	182	174	157	91	153	180	194	90
Severo	37	177	159	136	199	85	145	195	168	115
Classes	k-NN					PMC				
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
	Normal	Inicial	Médio	Avançado	Severo	Normal	Inicial	Médio	Avançado	Severo
Normal	625	14	22	24	14	617	4	6	10	8
Inicial	11	207	181	164	148	9	195	143	162	202
Médio	20	128	226	161	179	17	151	199	140	207
Avançado	18	146	174	222	148	16	130	188	188	186
Severo	18	136	171	176	207	11	148	133	133	245

A matriz de confusão da Tabela 5.48, mostra que o algoritmo PMC obteve precisão de 96% para diagnóstico de motor sem defeito. No entanto, para a multiclassificação de severidade das falhas os índices de precisão obtidos foram respectivamente 27,4%, 27,9%, 26,6% e 34,6% para classificação de rolamento com nível de desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Neste cenário, o algoritmo k-NN para obteve índices de precisão de 89,4%, 29,1%, 27,9%, 26,6% e 34,6%, respectivamente. Os algoritmos SVM/SMO e FAM obtiveram índices de precisão para indicação de motor sem defeito de 92,4% e 72,5%.

5.3.3 Comparativo entre Filtro Analógico e Filtro Digital - Falhas de Rolamentos

O gráfico da Figura 5.9, apresenta os índices de precisão individuais para o Motor 3 ao longo da faixa de 12 a 60 Hz, para cada um dos métodos avaliados. O classificador PMC obteve os índices de classificação ligeiramente superiores considerando utilização do filtro digital. Nestes testes, os resultados indicam que o classificador FAM obteve os menores desempenhos de classificação.

Figura 5.9 – Precisão de classificação - rolamentos (Motor 3) - filtro analógico x digital

No caso da multiclassificação, para o mesmo conjunto de dados, a Figura 5.10 descreve os índices de precisão para o Motor 3 considerando a multiclassificação do nível de severidade da falha. Os classificadores PMC, k -NN e SVM/SMO obtiveram índices de classificação superiores a 90% para indicação de motor sem defeitos. No entanto, a precisão para o diagnóstico da severidade da falha foi em média inferior a 30%. Os melhores resultados foram obtidos pelo classificador k -NN.

Figura 5.10 – Precisão de classificação - rolamentos (Motor 3) - filtro analógico x digital

Para o Motor 4, a partir da Figura 5.11 observa-se que classificadores PMC e k -NN obtiveram índices de classificação superiores a 90% para o diagnóstico de falhas, quando aplicado o filtro digital. Nos testes considerando filtro analógico, os índices de precisão para o diagnóstico de motor sem defeito foram inferiores a 50%.

Figura 5.11 – Precisão de classificação - rolamentos (Motor 4) - filtro analógico x digital

Ainda, no caso do Motor 4, o gráfico da Figura 5.12 mostra que os classificadores PMC, k -NN e SVM/SMO obtiveram índices de classificação superiores a 89% para o diagnóstico de motor sem defeitos, quando aplicado o filtro digital. No caso da multiclassificação do nível de severidade das falhas os índices de precisão em média foram inferiores a 30%.

Figura 5.12 – Precisão de multiclassificação - rolamentos (Motor 4) - filtro analógico x digital

Testes de classificação efetuados considerando exclusivamente dados de um único in- versor, apresentam índices de precisão superiores a 82,3% para indicação de motor sem defeito e percentuais superiores a 89,7% para os casos de motor operando com defeito de rolamentos. Novamente, no caso dos classificadores PMC e k -NN foram obtidos índices Kappa superiores a 0,8, o que indica perfeita concordância com os resultados obtidos nos testes. No caso da multiclassificação de falhas de rolamento, também os melhores resul-

tados foram obtidos a partir dos dados coletados do inversor MM440. Com o algoritmo PMC foram atingidos percentuais de 95,2% para indicação de motor sem defeito e respectivamente 33,2%, 38,3%, 39,4% e 29,7% para classificação de rolamento com nível de desgaste inicial, desgaste médio, desgaste avançado e desgaste severo.

5.4 Resultados de Classificação - Falhas de Rolamentos - Laboratório de Máquinas Elétricas UVa

Nesta seção são apresentados os resultados obtidos pelos classificadores no diagnóstico de falhas de rolamentos utilizando os dados coletados no laboratório de Máquinas Elétricas da Universidade de Valladolid. Nesta fase do trabalho foi adotado o mesmo procedimento metodológico de tratamento dos dados de entradas dos classificadores, que utilizam as correntes trifásicas dos MIT acionados pelos inversores de frequência AB Allen Braddley - Power Flex 40 e WEG CFW08 Plus. As estratégias de classificação propostas foram submetidas ao treinamento com os sinais de entrada conforme descrito na Seção 4.2 e os parâmetros utilizados nos classificadores estão descritos na Seção 4.7. Os sinais de corrente trifásicas de estator utilizados como entrada para os classificadores foram filtrados por um filtro digital FIR, conforme descrito na Subseção 4.2.3.

As Tabelas 5.49 e 5.50 apresentam os resultados de classificação do conjunto composto por 700 ensaios experimentais referentes aos inversores Allen Braddley e WEG, operando com frequências de 25, 50 e 75 Hz, para o motor de 0,75 kW (Motor 5) em regime permanente operando a vazio e em plena carga. Tem-se assim um conjunto de 2100 amostras utilizadas para treinamento e validação dos classificadores considerando classificação de motor sem defeito e motor com defeito de rolamentos.

Tabela 5.49 – Resultados experimentais de classificação do conjunto composto pelos inversores Allen Braddley e WEG (filtro FIR)

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	74,55	73,74	80,19	81,57
Instâncias incorretamente classificadas (%)	25,45	26,26	19,81	18,43
Estatística Kappa	0,40	0,10	0,52	0,54
Erro absoluto médio	0,25	0,26	0,19	0,19
Erro quadrático	0,50	0,51	0,44	0,38
Erro absoluto relativo (%)	62,54	64,53	48,77	48,34
Erro quadrático relativo (%)	111,85	113,62	98,64	85,99
Tempo para criação do modelo (s)	0,12	2,92	0,01	206,94

A partir dos resultados apresentados na Tabela 5.49 é possível observar que o algoritmo PMC obteve 81,57% de precisão global e moderada concordância com os resultados obtidos nos testes, atingindo índice Kappa 0,54. O algoritmo k -NN obteve precisão global de 80,19% e também moderada concordância com os resultados obtidos nos testes, seguidos pelos algoritmos FAM e SVM/SMO, respectivamente atingindo 74,55% e 73,74%

de precisão global. No entanto, o índice Kappa apresentado pelo algoritmo SVM/SMO indica pobre concordância dos resultados obtidos nestes testes.

Tabela 5.50 – Matriz de confusão gerada a partir do conjunto de dados composto pelos inversores Allen Braddley e WEG (filtro FIR)

Classes	Classes preditas							
	FAM		SVM/SMO		<i>k</i> -NN		PMC	
	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	374	221	47	548	402	193	389	206
Falha	312	1188	2	1498	222	1278	180	1320

A matriz de confusão da Tabela 5.50, mostra que o algoritmo PMC apresenta precisão de 65,4% para diagnóstico de motor operando sem defeito e 88% de precisão para classificação de motor operando com falha de rolamento. Neste mesmo cenário, o algoritmo *k*-NN possui precisão de 67,6% para diagnóstico de motor sem defeito e 85,2% de precisão para indicação de motor operando com falha de rolamento. A matriz de confusão mostra ainda que algoritmo SVM/SMO obteve apenas 7% de acerto para identificação de motor sem defeito.

No caso da multiclassificação da severidade das falhas de rolamento, foi utilizado um conjunto composto por 500 ensaios experimentais, considerando apenas dados do Motor 5, acionado pelos inversores Allen Braddley e WEG (Testes 1 a 5) operando em regime permanente. Visando classificar o nível de severidade da falha, para cada um dos 10 dias de testes foram adotados diferentes níveis de severidade, a saber: as amostras referentes aos primeiro, segundo e terceiro dias de testes definidas como Nível de desgaste inicial - Nível 1; as amostras referentes aos quarto, quinto e sexto dias de testes foram definidas como desgaste intermediário - Nível 2; as amostras referentes aos sétimo e oitavo dias como Nível Avançado - Nível 3. As amostras referentes aos nono e décimo dias de testes foram consideradas como rolamento operando em Nível Crítico - Nível 4. As Tabelas 5.51 e 5.52 apresentam os resultados obtidos para a multiclassificação da severidade da falha de rolamento para o conjunto de 1500 amostras utilizadas para treinamento e validação dos classificadores.

Tabela 5.51 – Resultados experimentais de multiclassificação do conjunto composto pelos inversores Allen Braddley e WEG (filtro FIR)

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	59,87	39,27	63,14	64,53
Instâncias incorretamente classificadas (%)	40,13	60,73	36,86	35,47
Estatística Kappa	0,45	0,13	0,50	0,52
Erro absoluto médio	0,20	0,33	0,18	0,19
Erro quadrático	0,44	0,42	0,42	0,37
Erro absoluto relativo (%)	54,23	90,37	49,69	51,93
Erro quadrático relativo (%)	104,14	98,19	99,67	88,23
Tempo para criação do modelo (s)	0,63	2,74	0,01	209,94

Analisando a Tabela 5.51 é possível observar que o melhor resultado foi obtido pelo algoritmo PMC que alcançou 64,53% de precisão global além de obter moderada concordância com os resultados obtidos nos testes, com índice Kappa 0,52. Estes resultados

indicam a capacidade de generalização do método proposto para diferentes modelos de inversores com frequências de chaveamento distintas, em uma ampla faixa de frequência e diferentes níveis de conjugado de carga. O algoritmo k -NN obteve resultados praticamente similares, atingindo precisão global de 63,14% e também moderada concordância com os resultados obtidos nos testes. O pior desempenho ficou por conta do algoritmo SVM/SMO com 39,27% de precisão.

Tabela 5.52 – Matriz de confusão gerada a partir do conjunto de dados composto pelos inversores Allen Braddley e WEG (filtro FIR) - Multiclassificação

Classes Preditas								
FAM					SVM/SMO			
Classes	Nível 1	Nível 2	Nível 3	Nível 4	Nível 1	Nível 2	Nível 3	Nível 4
Nível 1	181	78	37	4	0	193	107	0
Nível 2	65	271	89	25	1	257	190	2
Nível 3	32	91	261	66	0	138	297	15
Nível 4	8	29	78	185	1	76	188	35
k -NN					PMC			
Classes	Nível 1	Nível 2	Nível 3	Nível 4	Nível 1	Nível 2	Nível 3	Nível 4
Nível 1	213	53	27	7	211	69	15	5
Nível 2	85	257	80	28	71	297	59	23
Nível 3	33	70	294	53	32	72	279	67
Nível 4	13	39	65	183	5	42	72	181

A matriz de confusão da Tabela 5.52, mostra que o algoritmo PMC apresenta precisão de 70,3% para o diagnóstico do motor operando com rolamento em nível de desgaste inicial, 66% para identificação de rolamento com intermediário, 62% de precisão para diagnóstico de desgaste avançado, e 60,3% para nível de desgaste crítico. Neste mesmo cenário, o algoritmo k -NN possui precisão de 71% para diagnóstico de motor operando com rolamento em nível de desgaste inicial, 57,1% para identificação de rolamento com intermediário, e, respectivamente 65,3% e 61% de precisão para diagnóstico de níveis de desgaste avançado e crítico. A partir da matriz de confusão observa-se que o algoritmo SVM/SMO não conseguiu acertar nenhuma amostra referente ao nível de desgaste inicial além obter apenas 11% de precisão na identificação de rolamento com nível de desgaste crítico.

A falha de rolamento fica evidenciada pela operação acima da velocidade nominal máquina, uma vez que nestas condições, a máxima velocidade exige esforço adicional das partes periféricas como ventilador, rotor e principalmente do nível de integridade dos rolamentos. Neste cenário, com a máquina operando com frequência de 75 Hz, foram obtidos índices de precisão superiores a 88% para classificação de motor sem defeito e superiores 92% para indicação de motor operando com defeito de rolamentos. Resultados de classificação individuais para máquina operando nas condições de 25 e 50 Hz, foram similares. Para a máquina operando em regime nominal, na frequência de 50 Hz, foram também avaliadas a influência de diferentes frequências de chaveamento na assinatura da falha. Ainda, não foram observadas diferenças significativas entre os resultados de classificação de falhas de rolamento para o caso em estudo neste trabalho.

Figura 5.13 – Estimador neural da evolução do desgaste de uma falha de rolamento

Nesta pesquisa também foi proposta a estimação da evolução progressiva do desgaste de um rolamento utilizando uma rede PMC implementada como aproximador funcional.

Assim, o modelo construído foi treinado utilizando dados referentes ao Motor 5, considerando todas as amostras referentes aos Testes 1 a 5, executados no laboratório de Máquinas Elétricas da UVa.

Para execução deste teste foram utilizadas 1050 amostras para treinamento e 450 amostras para validação (relação 70/30), considerando apenas dados do Motor 5 operando com falha de rolamento. Seguindo o critério similar ao adotado para a multiclassificação da severidade da falha de rolamento, tem-se os conjuntos de amostras representando cada um dos 10 dias de testes os quais foram definidas como uma escala normalizada representando cada um dos 10 dias de teste (0,1 - 1). Esta escala representa a evolução progressiva do nível de desgaste, desde uma falha incipiente, seguindo por uma falha intermediária, evoluindo para uma falha avançada, até atingir um nível crítico (nível atribuído às amostras referentes ao nono e décimo dias de testes), em que a imediata substituição do rolamento faz-se necessária visando manutenção da integridade do processo.

A Figura 5.13 mostra os resultados da estimação da evolução progressiva do desgaste causado em rolamento após execução de um procedimento incorreto de lubrificação. Observa-se que o eixo y do referido gráfico apresenta o nível de desgaste em função do número de dias (normalizado), e o eixo x representa a quantidade de amostras de validação. A fim de demonstrar o processo de estimação de forma mais clara, o gráfico apresenta apenas os resultados referentes a estimação dos níveis 0,1 e 1, que representam os níveis de uma falha inicial e falha crítica, respectivamente.

Os resultados obtidos a partir do teste de validação apresentaram erro relativo médio de 45,34% e a variância do erro foi -2,13%, considerando a complexidade do problema

abordado e principalmente levando em conta o fato de serem utilizadas amostras diferentes obtidas a partir de diferentes modelos de inversores de frequência, faixas de velocidade variáveis, além de frequências de chaveamento e níveis de cargas distintas.

5.5 Multiclassificador de Falhas

Nesta seção são apresentados os resultados obtidos pelos classificadores para o diagnóstico de falhas de curto-circuito de estator, barras quebradas de rotor e rolamentos utilizando os dados coletados no laboratório de Sistemas Inteligentes da UTFPR. Novamente, foi adotado o mesmo procedimento de tratamento dos dados de entradas dos classificadores, que utilizam as correntes trifásicas dos MIT acionados pelos inversores de frequência modelos Sinamics G110, Micromaster MM440 e ATV12H075M2. As estratégias de classificação propostas foram submetidas ao treinamento com os sinais de entrada conforme descrito na Seção 4.2 e os parâmetros utilizados nos classificadores estão descritos na Subseção 4.7.

5.5.1 Multiclassificador de Falhas - Filtro Analógico

As Tabelas 5.53 e 5.54 apresentam os resultados de classificação do conjunto composto por 2967 ensaios experimentais coletados de todos os inversores frente as várias situações de carga na faixa de 12 a 60 Hz para os Motores 1 e 3. Os experimentos resultam em 8901 amostras utilizadas para treinamento e validação dos classificadores, configurados para classificação de motor operando sem falha ou motor operando com falha.

Tabela 5.53 – Resultados experimentais para o conjunto composto por todas as falhas (Motores 1 e 3) - Filtro Analógico

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	77,58	85,10	91,24	89,40
Instâncias incorretamente classificadas (%)	22,42	14,90	8,75	10,60
Estatística Kappa	0,36	0,29	0,72	0,64
Erro absoluto médio	0,22	0,14	0,08	0,12
Erro quadrático	0,47	0,38	0,29	0,28
Erro absoluto relativo (%)	74,12	49,27	28,98	39,68
Erro quadrático relativo (%)	121,77	99,27	76,08	72,52
Tempo para criação do modelo (s)	1,22	34,3	0,02	904,08

Analisando a Tabela 5.53 é possível observar que o algoritmo k -NN apresenta melhor precisão global de classificação atingindo 91,24% de acerto, seguido pelos algoritmos PMC, SVM/SMO e FAM, respectivamente com 89,40%, 85,10% e 77,58%. Os classificadores k -NN e PMC obtiveram índice Kappa superior a 0,60 indicando substancial concordância com os resultados obtidos nos testes. Os índices Kappa obtidos pelos classificadores SVM/SMO e FAM indicam fraca concordância com os resultados obtidos nos testes.

A matriz de confusão da Tabela 5.54, mostra que o algoritmo k -NN obteve precisão de 81,5% para diagnóstico de motor sem defeito e 93,3% para identificação de motor

Tabela 5.54 – Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas - Motores 1 e 3 - Filtro Analógico

Classes preditas								
FAM			SVM/SMO		k-NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	1015	637	340	1312	1346	306	1157	495
Falha	1358	5891	14	7235	473	6776	448	6801

com defeito. O algoritmo PMC apresenta precisão de 70% para motor sem defeito e 93,8% de precisão para indicação de motor com defeito. O classificador FAM obteve respectivamente 61,4% e 81,3% de precisão para indicação do motor sem defeito e do motor com defeito. Já o algoritmo SVM/SMO obteve 20% de precisão para indicação do motor sem defeito e 99,8 de precisão para indicação do motor com defeito.

As Tabelas 5.55 e 5.56 apresentam os resultados de multiclassificação de falhas de curto-circuito de estator, barras quebradas de rotor ou defeito rolamentos para os Motores 1 e 3.

Tabela 5.55 – Resultados experimentais para o conjunto composto por todas as falhas (Motores 1 e 3) - multiclassificação - Filtro Analógico

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	74,05	76,22	87,56	89,37
Instâncias incorretamente classificadas (%)	25,95	23,78	12,44	10,63
Estatística Kappa	0,64	0,67	0,83	0,85
Erro absoluto médio	0,12	0,27	0,06	0,06
Erro quadrático	0,36	0,35	0,24	0,20
Erro absoluto relativo (%)	35,49	76,10	17,06	17,54
Erro quadrático relativo (%)	84,25	82,54	58,32	47,30
Tempo para criação do modelo (s)	1,67	28,69	0,02	917,33

A partir da Tabela 5.53 é possível observar que no caso da multiclassificação o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 89,37% de precisão global, seguido pelos algoritmos *k*-NN, SVM/SMO e FAM, respectivamente com 87,56%, 76,22% e 74,05% de precisão global. Os classificadores *k*-NN e PMC obtiveram índice Kappa superior a 0,80 indicando perfeita concordância com os resultados obtidos nos testes. Os índices Kappa obtidos pelos classificadores SVM/SMO e FAM indicam substancial concordância com os resultados obtidos nos testes.

A matriz de confusão da Tabela 5.56 mostra que o algoritmo PMC apresenta precisão de 75,3% para diagnóstico de motor operando sem defeitos, 92,1% para o diagnóstico de motor operando com falha de curto-circuito de estator, 98,3 % de precisão para diagnóstico de motor operando com barras quebradas de rotor, e 82,8% para diagnóstico de motor operando com defeito de rolamento. Neste mesmo cenário, o algoritmo *k*-NN possui maior índice de precisão para diagnóstico de motor sem defeitos, atingindo 82,6%. Para o diagnóstico de motor operando com falha de curto-circuito de estator foi obtido 86,6 % de precisão, 96,2% de precisão para diagnóstico do motor operando com barras quebradas de rotor, e 77,9% para diagnóstico do motor operando com defeito de rolamento. A partir da matriz de confusão é possível observar que o algoritmo SVM/SMO obteve o menor

Tabela 5.56 – Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 1 e 3) - Multiclassificação - Filtro Analógico

Classes Preditas								
FAM					SVM/SMO			
Classes	Normal	Estator	Rotor	Rolamento	Normal	Estator	Rotor	Rolamento
Normal	1129	224	91	208	780	145	86	641
Estator	258	2037	169	164	182	2064	186	196
Rotor	124	198	2544	158	56	127	2793	48
Rolamento	389	169	157	882	325	64	61	1147
k -NN					PMC			
Classes	Normal	Estator	Rotor	Rolamento	Normal	Estator	Rotor	Rolamento
Normal	1364	176	20	92	1240	159	17	236
Estator	216	2276	40	36	146	2420	24	38
Rotor	35	36	2910	43	6	31	2973	14
Rolamento	239	73	41	1244	210	37	28	1322

índice para classificação do motor sem defeito, atingindo apenas 47,2% de precisão.

Nas Tabelas 5.57 e 5.58 são apresentados os resultados de classificação do conjunto composto por 3535 ensaios experimentais coletados de todos os inversores frente as diversas situações de carga na faixa de 12 a 60 Hz para os Motores 2 e 4, resultado assim em 10605 amostras utilizadas para treinamento e validação dos classificadores, configurados para classificação de motor operando sem falha ou motor operando com falha.

Tabela 5.57 – Resultados experimentais para o conjunto composto por todas as falhas (Motores 2 e 4) - Filtro Analógico

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	38,10	79,88	89,73	81,50
Instâncias incorretamente classificadas (%)	31,90	20,12	10,27	18,50
Estatística Kappa	0,20	0	0,69	0,33
Erro absoluto médio	0,31	0,20	0,10	0,22
Erro quadrático	0,56	0,44	0,32	0,36
Erro absoluto relativo (%)	99,28	62,58	31,97	69,42
Erro quadrático relativo (%)	140,92	111,88	79,93	91,68
Tempo para criação do modelo (s)	2,64	471,7	0,02	924,21

A Tabela 5.57 mostra novamente que no caso da classificação de motor com defeito/motor sem defeito, o classificador k -NN obteve melhor precisão global de classificação, atingindo 89,73%, seguido pelos algoritmos PMC, SVM/SMO e FAM, respectivamente com 81,50%, 79,88% e 38,10% de precisão global. O classificador k -NN obteve índice Kappa superior a 0,60, o qual indica substancial concordância com os resultados dos testes. Os índices Kappa obtidos pelos classificadores PMC e FAM indicam fraca concordância com os resultados obtidos nos testes. Já o índice Kappa do classificador SVM/SMO indica não haver qualquer concordância dos resultados.

Tabela 5.58 – Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 2 e 4) - Filtro Analógico

Classes preditas								
FAM			SVM/SMO		k -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	1158	975	0	2133	1717	416	755	1378
Falha	2409	6063	0	8472	673	7799	583	7889

A matriz de confusão da Tabela 5.58 mostra que o algoritmo k -NN obteve precisão de 80,5% para diagnóstico de motor sem defeito e 92,1% para identificação de motor com defeito. O algoritmo PMC apresenta precisão de 35% para motor sem defeito e 93,1% de precisão para indicação de motor com defeito. O classificador FAM obteve respectivamente 54,3% e 71,6% de precisão para indicação de motor sem defeito e motor com defeito. Já o algoritmo SVM/SMO não obteve separabilidade adequada entre as classes, apresentando assim resultados insatisfatórios de classificação.

As Tabelas 5.59 e 5.60 apresentam os resultados de multiclassificação para o conjunto composto por 3535 ensaios experimentais coletados de todos os inversores para os Motores 2 e 4, considerando os classificadores configurados para diagnóstico de curto-circuito de estator, barras quebradas de rotor ou defeito rolamentos.

Tabela 5.59 – Resultados experimentais para o conjunto composto por todas as falhas (Motores 2 e 4) - Multiclassificação - Filtro Analógico

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	61,50	58,25	80,60	73,47
Instâncias incorretamente classificadas (%)	38,50	41,75	19,40	26,53
Estatística Kappa	0,48	0,43	0,74	0,64
Erro absoluto médio	0,19	0,30	0,09	0,15
Erro quadrático	0,43	0,38	0,31	0,30
Erro absoluto relativo (%)	51,55	81,16	26	41,89
Erro quadrático relativo (%)	101,54	89,59	72,05	71,49
Tempo para criação do modelo (s)	2,65	20,84	0,02	1082,84

A Tabela 5.59 mostra que a multiclassificação utilizando o algoritmo k -NN obteve melhor precisão global de classificação, atingindo 80,60%. Na sequência tem-se os algoritmos PMC, FAM e SVM/SMO, respectivamente com 73,47%, 61,50% e 58,25% de precisão global. Os classificadores k -NN e PMC obtiveram índice Kappa superior a 0,60, indicando substancial concordância com os resultados obtidos nos testes. Os índices Kappa obtidos pelos classificadores SVM/SMO e FAM indicam moderada concordância com os resultados obtidos nos testes.

Tabela 5.60 – Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 2 e 4) - Multiclassificação - Filtro Analógico

Classes Preditas								
FAM					SVM/SMO			
Classes	Normal	Estator	Rotor	Rolamento	Normal	Estator	Rotor	Rolamento
Normal	1250	156	282	445	380	149	477	1127
Estator	259	2268	117	173	337	2101	153	226
Rotor	378	57	1647	759	34	59	1820	928
Rolamento	677	84	696	1357	52	76	810	1876
k -NN					PMC			
Classes	Normal	Estator	Rotor	Rolamento	Normal	Estator	Rotor	Rolamento
Normal	1763	159	43	168	1055	89	197	792
Estator	158	2532	67	60	219	2489	36	73
Rotor	125	29	2198	489	164	22	2236	419
Rolamento	301	13	445	2055	368	27	408	2011

A matriz de confusão da Tabela 5.60 mostra que o algoritmo k -NN apresenta precisão de 82,65% para diagnóstico do motor operando sem defeitos, 89,88% para o diagnóstico

de motor operando com falha de curto-circuito de estator, 77,36% de precisão para diagnóstico de motor operando com barras quebradas de rotor e 73,02% para diagnóstico de motor operando com defeito de rolamento. Neste mesmo cenário, o algoritmo PMC obteve precisão de 49,5% para diagnóstico de motor sem defeitos, 88,4% de precisão para o diagnóstico de motor operando com falha de curto-circuito de estator, 78,7% de precisão para diagnóstico de motor operando com barras quebradas de rotor e 71,5% para diagnóstico de motor operando com defeito de rolamento. Novamente, a partir da matriz de confusão é possível observar que o algoritmo SVM/SMO obteve o menor índice para classificação de motor sem defeito, atingindo apenas 17,8% de precisão.

5.5.2 Multiclassificador de Falhas - Filtro Digital

As Tabelas 5.61 e 5.62 apresentam os resultados de classificação do conjunto composto por 2734 ensaios experimentais coletados de todos os inversores para os Motores 1 e 3. O resultado dos experimentos consiste num conjunto formado por 8202 amostras utilizadas para treinamento e validação dos classificadores, os quais foram ajustados para a classificação do motor operando sem falha ou motor operando com falha de curto-circuito de estator, barras quebradas de rotor e rolamentos.

Tabela 5.61 – Resultados experimentais para o conjunto composto por todas as falhas (Motores 1 e 3) - Filtro Digital

Atributos	FAM	SVM/SMO	<i>k</i> -NN	PMC
Instâncias corretamente classificadas (%)	76,95	85,22	90,85	92,05
Instâncias incorretamente classificadas (%)	23,05	14,78	9,15	7,95
Estatística Kappa	0,36	0,41	0,72	0,75
Erro absoluto médio	0,23	0,14	0,09	0,08
Erro quadrático	0,48	0,38	0,30	0,25
Erro absoluto relativo (%)	72,51	46,51	28,79	27,42
Erro quadrático relativo (%)	120,43	96,46	75,33	63,58
Tempo para criação do modelo (s)	0,89	15,3	0,02	716,87

Na partir da Tabela 5.61 é possível observar que o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 92,05%, seguido pelos algoritmos *k*-NN, SVM/SMO e FAM, respectivamente com 90,85%, 85,22% e 76,95% de precisão global. Os classificadores *k*-NN e PMC obtiveram índice Kappa 0,75 e 0,72 respectivamente, indicando substancial concordância com os resultados obtidos nos testes. Os índices Kappa obtidos pelos classificadores SVM/SMO e FAM indicam respectivamente, moderada e fraca concordância com os resultados obtidos nos testes.

Tabela 5.62 – Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 1 e 3) - Filtro Digital

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	986	640	563	1063	1349	277	1325	301
Falha	1251	5325	150	6426	473	6103	351	6225

A matriz de confusão da Tabela 5.62 mostra que o algoritmo PMC obteve precisão de 81,5% para o diagnóstico do motor sem defeito e 94,7% para identificação do motor com defeito. O algoritmo k -NN apresenta precisão de 83% para motor sem defeito e 92,8% de precisão para indicação de motor com defeito. O classificador FAM obteve respectivamente 60,6% e 81% de precisão para indicação de motor sem defeito e motor com defeito. Já o algoritmo SVM/SMO apresenta 34,6% de precisão para o diagnóstico de motor sem defeito e 97,7% de precisão para diagnóstico de motor com falha.

Ainda, em relação aos Motores 1 e 3, as Tabelas 5.63 e 5.64 apresentam os resultados de multiclassificação para o diagnóstico de curto-circuito de estator, barras quebradas de rotor ou defeito rolamentos.

Tabela 5.63 – Resultados experimentais para o conjunto composto por todas as falhas (Motores 1 e 3) - Multiclassificação - Filtro Digital

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	73,04	78,89	86,14	91,46
Instâncias incorretamente classificadas (%)	26,96	21,11	13,16	8,54
Estatística Kappa	0,62	0,70	0,81	0,88
Erro absoluto médio	0,13	0,27	0,69	0,05
Erro quadrático	0,36	0,34	0,26	0,18
Erro absoluto relativo (%)	38,18	77,78	19,66	14,52
Erro quadrático relativo (%)	87,39	82,76	62,62	44,32
Tempo para criação do modelo (s)	1,39	23,12	0,09	1289,35

A partir da Tabela 5.63 é possível observar que no caso da multiclassificação o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 91,46% de precisão global, seguido pelos algoritmos k -NN, SVM/SMO e FAM, respectivamente com 86,14%, 78,89% e 73,04% de precisão global. Os classificadores k -NN e PMC obtiveram índice Kappa superior a 0,80 o qual indica perfeita concordância com os resultados obtidos nos testes. Os índices Kappa obtidos pelos classificadores SVM/SMO e FAM indicam substancial concordância com os resultados obtidos nos testes.

Tabela 5.64 – Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas (Motores 1 e 3) - Multiclassificação - Filtro Digital

Classes Preditas								
FAM					SVM/SMO			
Classes	Normal	Estator	Rotor	Rolamento	Normal	Estator	Rotor	Rolamento
Normal	1002	297	188	139	1316	74	120	116
Estator	358	2039	200	97	489	1991	173	41
Rotor	284	234	2409	97	187	208	2588	41
Rolamento	164	94	59	541	152	40	90	576
k -NN					PMC			
Classes	Normal	Estator	Rotor	Rolamento	Normal	Estator	Rotor	Rolamento
Normal	1346	179	28	73	1372	149	32	73
Estator	228	2403	16	47	202	2442	38	12
Rotor	206	160	2555	103	29	67	2915	13
Rolamento	53	33	10	762	52	19	14	773

A matriz de confusão da Tabela 5.64, mostra que o algoritmo PMC apresenta precisão de 84,4% para o diagnóstico de motor operando sem defeitos, 90,6% para o diagnóstico de motor operando com falha de curto-circuito de estator, 96,4% de precisão para diagnóstico

de motor operando com barras quebradas de rotor e 91,5% para diagnóstico de motor operando com defeito de rolamento.

Neste mesmo cenário, o algoritmo k -NN obteve precisão de 82,8% para o diagnóstico do motor sem defeitos, 89,2% de precisão para o diagnóstico do motor operando com falha de curto-circuito de estator, 84,5% de precisão para o diagnóstico do motor operando com barras quebradas de rotor e 88,8% para diagnóstico de motor operando com defeito de rolamento. A partir da matriz de confusão é possível observar que o algoritmo SVM/SMO obteve índice de 80,9% para classificação de motor sem defeito, 73,9% para o diagnóstico de motor operando com falha de curto-circuito de estator, 85,6% de precisão para diagnóstico de motor operando com barras quebradas de rotor e 67,1% para diagnóstico de motor operando com defeito de rolamento. Já o algoritmo FAM obteve precisão de 61,6% para classificação de motor sem defeitos, 75,7% para o diagnóstico de motor operando com falha de curto-circuito de estator, 79,7% de precisão para diagnóstico de motor operando com barras quebradas de rotor e 63,1% para diagnóstico de motor operando com defeito de rolamento.

As Tabelas 5.65 e 5.66 apresentam os resultados de classificação dos Motores 2 e 4 configurados para classificação de motor operando sem falha ou motor operando com falha. Tem-se 3057 ensaios experimentais os quais seguem os aspectos metodológicos anteriores.

Tabela 5.65 – Resultados experimentais para o conjunto composto por todas as falhas (Motores 2 e 4) - Filtro Digital

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	68,77	81,05	83,19	84,19
Instâncias incorretamente classificadas (%)	31,33	18,95	16,81	15,81
Estatística Kappa	0,20	0,08	0,48	0,42
Erro absoluto médio	0,31	0,18	0,16	0,16
Erro quadrático	0,55	0,43	0,41	0,36
Erro absoluto relativo (%)	97,39	59,11	52,46	52,07
Erro quadrático relativo (%)	139,57	108,74	102,41	91,77
Tempo para criação do modelo (s)	1,83	69,93	0,02	948,85

Na Tabela 5.61 é possível observar que o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 84,19%, seguido pelos algoritmos k -NN, SVM/SMO e FAM, respectivamente com 83,19%, 81,05% e 68,77% de precisão global. Os classificadores k -NN e PMC obtiveram índice Kappa superior a 0,40. O índice Kappa obtido pelo classificador FAM indica fraca concordância com os resultados obtidos nos testes e o obtido pelo classificador SVM/SMO indica não haver qualquer concordância dos resultados obtidos.

Tabela 5.66 – Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas - Filtro Digital

Classes preditas								
FAM			SVM/SMO		<i>k</i> -NN		PMC	
Classes	Normal	Falha	Normal	Falha	Normal	Falha	Normal	Falha
Normal	1076	1033	116	1993	1228	881	873	1236
Falha	2252	6160	1	8411	888	7524	427	7985

A matriz de confusão da Tabela 5.66 mostra que o algoritmo PMC obteve precisão de 41,4% para o diagnóstico do motor sem defeito e 94,9% para identificação do motor com defeito. O algoritmo k -NN apresenta precisão de 58,2% para motor sem defeito e 89,4% de precisão para indicação de motor com defeito. O classificador FAM obteve respectivamente 51% e 73,2% de precisão para indicação de motor sem defeito e motor com defeito. Já o algoritmo SVM/SMO obteve 5% de precisão para o diagnóstico de motor sem defeito e 100% de precisão para diagnóstico de motor com falha.

As Tabelas 5.67 e 5.68 apresentam os resultados de classificação para os Motores 2 e 4, submetidos a falhas de curto-circuito de estator, barras quebradas de rotor ou defeito rolamentos.

Tabela 5.67 – Resultados experimentais para o conjunto composto por todas as falhas (Motores 2 e 4) - Multiclassificação - Filtro Digital

Atributos	FAM	SVM/SMO	k -NN	PMC
Instâncias corretamente classificadas (%)	61,67	61,21	73,41	77,73
Instâncias incorretamente classificadas (%)	38,33	38,79	26,59	22,27
Estatística Kappa	0,49	0,49	0,65	0,70
Erro absoluto médio	0,19	0,30	0,13	0,12
Erro quadrático	0,43	0,38	0,36	0,29
Erro absoluto relativo (%)	51,32	81,55	35,63	34,80
Erro quadrático relativo (%)	101,31	89,92	84,36	68,34
Tempo para criação do modelo (s)	3,05	89,65	0,02	988,16

Na Tabela 5.67 é possível observar que o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 77,73%, seguido pelos algoritmos k -NN, FAM e SVM/SMO, respectivamente com 73,41%, 61,67% e 61,21% de precisão global. Os classificadores k -NN e PMC obtiveram índice Kappa superior a 0,60, indicando substancial concordância com os resultados obtidos nos testes. O índice Kappa obtido pelos classificadores FAM e SVM/SMO indica moderada concordância com os resultados obtidos nos testes.

Tabela 5.68 – Matriz de confusão gerada a partir do conjunto de dados composto por todas as falhas - Multiclassificação - Filtro Digital

Classes Preditas								
FAM					SVM/SMO			
Classes	Normal	Estator	Rotor	Rolamento	Normal	Estator	Rotor	Rolamento
Normal	1015	249	272	573	1015	73	205	816
Estator	278	2002	164	313	272	1732	193	560
Rotor	371	131	1903	436	184	113	1695	849
Rolamento	678	228	339	1569	219	129	468	1998
k -NN					PMC			
Classes	Normal	Estator	Rotor	Rolamento	Normal	Estator	Rotor	Rolamento
Normal	1233	202	66	608	1213	123	129	644
Estator	212	2306	26	213	193	2357	56	151
Rotor	232	53	1988	568	86	43	2450	262
Rolamento	426	110	81	2197	294	112	249	2159

A matriz de confusão da Tabela 5.68 mostra que o algoritmo PMC apresenta precisão de 57,4% para o diagnóstico do motor operando sem defeitos, 85,5% para o diagnóstico do motor operando com falha de curto-circuito de estator, 86,2% de precisão para diagnóstico de motor operando com barras quebradas de rotor, e 76,7% para diagnóstico de motor operando com defeito de rolamento.

Neste mesmo cenário, o algoritmo k -NN obteve precisão de 58,5% para diagnóstico de motor sem defeitos, 83,6% de precisão para o diagnóstico de motor operando com falha de curto-circuito de estator, 70% de precisão para diagnóstico de motor operando com barras quebradas de rotor, e 78,1% para o diagnóstico do motor operando com defeito de rolamento. No caso do algoritmo SVM/SMO o índice de precisão para classificação do motor sem defeito foi de 48,1%. O diagnóstico do motor operando com falha de curto-circuito de estator o índice obtido foi de 62,8% e para o diagnóstico de barras quebradas de rotor o índice obtido foi de 59,7%. Finalmente, obtém-se o índice de 71% para diagnóstico de motor operando com defeito de rolamento.

Ainda, o algoritmo FAM obteve precisão de 48,1% para classificação de motor sem defeitos, 72,6% para o diagnóstico de motor operando com falha de curto-circuito de estator, 67% de precisão para diagnóstico de motor operando com barras quebradas de rotor, e 55,8% para diagnóstico de motor operando com defeito de rolamento.

5.5.3 Comparativo entre Filtro Analógico e Filtro Digital - Multiclassificação de Falhas

O gráfico apresentado na Figura 5.14, descreve os índices de precisão para os Motores 1 e 3 ao longo da faixa de 12 a 60 Hz, considerando o diagnóstico de todas as falhas avaliadas nesta pesquisa, considerando cada um dos métodos avaliados. No filtro digital, os melhores resultados foram obtidos pelos classificadores PMC e k -NN os quais obtiveram índices de classificação superiores a 80%. Os piores resultados são atribuídos ao classificador SVM/SMO que obteve 34,6% de precisão para o diagnóstico de motor sem defeito. Em relação aos resultados obtidos a partir da aplicação do filtro analógico, o melhor índice de precisão foi obtido pelo classificador k -NN com acurácia de 93,8% para motor com defeito e 81,5% de precisão para indicação de motor sem defeito.

No caso da multiclassificação, o gráfico da Figura 5.15 apresenta os índices de precisão para os Motores 1 e 3 ao longo da faixa de 12 a 60 Hz, considerando o diagnóstico de todas as falhas avaliadas nesta pesquisa, para cada um dos métodos avaliados. No caso de aplicação do filtro digital, os melhores resultados foram obtidos pelos classificadores PMC e k -NN, que obtiveram índices de classificação superiores a 82% para indicação de motor sem defeitos, curto-circuito de estator, barras quebradas de rotor e rolamentos.

Em relação aos resultados obtidos a partir da aplicação do filtro analógico, o classificador k -NN obteve índices de precisão superiores a 73,2% para indicação de motor operando com defeito, seguido pelo classificador PMC com índices de precisão superiores a 71,5% para a indicação de motor com defeito. Observa-se ainda que a indicação de motor operando com barra quebrada de rotor obteve os maiores índices de classificação.

Os índices de precisão obtidos a partir do emprego do filtro digital foram ligeiramente superiores.

Figura 5.14 – Precisão de classificação (Motores 1 e 3) - filtro analógico x digital

Figura 5.15 – Precisão de classificação (Motores 1 e 3) - filtro analógico x digital

Em relação aos motores 2 e 4, a partir da Figura 5.16 é possível observar que os melhores resultados foram obtidos pelo classificador *k*-NN, o qual obteve índices de classificação superiores a 80%, utilizando filtro analógico. Neste cenário de testes, os índices de precisão obtidos a partir do emprego do filtro digital foram ligeiramente superiores.

A Figura 5.17 apresenta os índices de precisão para a multiclassificação referente aos Motores 2 e 4. Os melhores índices de classificação foram obtidos para o diagnóstico de barras quebradas de rotor. Os índices de precisão obtidos a partir do emprego do filtro digital foram ligeiramente superiores, sendo atingidos precisões superiores a 80% pelos classificadores *k*-NN e PMC tanto para a indicação de motor sem defeitos quanto para a indicação de motor com defeito de curto-circuito de estator, barras quebradas de rotor ou

Figura 5.16 – Precisão de classificação (Motores 2 e 4) - filtro analógico x digital

rolamentos. No caso das classificações utilizando filtro analógico, novamente os melhores índices foram obtidos pelos classificadores k -NN e PMC que atingiram índices de precisão superiores a 70% para indicação do estado de operação do motor.

Figura 5.17 – Precisão de multiclassificação (Motores 2 e 4) - filtro analógico x digital

5.6 Considerações Finais

Neste Capítulo, são avaliadas estratégias distintas de classificação baseadas em SI para diagnóstico e multiclassificação de defeitos em motores de indução acionados por inversores de frequência, operando em regime permanente ao longo de uma ampla faixa de velocidade e níveis de carga. Além disso foram empregadas técnicas de filtragem

analógica e digital dos sinais de corrente visando comparar o desempenho dos diferentes algoritmos de classificação.

Para classificação de barras quebradas no rotor os algoritmos k -NN e PMC apresentaram os melhores desempenhos.

Um fator essencial para o aumento na porcentagem de acerto dos algoritmos utilizados como multiclassificadores de falhas de rotor deve-se à utilização dos dados tratados pela TWD ao invés dos dados adquiridos diretamente pelo inversor utilizando o filtro analógico.

Considerando exclusivamente os estudos relacionados com a classificação de falhas em motores de indução alimentados por inversores de frequência, este trabalho apresenta um método de pré-processamento baseado na discretização do sinal de corrente do estator no domínio do tempo, enquanto a literatura pesquisada mostra o uso de técnicas baseadas na análise do sinal corrente no domínio da frequência (BRIZ et al., 2009; NUSSBAUMER; STOJICIC; WOLBANK, 2011; YAHIA et al., 2012; WOLBANK et al., 2011; MAOUCHE et al., 2014; ZHU et al., 2014; DRIF; CARDOSO, 2014), no domínio do tempo (SHI et al., 2014; CRISTALDI et al., 2009) ou o uso de transformadas (FAIZ; GHORBANIAN; EBRAHIMI, 2012a).

Outro aspecto importante é o fato de que este trabalho considerou o emprego de quatro diferentes estratégias de classificação para o diagnóstico de falhas, enquanto outros trabalhos disponíveis na literatura pesquisada basicamente empregam o uso de uma única ferramenta. Ainda, neste trabalho, a frequência foi variada de 12 a 60 Hz (em intervalos de 6 Hz), e o nível de carga amplamente explorado na faixa de 10-110% do conjugado nominal. De acordo com a literatura pesquisada, a variação de frequência é considerada apenas nos trabalhos de Barendse e Pillay (2007), Yahia et al. (2012), Chua et al. (2010), Zhu et al. (2014), Basaran e Ece (2009). Já uma ampla variação de carga é apresentada nos trabalhos de Zhu et al. (2014), Drif e Cardoso (2014).

Além disso, este trabalho considera o emprego de 5 modelos de inversores de frequência, operando com frequência de chaveamentos distintas, enquanto outros estudos disponíveis na literatura pesquisada empregam a utilização de um único inversor, com exceção dos trabalhos de Cristaldi et al. (2009), Maouche et al. (2014), que consideram o uso de 2 inversores.

Em relação aos estudos considerando a classificação das falhas de curto-circuito de estator em motores de indução alimentados por inversores de frequência uma contribuição deste trabalho consiste em apresentar um novo conceito de multiclassificação do nível de severidade de uma falha de curto-circuito de estator. Assim, são investigadas situações envolvendo a classificação de uma falha incipiente, como é o caso de uma falha de 1 % de curto-circuito de estator até a sua evolução a níveis mais críticos, como é o caso envolvendo falhas de 10 % de curto-circuito de estator. Os trabalhos disponíveis na literatura pesquisada e referenciada nesta tese não apresentam índices de precisão obtidos para classificação da severidade.

Para os métodos em estudo neste trabalho, tanto a rede PMC quanto os algoritmos k -

NN e SVM/SMO podem ser utilizados para classificação de falhas de estator em diferentes motores acionados por inversores de diferentes modelos e fabricantes, ao longo da faixa de frequência de 12 a 60 Hz, com precisão para detecção de falhas de curto-circuito de diferentes níveis de severidade.

Na multiclassificação de defeitos de curto-circuito de estator foram obtidos índices de precisão superiores a 85 %, especificamente para o diagnóstico e classificação de falhas de 3%, 5% e 10% de defeito de curto-circuito de estator. Estes resultados podem ser utilizados como indicadores para que o operador retire a máquina de operação.

Já no caso dos estudos relacionados à classificação de barras quebradas foram consideradas situações de 1 a 4 barras quebradas, atingindo uma precisão de 91,47 %, enquanto que na literatura pesquisada diversos estudos consideram abordagens no domínio da frequência para classificação de motores de indução alimentados por inversores. Em Chua et al. (2010) foi obtida uma precisão de 100 % para classificação de barras quebradas de rotor. No trabalho de Basaran e Ece (2009) foi atingido 96,58 % de precisão global.

A Tabela 5.69 mostra a comparação do método proposto com alguns trabalhos encontrados na literatura consultada em relação à classificação de barras quebradas de rotor em motores de indução alimentados por inversores de frequência.

Tabela 5.69 – Comparação do método proposto com trabalhos recentemente publicados sobre classificações de barras quebradas de rotor

	Ref. [1]	Ref. [2]	Ref. [3]	Ref. [4]	Este trabalho
Motores	1,1 kW	3,0 kW	0,75 kW	2,2 kW	0,74 e 1,5 kW
Dados entrada	Corrente	Corrente	Corrente	Corrente	Corrente
Preprocessamento	DT/DF	DF	DT	Wavelet	DT/Discretização
Mét. classificação	Fuzzy	MCSA	Instrum. virtual	Bayesiana	FAM, SVM/SMO <i>k</i> -NN e PMC
Faixa frequência	20 - 55 Hz	10 - 50 Hz	35 e 50 Hz	35 - 50 Hz	12 - 60 Hz
Nível carga	N/E	20 e 80 %	0 - 100 %	90-100-110 %	10 - 110 %
Estratégia Controle	N/E	V/f	V/f	V/f	V/f
Inversores	1	1	2	1	3
Barras quebradas	2	1 e 2	1	3 e 5	1, 2, 4 e 2/2
Classificação	Simples	Simples	Simples	Simples	Simples & Severidade
Precisão	100 %	N/E	N/E	93,6 a 96,58 %	Único inversor 99.7 % Múltiplos inversores 95.6 %

N/E - Não especificado; DT - Domínio tempo; DF - Domínio frequência

1 - Chua et al. (2010)

2 - Yahia et al. (2012)

3 - Cristaldi et al. (2009)

4 - Basaran e Ece (2009)

No caso das falhas de rolamentos, a contribuição deste trabalho refere-se a utilização de sinais de corrente discretizados no domínio do tempo para classificar a evolução progressiva de uma falha de rolamento causada pela contaminação da lubrificação durante a montagem. A literatura consultada emprega de métodos tradicionais que consideram o monitoramento da temperatura e da vibração dos rolamentos visando estimar suas condições de operação (ARAÚJO et al., 2010; ZAREI; TAJEDDINI; KARIMI, 2014; JIN et al., 2014; LIU et al., 2013; ALI et al., 2015).

Além disso, destaca-se neste trabalho o conceito da multiclassificação e a estimação do nível de severidade da falha em MIT alimentados por inversores de frequência. Neste

contexto, os conjuntos de amostras representando cada teste foram separadas em escalas acompanhando o desenvolvimento desde uma falha incipiente, seguindo por uma falha intermediária, evoluindo para uma falha avançada, até atingir um nível crítico, em que requer-se a imediata substituição do rolamento danificado. A literatura consultada apresenta conceito similar de avaliação da severidade das falhas de rolamentos apenas para o diagnóstico de máquinas acionadas diretamente na rede (LIU et al., 2013; ZAREI; TAJED-DINI; KARIMI, 2014; JIN et al., 2014; ALI et al., 2015). Os resultados obtidos neste trabalho podem ser utilizados como ferramenta de suporte para a criação de indicadores que permitam programar eficientemente uma interrupção planejada de processo, possibilitando ainda a aplicação desta estratégia de monitoramento em tempo real.

Finalmente, no Capítulo 6 são apresentadas as conclusões e diretrizes futuras deste trabalho.

Conclusões

Este trabalho apresenta o emprego de quatro técnicas inteligentes para o diagnóstico e multiclassificação de falhas de curto-circuito entre as espiras do enrolamento de estator, barras quebradas de rotor, bem como a evolução de uma falha de rolamento, que são as principais causas associadas a falhas de MIT. Dados experimentais coletados em 5 motores diferentes acionados por 5 diferentes modelos de inversores de frequência ao longo de uma ampla faixa de frequência e variações de carga mecânica no eixo da máquina.

Técnicas distintas de filtragem dos sinais de corrente são comparadas. A abordagem analógica é baseada na utilização de um filtro RC diretamente aplicado durante a coleta dos dados experimentais. Os métodos digitais consistem na utilização da Transformada Wavelet Discreta e no filtro FIR.

Um método de pré-processamento baseado na discretização da amplitude do sinal das correntes de estator no domínio do tempo é utilizado para formar os vetores de entrada dos algoritmos classificadores para diagnóstico e multiclassificação das falhas.

A correta identificação das falhas melhora a confiabilidade das máquinas além de reduzir custos de manutenção. Assim, a proposta deste trabalho apresenta o desenvolvimento de um sistema de detecção de falhas em motores de indução a partir de dados coletados por sensores de corrente, normalmente disponíveis na indústria, que possibilitam diagnóstico de falhas elétricas e mecânicas da máquina.

Falhas de curto-circuito de estator com diferentes níveis de severidade são diagnosticadas. Os resultados globais indicam que para os métodos estudados neste trabalho, tanto a rede PMC quanto o SVM/SMO podem ser utilizados para classificação de falhas de estator em diferentes motores acionados por inversores de diferentes modelos e fabricantes, ao longo da faixa de frequência de 12 a 60 Hz, com precisão para detecção de falhas de curto-circuito de diferentes níveis de severidade. No caso das falhas ainda em fase prematura de evolução, como o caso da falha de 1% o índice de precisão é confundido com o motor saudável.

Em relação às falhas de barras quebradas de rotor, têm-se as situações de testes de 1 a 4 barras quebradas as quais os resultados confirmam a viabilidade do método proposto

para classificar barras quebradas de rotor independentemente da velocidade de operação da máquina ou mesmo das condições de carga. Considerando o diagnóstico simples de classificação, em geral, tanto SVM/SMO, k -NN e PMC são capazes de proporcionar diagnósticos rápidos e precisos (acima de 95% de precisão) de barras quebradas de rotor.

Na multiclassificação da severidade de falhas de barras quebradas de rotor, para o conjunto composto por todos os inversores, a precisão é inferior a 50%. No geral, o método k -NN obteve os mais elevados índices de precisão, seguido pela rede PMC.

No caso dos testes para classificação de defeitos de rolamentos no laboratório de Sistemas Inteligentes, são consideradas 4 situações distintas de desgaste: desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Os classificadores PMC e k -NN atingem índices de precisão para o diagnóstico do motor sem defeito superiores a 95%. No entanto, para a identificação do nível de desgaste, em média, os índices de precisão por classe de defeitos são inferiores a 30%. Novamente, considerando o diagnóstico de motor com defeito/motor sem defeito, ambos os classificadores k -NN e PMC obtiveram índices de precisão acima de 95%.

Além disso, os testes efetuados no laboratório de Máquinas Elétricas da UVA também adotam diferentes níveis de severidade, a saber: as amostras referentes aos primeiro, segundo e terceiro dias de testes definidas como Nível de desgaste inicial - Nível 1; as amostras referentes aos quarto, quinto e sexto dias de testes foram definidas como desgaste intermediário - Nível 2; as amostras referentes aos sétimo e oitavo dias como Nível Avançado - Nível 3; já as amostras referentes aos nono e décimo dias de testes foram consideradas como rolamento operando em Nível Crítico - Nível 4. Neste cenário, o algoritmo PMC apresenta precisão de 70,3% para diagnóstico de motor operando com rolamento em nível de desgaste inicial, 66% para identificação de rolamento com intermediário, 62% de precisão para diagnóstico de desgaste avançado, e 60,3% para nível de desgaste crítico.

Finalmente, nos testes considerando a multiclassificação de todas as falhas associadas a esta pesquisa mostram que os algoritmos PMC e k -NN apresentam os melhores índices de precisão. Especificamente com o algoritmo PMC é possível atingir índice de precisão de 84,4% para o diagnóstico do motor sem defeitos. Para o diagnóstico de motor operando com falha de curto-circuito de estator foi obtido 90,6 % de precisão, 96,4% de precisão para diagnóstico de motor operando com barras quebradas de rotor e 91,5% para diagnóstico de motor operando com defeito de rolamento.

Neste estudo de diagnóstico e multiclassificação de falhas em motores de indução alimentados por diferentes inversores de frequência, a rede PMC apresenta os melhores índices de precisão global, seguido pelo método k -NN.

Os resultados confirmam ainda a viabilidade do método proposto para a multiclassificação de falhas de estator, rotor e rolamentos, independentemente da velocidade de operação da máquina ou condições de carga, que não influenciam os resultados de diagnóstico. Além disso, esta metodologia pode ser aplicada a MIT diretamente acionados

pela rede elétrica.

6.1 Perspectivas para Trabalhos Futuros

Os trabalhos futuros associados a esta pesquisa baseiam-se no aperfeiçoamento dos métodos propostos para identificação de falhas em motores de indução alimentados por inversores de frequência. Assim, a partir dos resultados obtidos neste trabalho são sugeridas as seguintes perspectivas:

- ❑ Conciliar a técnica de detecção de falhas no domínio do tempo e técnicas no domínio da frequência, bem como avaliar a possibilidade de utilizar transformadas visando incrementar a precisão de classificação;
- ❑ Investigar a influência do perfil de variação da temperatura em motores de indução acionados com inversores de frequência, na presença de falhas, ao longo de uma ampla faixa de variação de velocidade e conjugado de carga;
- ❑ Desenvolver métodos para o diagnóstico de falhas durante o regime transitório de máquinas acionadas por inversores de frequência, a partir da extração de diferentes padrões de falhas;
- ❑ Melhorar o desempenho dos multiclassificadores de falhas de rotor e rolamentos a partir de outras técnicas avançadas de processamento de sinais;
- ❑ Implementar em *hardware* dedicado a melhor estratégia baseada nos classificadores avaliados neste trabalho, para o diagnóstico e classificação de falhas em tempo real.

6.2 Produção Científica

Os resultados parciais do presente trabalho foram reunidos nos artigos científicos listados a seguir:

- ❑ Artigos publicados em periódicos - Autor principal
 - GODOY, Wagner F.; SILVA, Ivan Nunes; GOEDEL, Alessandro; PALÁCIOS, Rodrigo Henrique Cunha. Evaluation of stator winding faults severity in inverter-fed induction motors. *Applied Soft Computing* (Print), v. 32, p. 420-431, 2015.
 - GODOY, Wagner F.; SILVA, Ivan Nunes; GOEDEL, Alessandro; PALÁCIOS, Rodrigo Henrique Cunha. Application of intelligent tools to detect and classify broken rotor bars in three-phase induction motors fed by an inverter. *IET Electric Power Applications* (Print), v. 1, p. 1-10, 2016.

❑ Colaboração direta

- PALÁCIOS, Rodrigo Henrique C.; SILVA, Ivan Nunes ; GOEDTEL, Alessandro ; GODOY, Wagner F.. A novel multi-agent approach to identify faults in line connected three-phase induction motors. *Applied Soft Computing* (Print), v. 45, p. 1-10, 2016.
- PALÁCIOS, RODRIGO HENRIQUE CUNHA; GOEDTEL, Alessandro ; GODOY, Wagner 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*, v. 1, p. 1-13, 2016.
- PALÁCIOS, Rodrigo Henrique C.; SILVA, Ivan Nunes; GOEDTEL, Alessandro; GODOY, Wagner F.. A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. *Electric Power Systems Research* (Print), v. 127, p. 249-258, 2015.
- PALÁCIOS, Rodrigo Henrique C.; SILVA, Ivan Nunes; GOEDTEL, Alessandro; GODOY, Wagner F.; OLESKOVICZ, MÁRIO. A Robust Neural Method to Estimate Torque in Three-Phase Induction Motor. *Journal of Control, Automation and Electrical Systems*, v. 1, p. 1, 2014.

❑ Artigos publicados em conferências internacionais - Autor principal

- GODOY, W. F.; SILVA, Ivan Nunes; GOEDTEL, Alessandro ; PALÁCIOS, Rodrigo Henrique C.. Application of Artificial Neural Networks and PCA for Fault Diagnosis in Inverter-Fed Induction Motors. In: 10th Internacional Symposium on Diagnostics for Electric Machines, 2015, Guarda - Portugal. *SDEMPED 2015*, 2015. v. 0. p. 0-0.
- GODOY, Wagner Fontes; SILVA, Ivan Nunes; GOEDTEL, Alessandro; PALÁCIOS, Rodrigo Henrique Cunha; GONGORA, Wylliam Salviano. Neural Approach for Bearing Fault Classification in Induction Motors by Using Motor Current and Voltage. In: *IEEE World Congress on Computational Intelligence*, 2014, Pequim. *Proceedings of the 2014 IEEE World Congress on Computational Intelligence*, 2014. p. 2087-2092.
- GODOY, W. F.; SILVA, Ivan Nunes; GOEDTEL, Alessandro; PALÁCIOS, Rodrigo Henrique C.. Fuzzy Logic Applied at Industrial Roasters in the Temperature Control. In: 11th IFAC Workshop on Intelligent Manufacturing Systems (IMS 13), 2013, São Paulo - Brasil. *11th IFAC Workshop on Intelligent Manufacturing Systems*.

❑ Colaboração direta

- PALÁCIOS, Rodrigo Henrique C. ; SILVA, Ivan Nunes ; GOEDTEL, Alessandro ; GODOY, Wagner F.. Neuro-Fuzzy Approach to Estimate the Torque in Three-Phase Induction Motors with Unbalanced Power. In: 11th IFAC Workshop on Intelligent Manufacturing Systems.

□ Artigos publicados em conferências nacionais - Autor principal

- GODOY, W. F.; SILVA, Ivan Nunes; GOEDTEL, Alessandro; PALACIOS, R. H. C.; BAZAN, G. H.. Sistemas Inteligentes Aplicados no Diagnóstico de Barras Quebradas de Rotor em Motores de Indução Alimentados por Inversores de Frequência. In: XII Simpósio Brasileiro de Automação Inteligente, 2015, Natal/RN/Brasil. XII SBAI, 2015.
- GODOY, W. F.; SILVA, Ivan Nunes; PALÁCIOS, Rodrigo Henrique C.; GOEDTEL, Alessandro; GRACIOLA, C. L.; BRONIERA, P.. Rede Fuzzy Artmap para Classificação de Falhas de Estator em Motores de Indução Trifásicos. In: XX Congresso Brasileiro de Automática, 2014, Belo Horizonte, MG, Brasil.
- GODOY, W. F.; SILVA, Ivan Nunes; GONGORA, W. S.; GOEDTEL, Alessandro; PALÁCIOS, Rodrigo Henrique C.. Classificação de Falhas em Rolamentos de Motores de Indução Trifásicos Utilizando Redes Neurais Artificiais. XI Simpósio Brasileiro de Automação Inteligente (SBAI), 2013, Fortaleza/CE.

□ Colaboração direta

- PALÁCIOS, Rodrigo Henrique C.; SILVA, Ivan Nunes; GOEDTEL, A.; GODOY, Wagner F.; LOPES, Tiago Drummond. Reconhecedor Neural de Defeitos no Estator em Motores de Indução Trifásicos Apoiado por Análise de Componentes Principais. In: XII Simpósio Brasileiro de Automação Inteligente, 2015, Natal, RN, Brasil. XII SBAI, 2015.
- PALÁCIOS, Rodrigo Henrique C.; SILVA, Ivan Nunes; GOEDTEL, Alessandro; GODOY, Wagner F.; GONGORA, W. S.; LOPES, Tiago Drummond. Estudo Comparativo entre SVM e RNA no Reconhecimento de Defeito em Rolamentos de Motores de Indução. In: XX Congresso Brasileiro de Automática, 2014, Belo Horizonte, MG, Brasil. XX CBA, 2014.
- PALÁCIOS, Rodrigo Henrique C.; SILVA, Ivan Nunes; GODOY, Wagner F.; GOEDTEL, Alessandro; OLESKOVICZ, M.. Estimador de Torque em Motores de Indução Trifásicos com Alimentação Desequilibrada Baseado em Redes Neurais Artificiais. In: X Conferência Brasileira sobre Qualidade da Energia Elétrica, 2013, Araxá-MG. X CBQEE, 2013.
- LOPES, Tiago Drummond; GOEDTEL, Alessandro; PALACIOS, R. H. C.; BAZAN, G. H.; GODOY, W. F.. Análise Comparativa da Detecção de Defeitos

em Rolamentos em Motores de Indução Trifásicos Utilizando RBF e SFAM. In: XII Simpósio Brasileiro de Automação Inteligente, 2015, Nata/RN/Brasil. XII SBAI, 2015.

- LOPES, Tiago Drummond; GOEDTEL, A.; PALACIOS, R. H. C.; GODOY, W. F.; GRACIOLA, C. L. Um Estudo de Redes Neurais Artificiais do Tipo PMC na Detecção de Defeitos nos Rolamentos de Máquinas de Indução. In: XII Simpósio Brasileiro de Automação Inteligente, 2015, Natal/RN/Brasil. XII SBAI, 2015.

Referências

ABRAMAM, . A situação da manutenção no brasil. **28° Congresso Brasileiro de Manutenção**, 2013. p. 1–23, 2013.

ABU-RUB, H.; AHMED, S.; IQBAL, A.; RAHIMIAN, M.; TOLİYAT, H. Incipient bearing fault diagnostics for inverter fed induction motor drive using anfis. In: **XIX International Conference on Electrical Machines (ICEM)**. [S.l.: s.n.], 2010. p. 1–5.

AKIN, B.; ORGUNER, U.; TOLİYAT, H.; RAYNER, M. Low order pwm inverter harmonics contributions to the inverter-fed induction machine fault diagnosis. **IEEE Transactions on Industrial Electronics**, 2008. v. 55, n. 2, p. 610–619, 2008.

AKIN, B.; TOLİYAT, H.; ORGUNER, U.; RAYNER, M. Pwm inverter harmonics contributions to the inverter-fed induction machine bearing fault diagnosis. In: **Twenty Second Annual IEEE Applied Power Electronics Conference (APEC)**. [S.l.: s.n.], 2007. p. 1393–1399.

ALI, J. B.; SAIDI, L.; MOUELHI, A.; CHEBEL-MORELLO, B.; FNAIECH, F. Linear feature selection and classification using pnn and sfam neural networks for a nearly online diagnosis of bearing naturally progressing degradations. **Engineering Applications of Artificial Intelligence**, 2015. v. 42, p. 67 – 81, 2015.

ALPAYDIN, E. **Introduction to Machine Learning**. 2nd. ed. [S.l.]: The MIT Press, 2010. ISBN 026201243X, 9780262012430.

AMARAL, T.; PIRES, V.; MARTINS, J.; PIRES, A.; CRISOSTOMO, M. Image processing to a neuro-fuzzy classifier for detection and diagnosis of induction motor stator fault. In: **33rd Annual Conference of the IEEE Industrial Electronics Society. IECON 2007**. [S.l.: s.n.], 2007. p. 2408–2413.

ARAÚJO, R.; RODRIGUES, R. A.; PAULA, H. D.; BACCARINI, L. M. R. Desgaste prematuro e falhas recorrentes dos rolamentos de um mit: Estudo de caso. In: **9th IEEE/IAS International Conference on Industry Applications (INDUSCON)**. [S.l.: s.n.], 2010. p. 1–6.

ARAÚJO, R. d. S. **Desgaste Prematuro e Falhas Recorrentes em Rolamentos de Motores de Indução Alimentados por Inversores: Análise e Proposta de Solução**. Tese (Doutorado) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, 2011.

AYDIN, I.; KARAKOSE, M.; AKIN, E. An adaptive artificial immune system for fault classification. **Journal of Intelligent Manufacturing**, 2012. Springer US, v. 23, n. 5, p. 1489–1499, 2012. ISSN 0956-5515.

BACCARINI, L.; AVELAR, V.; SILVA, V.; AMARAL, G. Intelligent system design for stator windings faults diagnosis: suitable for maintenance work. **Journal of Software Engineering and Applications.**, 2013. v. 6, n. 10, p. 526–532, 2013.

BACCARINI, L. M. R. **Detecção e Diagnóstico de Falhas em Motores de Indução**. Tese (Doutorado) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, 2005.

BACCARINI, L. M. R.; MENEZES, B. R. d.; CAMINHAS, W. M. Fault induction dynamic model, suitable for computer simulation: Simulation results and experimental validation. **Mechanical Systems and Signal Processing**, 2010. v. 24, n. 1, p. 300 – 311, 2010.

BARENDSE, P.; PILLAY, P. The detection of unbalanced faults in inverter-fed induction machines. In: **IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives**. [S.l.: s.n.], 2007. p. 46–51.

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**, 2013. v. 28, n. 4, p. 1064–1071, Dec 2013.

BASARAN, M.; ECE, D. Detection of mechanical faults in induction motors supplied with adjustable speed drives. In: **IEEE International Electric Machines and Drives Conference (IEMDC)**. [S.l.: s.n.], 2009. p. 1414–1419.

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

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

BRIZ, F.; DEGNER, M.; GARCIA, P.; DIEZ, A. High-frequency carrier-signal voltage selection for stator winding fault diagnosis in inverter-fed ac machines. **IEEE Transactions on Industrial Electronics**, 2008. v. 55, n. 12, p. 4181–4190, 2008.

BRIZ, F.; DEGNER, M.; GUERRERO, J.; GARCIA, P. Stator windings fault diagnostics of induction machines operated from inverters and soft-starters using high-frequency negative-sequence currents. **IEEE Transactions on Industry Applications**, 2009. v. 45, n. 5, p. 1637–1646, 2009.

BRONIERA, P. J. Mestrado, **Diagnóstico de Curto-Circuito no Enrolamento do Estator em Máquinas de Indução Trifásicas Utilizando Redes Neurais Artificiais**. 2014.

CARPENTER, G.; GROSSBERG, S. Art2: Self-organizing of stable category recognition codes for analog input patterns. **Applied Optics, New York.**, 1987. v. 26, p. 4919–4930, 1987.

- CARPENTER, G.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J.; ROSEN, D. Fuzzy artmap: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, 1992. v. 3, n. 5, p. 698–713, Sep 1992.
- CHEN, C.; ZHANG, B.; VACHTSEVANOS, G.; ORCHARD, M. Machine condition prediction based on adaptive neuro fuzzy and high-order particle filtering. **IEEE Transactions on Industrial Electronics**, 2011. v. 58, n. 9, p. 4353–4364, 2011.
- CHUA, T.; TAN, W.-W.; WANG, Z.-X.; CHANG, C. Hybrid time-frequency domain analysis for inverter-fed induction motor fault detection. In: **IEEE International Symposium on Industrial Electronics (ISIE)**. [S.l.: s.n.], 2010. p. 1633–1638.
- CRISTALDI, L.; FAIFER, M.; LAZZARONI, M.; TOSCANI, S. An inverter-fed induction motor diagnostic tool based on time-domain current analysis. **IEEE Transactions on Instrumentation and Measurement**, 2009. v. 58, n. 5, p. 1454–1461, 2009.
- CUSIDO, J.; ROMERAL, L.; ORTEGA, J.; ROSERO, J.; ESPINOSA, A. G. Fault detection in induction machines using power spectral density in wavelet decomposition. **IEEE Transactions on Industrial Electronics**, 2008. v. 55, n. 2, p. 633–643, 2008.
- DAS, S.; KOLEY, C.; PURKAIT, P.; CHAKRAVORTI, S. Wavelet aided svm classifier for stator inter-turn fault monitoring in induction motors. In: **IEEE Power and Energy Society General Meeting, 2010**. [S.l.: s.n.], 2010. p. 1–6.
- DAS, S.; PURKAIT, P.; KOLEY, C.; CHAKRAVORTI, S. Performance of a load-immune classifier for robust identification of minor faults in induction motor stator winding. **IEEE Transactions on Dielectrics and Electrical Insulation**, 2014. v. 21, n. 1, p. 33–44, February 2014.
- DLAMINI, M.; BARENDSE, P. The detection of inter-turn stator faults on inverter fed induction motors. In: **IEEE Power Engineering Society Conference and Exposition in Africa (PowerAfrica)**. [S.l.: s.n.], 2012. p. 1–8.
- 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**, 2014. v. 10, n. 2, p. 1348–1360, May 2014.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2. ed. New York: J. Willey and Sons, Inc, 2001.
- DUQUE-PEREZ, O.; GARCIA-ESCUADERO, L. A.; MORINIGO-SOTELO, D.; GARDEL, P. E.; PEREZ-ALONSO, M. Condition monitoring of induction motors fed by voltage source isilvanverters. statistical analysis of spectral data. In: **XX International Conference on Electrical Machines (ICEM)**. [S.l.: s.n.], 2012. p. 2479–2484.
- DUQUE-PEREZ, O.; MORINIGO-SOTELO, D.; PEREZ-ALONSO, M. Diagnosis of induction motors fed by supplies with high harmonic content using motor current signature analysis. In: **International Conference on Power Engineering, Energy and Electrical Drives (POWERENG)**. [S.l.: s.n.], 2011. p. 1–6.

DUQUE-PEREZ, O.; MORINIGO-SOTELO, D.; RODRIGUEZ-CARRASCAL, A.; GARCIA-ESCUADERO, L.; PEREZ-ALONSO, M. Experimental identification of induction motor broken bar characteristic frequencies using a programmable power source. In: **XIX International Conference on Electrical Machines (ICEM)**. [S.l.: s.n.], 2010. p. 1–6.

EBRAHIMI, B. M.; FAIZ, J.; LOTFI-FARD, S.; PILLAY, P. Novel indices for broken rotor bars fault diagnosis in induction motors using wavelet transform. **Mechanical Systems and Signal Processing**, 2012. v. 30, n. 0, p. 131 – 145, 2012.

EPE, . Balanço energético nacional 2014 - ano base 2013 - relatório final. **Empresa de Pesquisa Energética - Ministério de Minas e Energia**, 2014. p. 288, 2014.

ESPINOZA-TREJO, D. R.; CAMPOS-DELGADO, D.; BRCENAS, E.; MARTINEZ-LOIPEZ, F. Robust fault diagnosis scheme for open-circuit faults in voltage source inverters feeding induction motors by using non-linear proportional-integral observers. **IET Power Electronics**, 2012. v. 5, n. 7, p. 1204–1216, 2012.

FAIZ, J.; GHORBANIAN, V.; EBRAHIMI, B. Locating broken bars in line-start and inverter-fed induction motors using modified winding function method. **Electromagnetics**, 2012. v. 32, n. 3, p. 173–192, 2012.

_____. A survey on condition monitoring and fault diagnosis in line-start and inverter-fed broken bar induction motors. In: **IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)**. [S.l.: s.n.], 2012. p. 1–5.

FERNÁNDEZ-FRANCOS, D.; MARTÍNEZ-REGO, D.; FONTENLA-ROMERO, O.; ALONSO-BETANZOS, A. Automatic bearing fault diagnosis based on one-class v-svm. **Computers and Industrial Engineering**, 2013. v. 64, n. 1, p. 357 – 365, 2013.

FITZGERALD, A. E.; JR., C. K.; UMANS, S. D. **Máquinas Elétricas**. 6. ed. Porto Alegre: Bookman Companhia Editora, 2006.

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**, 2011. v. 58, n. 5, p. 1564–1575, 2011.

_____. Recent advances in modeling and online detection of stator interturn faults in electrical motors. **IEEE Transactions on Industrial Electronics**, 2011. v. 58, n. 5, p. 1564–1575, May 2011.

GARCIA-ESCUADERO, L.; DUQUE-PEREZ, O.; MORINIGO-SOTELO, D.; PEREZ-ALONSO, M. Robust multivariate control charts for early detection of broken rotor bars in an induction motors fed by a voltage source inverter. In: **2011 International Conference on Power Engineering, Energy and Electrical Drives (POWERENG)**. [S.l.: s.n.], 2011. p. 1–6.

GEORGAKOPOULOS, I.; MITRONIKAS, E.; SAFACAS, A. Detection of induction motor faults in inverter drives using inverter input current analysis. **IEEE Transactions on Industrial Electronics**, 2011. v. 58, n. 9, p. 4365–4373, 2011.

- GEORGAKOPOULOS, I.; MITRONIKAS, E.; SAFACAS, A.; TSOUMAS, I. Rotor fault detection in inverter drive systems using inverter input current analysis. In: **XIX International Conference on Electrical Machines (ICEM)**. [S.l.: s.n.], 2010. p. 1–5.
- GERMEN, E.; BASARAN, M.; FIDAN, M. Sound based induction motor fault diagnosis using kohonen self-organizing map. **Mechanical Systems and Signal Processing**, 2014. v. 46, n. 1, p. 45 – 58, 2014.
- 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)**, 2009. [S.l.: s.n.], 2009. p. 922–928.
- GODOY, W.; SILVA, I. da; GOEDTEL, A.; PALACIOS, R.; GONGORA, W. Neural approach for bearing fault classification in induction motors by using motor current and voltage. In: **2014 International Joint Conference on Neural Networks (IJCNN)**. [S.l.: s.n.], 2014. p. 2087–2092.
- GODOY, W.; SILVA, I. da; GOEDTEL, A.; PALACIOS, R.; BAZAN, G. Sistemas inteligentes aplicados no diagnóstico de barras quebradas de rotor em motores de indução alimentados por inversores de frequência. In: **XII Simpósio Brasileiro de Automação Inteligente - SBAI**. [S.l.: s.n.], 2015. p. 6.
- GODOY, W. F.; SILVA, I. N. da; GOEDTEL, A.; PALACIOS, R. H. C. Evaluation of stator winding faults severity in inverter-fed induction motors. **Applied Soft Computing**, 2015. v. 32, p. 420 – 431, 2015.
- GOEDTEL, A. **Estimador Neural de Velocidade para Motores de Indução Trifásicos**. Tese (Doutorado) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo - Escola de Engenharia de São Carlos, 2007.
- GOUVEA, M. R. d. **Controle Neurofuzzy de Motores de Indução com Estimção de Parâmetros e Fluxo de Estator**. Tese (Doutorado) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, 2005.
- GUAN, Y.; SUN, D.; HE, Y. Mean current vector based online real-time fault diagnosis for voltage source inverter fed induction motor drives. In: **IEEE International Electric Machines Drives Conference, 2007. IEMDC '07**. [S.l.: s.n.], 2007. v. 2, p. 1114–1118.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: An update, sigkdd explor. 2009. v. 11, n. 1, p. 10–18, 2009.
- HAN, J.; KAMBER, M.; PEI, J. **Data Mining: Concepts and Techniques**. 3. ed. Amsterdam: Elsevier: Morgan Kaufmann, 2011.
- HAYKIN, S. O. **Neural Networks and Learning Machines**. 3. ed. [S.l.]: Hardcover, 2008.
- HONG, J.; HYUN, D.; LEE, S. B.; KRAL, C. Monitoring of airgap eccentricity for inverter-fed induction motors based on the differential inductance. In: **IEEE Energy Conversion Congress and Exposition (ECCE)**. [S.l.: s.n.], 2012. p. 3000–3007.

- INGLE, V. K.; PROAKIS, J. G. **Digital Signal Processing Using Matlab**. 1. ed. [S.l.]: PWS Publishing Company, 1997. 420 p.
- JIN, X.; YUAN, F.; CHOW, T. W.; ZHAO, M. Weighted local and global regressive mapping: A new manifold learning method for machine fault classification. **Engineering Applications of Artificial Intelligence**, 2014. v. 30, p. 118 – 128, 2014.
- JUNIOR, A. M. Mestrado, **Uma Abordagem sobre Detecção de Barras Quebradas em Motores de Indução**. 2008.
- KANKAR, P. K.; SHARMA, S. C.; HARSHA, S. P. Fault diagnosis of ball bearings using continuous wavelet transform. **Applied Soft Computing**, 2011. Elsevier Science Publishers B. V., v. 11, n. 2, p. 2300–2312, mar. 2011.
- KARABADJI, N. E. I.; SERIDI, H.; KHELF, I.; AZIZI, N.; BOULKROUNE, R. Improved decision tree construction based on attribute selection and data sampling for fault diagnosis in rotating machines. **Engineering Applications of Artificial Intelligence**, 2014. v. 35, n. 0, p. 71 – 83, 2014.
- KIM, B.; LEE, K.; YANG, J.; LEE, S.-B.; WIEDENBRUG, E.; SHAH, M. Automated detection of rotor faults for inverter-fed induction machines under standstill conditions. **IEEE Transactions on Industry Applications**, 2011. v. 47, n. 1, p. 55–64, 2011.
- KIM, M.-J.; KIM, B.-K.; MOON, J.-W.; CHO, Y.-H.; HWANG, D.-H.; KANG, D.-S. Analysis of inverter-fed squirrel-cage induction motor during eccentric rotor motion using fem. **IEEE Transactions on Magnetics**, 2008. v. 44, n. 6, p. 1538–1541, 2008.
- KIM, S.-K.; SEOK, J.-K. High-frequency signal injection-based rotor bar fault detection of inverter-fed induction motors with closed rotor slots. **IEEE Transactions on Industry Applications**, 2011. v. 47, n. 4, p. 1624–1631, 2011.
- LANDIS, J. R.; G., K. G. The measurement of observer agreement for categorical data. **International Biometric Society**, 1977. v. 33, n. 1, p. 159–174, 1977.
- LEE, J.; WU, F.; ZHAO, W.; GHAFARI, M.; LIAO, L.; SIEGEL, D. Prognostics and health management design for rotary machinery systems reviews, methodology and applications. **Mechanical Systems and Signal Processing**, 2014. v. 42, n. 1, p. 314 – 334, 2014.
- LEE, K.; HONG, J.; LEE, K.-W.; LEE, S.-B.; WIEDENBRUG, E. A stator core quality assessment technique for inverter-fed induction machines. **IEEE Transactions on Industry Applications**, 2010. v. 46, n. 1, p. 213–221, 2010.
- LIU, Z.; CAO, H.; CHEN, X.; HE, Z.; SHEN, Z. Multi-fault classification based on wavelet {SVM} with {PSO} algorithm to analyze vibration signals from rolling element bearings. **Neurocomputing**, 2013. v. 99, p. 399 – 410, 2013.
- MALANGE, F. C. V. **Rede Neuro-Fuzzy-Wavelet para Detecção e Classificação de Anomalias de Tensão em Sistemas Elétricos de Potência**. Tese (Doutorado) — Universidade Estadual Paulista - Júlio de Mesquita Filho - Campus de Ilha Solteira, Programa de Pós-Graduação em Engenharia Elétrica, 2010.
- MALLAT, S. **A wavelet tour of signal processing**. 2. ed. [S.l.]: Cambridge: Academic Press, 1999.

- MAOUCHE, Y.; OUMAAMAR, M. E. K.; BOUCHERMA, M.; KHEZZAR, A. Instantaneous power spectrum analysis for broken bar fault detection in inverter-fed six-phase squirrel cage induction motor. **International Journal of Electrical Power and Energy Systems**, 2014. v. 62, p. 110 – 117, 2014.
- MORINIGO-SOTELO, D.; GARCIA-ESCUADERO, L.; DUQUE-PEREZ, O.; PEREZ-ALONSO, M. Practical aspects of mixed-eccentricity detection in pwm voltage-source-inverter-fed induction motors. **IEEE Transactions on Industrial Electronics**, 2010. v. 57, n. 1, p. 252–262, 2010.
- MUETZE, A.; BINDER, A. Practical rules for assessment of inverter-induced bearing currents in inverter-fed ac motors up to 500 kw. **IEEE Transactions on Industrial Electronics**, 2007. v. 54, n. 3, p. 1614–1622, 2007.
- MUTHUSELVAN, N. B.; DASH, S.; SOMASUNDARAM, P. A high performance induction motor drive system using fuzzy logic controller. In: **IEEE Region 10 Conference (TENCON)**. [S.l.: s.n.], 2006. p. 1–4.
- NASCIMENTO, C. F. do; JR., A. A. de O.; GOEDTEL, A.; SERNI, P. J. A. Harmonic identification using parallel neural networks in single-phase systems. **Applied Soft Computing**, 2011. v. 11, n. 2, p. 2178 – 2185, 2011.
- NUSSBAUMER, P.; STOJICIC, G.; WOLBANK, T. Exploiting switching transients for broken rotor bar detection in inverter-fed induction machines at all operating conditions. In: **IEEE International Electric Machines Drives Conference (IEMDC)**. [S.l.: s.n.], 2011. p. 418–423.
- ONDEL, O.; CLERC, G.; BOUTLEUX, E.; BLANCO, E. Fault detection and diagnosis in a set inverter induction machine through multidimensional membership function and pattern recognition. **IEEE Transactions on Energy Conversion**, 2009. v. 24, n. 2, p. 431–441, 2009.
- ONEL, I.; AYCICEK, E.; SENOLL, I. An experimental study, about detection of bearing defects in inverter fed small induction motors by concordia transform. **Journal of Intelligent Manufacturing**, 2009. Springer US, v. 20, n. 2, p. 243–247, 2009.
- OPPENHEIM, A. V.; SCHAFER, R. W. **Discrete-time signal processing**. 3. ed. [S.l.]: Upper Saddle River: Prentice-Hall, 2010. 1108 p.
- PALACIOS, 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**, 2014. Springer US, v. 25, n. 4, p. 493–502, 2014.
- PALÁCIOS, R. H. C.; SILVA, I. N. da; GOEDTEL, A.; GODOY, W. F. A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. **Electric Power Systems Research**, 2015. v. 127, p. 249 – 258, 2015.
- PARK, J.-H.; KIM, D.-H.; KIM, S.-S.; LEE, D.-J.; CHUN, M.-G. C-anfis based fault diagnosis for voltage-fed pwm motor drive systems. In: **IEEE Annual Meeting of the Fuzzy Information, 2004. Processing NAFIPS '04**. [S.l.: s.n.], 2004. v. 1, p. 379–383.

- PLATT, J. Fast training of support vector machines using sequential minimal optimization. In: SCHOELKOPF, B.; BURGESS, C.; SMOLA, A. (Ed.). **Advances in Kernel Methods - Support Vector Learning**. [S.l.]: MIT Press, 1998.
- SAMANTA, B.; NATARAJ, C. Use of particle swarm optimization for machinery fault detection. **Engineering Applications of Artificial Intelligence**, 2009. v. 22, n. 2, p. 308 – 316, 2009.
- SANTOS, F.; SILVA, I. da; SUETAKE, M. Neural network classifier for faults detection in induction motors. In: **International Conference on Computer Applications Technology (ICCAT)**. [S.l.: s.n.], 2013. p. 1–5.
- SANTOS, F. M. d. C. **Identificação de Falhas em Motores de Indução Trifásicos Utilizando Sistemas Inteligentes**. Tese (Doutorado) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo - Escola de Engenharia de São Carlos, 2013.
- SANTOS, F. M. d. C.; SILVA, I. N. d.; SUETAKE, M. Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução - uma visão geral. **Sba: Controle & Automação Sociedade Brasileira de Automática**, 2012. scielo, v. 23, p. 553 – 569, 10 2012. ISSN 0103-1759.
- SAYOUTI, Y.; ABOU, A.; AKHERRAZ, M.; MAHMOUDI, H. Sensor less low speed control with ann mras for direct torque controlled induction motor drive. In: **International Conference on Power Engineering, Energy and Electrical Drives (POWERENG)**. [S.l.: s.n.], 2011. p. 1–5.
- SCHMITT, H.; SILVA, L.; SCALASSARA, P.; GOEDTEL, A. Bearing fault detection using relative entropy of wavelet components and artificial neural networks. In: **Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED), 2013 9th IEEE International Symposium on**. [S.l.: s.n.], 2013. p. 538–543.
- SEDRA, A. S.; SMITH, K. C. **Microeletrônica**. 4. ed. São Paulo, SP: Pearson Makron Books, 1995.
- 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**, 2012. v. 23, n. 1, p. 97–108, 2012.
- SEERA, M.; LIM, C. P.; ISHAK, D.; SINGH, H. Offline and online fault detection and diagnosis of induction motors using a hybrid soft computing model. **Applied Soft Computing**, 2013. v. 13, n. 12, p. 4493 – 4507, 2013.
- SEERA, M.; LIM, C. P.; NAHAVANDI, S.; LOO, C. K. Condition monitoring of induction motors: A review and an application of an ensemble of hybrid intelligent models. **Expert Systems with Applications**, 2014. v. 41, n. 10, p. 4891 – 4903, 2014.
- 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**, 2014. v. 29, n. 2, p. 936–945, Feb 2014.

- SHI, P.; CHEN, Z.; VAGAPOV, Y.; ZOUAOU, Z. A new diagnosis of broken rotor bar fault extent in three phase squirrel cage induction motor. **Mechanical Systems and Signal Processing**, 2014. v. 42, n. 1, p. 388–403, 2014.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**. São Paulo: ArtLiber, 2010. 399 p.
- SIQUEIRA, I. P. d. **Manutenção Centrada na Confiabilidade**. 1. ed. Rio de Janeiro: Qualitymark Editora, 2005.
- STIEBLER, M.; PLOTKIN, Y. Online winding temperature monitoring of pwm inverter-fed induction machines. In: **Power Electronics and Applications, 2005 European Conference on**. [S.l.: s.n.], 2005. p. 5 pp.–P.5.
- STOJCIC, G.; JOKSIMOVIC, G.; VASAK, M.; PERIC, N.; WOLBANK, T. Inter turn short circuit detection at higher modulation indexes including six step operation. In: **XXth International Conference on Electrical Machines (ICEM)**. [S.l.: s.n.], 2012. p. 2485–2491.
- SUETAKE, M. **Sistemas Inteligentes para o Diagnóstico de Falhas em Motores de Indução Trifásicos**. Tese (Doutorado) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo - Escola de Engenharia de São Carlos, 2012.
- SUETAKE, M.; SILVA, I. da; GOEDTEL, A. Embedded dsp-based compact fuzzy system and its application for induction-motor speed control. **IEEE Transactions on Industrial Electronics**, 2011. v. 58, n. 3, p. 750–760, March 2011.
- TAKBASH, A.; FAIZ, J.; EBRAHIMI, B. Losses characterization in voltage-fed pwm inverter induction motor drives under rotor broken bars fault. **IEEE Transactions on Magnetics**, 2013. v. 49, n. 4, p. 1516–1525, April 2013.
- THORSEN, O.; DALVA, M. A survey of faults on induction motors in offshore oil industry, petrochemical industry, gas terminals and oil refineries. In: **41st Annual Petroleum and Chemical Industry Conference, 1994. Record of Conference Papers, Institute of Electrical and Electronics Engineers Incorporated Industry Applications Society**. [S.l.: s.n.], 1994. p. 1–9.
- TRABELSI, M.; BOUSSAK, M.; CHAARI, A. High performance single and multiple faults diagnosis in voltage source inverter fed induction motor drives. In: **XXth International Conference on Electrical Machines (ICEM)**. [S.l.: s.n.], 2012. p. 1717–1723.
- TRAN, V. T.; ALTHOBIANI, F.; BALL, A.; CHOI, B.-K. An application to transient current signal based induction motor fault diagnosis of fourier bessell expansion and simplified fuzzy artmap. **Expert Systems with Applications**, 2013. v. 40, n. 13, p. 5372 – 5384, 2013.
- TRIGEASSOU, J.-C. **Electrical Machines Diagnosis**. 1. ed. [S.l.]: ISTE Ltd. and John Wiley & Sons, Inc., 2011.
- WANG, J.; LIU, S.; GAO, R. X.; YAN, R. Current envelope analysis for defect identification and diagnosis in induction motors. **Journal of Manufacturing Systems**, 2012. v. 31, n. 4, p. 380 – 387, 2012.

WEEKS, M. **Processamento digital de sinais utilizando Matlab e Wavelets**. 2. ed. Rio de Janeiro: LTC, 2012.

WEG, . Guia de aplicação de inversores de frequência. **Guia do usuário**, 2009. p. 1–192, 2009.

WOLBANK, T.; NUSSBAUMER, P.; CHEN, H.; MACHEINER, P. Monitoring of rotor-bar defects in inverter-fed induction machines at zero load and speed. **IEEE Transactions on Industrial Electronics**, 2011. v. 58, n. 5, p. 1468–1478, 2011.

WOLBANK, T.; WOHRNSCHIMMEL, R. On-line stator winding faults detection in inverter fed induction motors by stator current reconstruction. In: **XXth International Conference on Electrical Machines and Drives**. [S.l.: s.n.], 1999. p. 253–257.

YAHIA, K.; CARDOSO, A.; ZOUZOU, S.; GUEDDIDI, S. Broken rotor bars diagnosis in an induction motor fed from a frequency converter: experimental research. **International Journal of System Assurance Engineering and Management**, 2012. Springer-Verlag, v. 3, n. 1, p. 40–46, 2012.

YANG, J.; LEE, S.-B.; YOO, J.-Y.; LEE, S.; OH, Y.; CHOI, C. A stator winding insulation condition monitoring technique for inverter-fed machines. **IEEE Transactions on Power Electronics**, 2007. v. 22, n. 5, p. 2026–2033, Sept 2007.

YANG, X.-j.; YI-LONG, C.; GONG, Y.-m. Analysis of capacitive parasitism in pwm inverter-fed motor. **Journal of Shanghai University**, 2001. v. 5, n. 1, p. 60–65, 2001.

YILMAZ, M.; AYAZ, E. Adaptive neuro-fuzzy inference system for bearing fault detection in induction motors using temperature, current, vibration data. In: **IEEE EUROCON 2009**. [S.l.: s.n.], 2009. p. 1140–1145.

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

ZHU, H.; HU, J.; GAO, L.; HUANG, H. Fault diagnosis of broken rotor bars of inverter-fed squirrel-cage induction motor at no-load using supply-side current based on hilbert demodulation technique. **Yi Qi Yi Biao Xue Bao/Chinese Journal of Scientific Instrument**, 2014. v. 35, n. 1, p. 139–147, 2014.