Universidade de São Paulo Escola de Engenharia de São Carlos Departamento de Engenharia Elétrica Programa de Pós-Graduação em Engenharia Elétrica

Fernanda Maria da Cunha Santos

Identificação de Falhas em Motores de Indução Trifásicos Usando Sistemas Inteligentes

Fernanda Maria da Cunha Santos

Identificação de Falhas em Motores de Indução Trifásicos Usando Sistemas Inteligentes

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

Área de concentração: Sistemas Dinâmicos

ORIENTADOR: Prof. Dr. Ivan Nunes da Silva

São Carlos 2013

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.

Santos, Fernanda Maria da Cunha
S237i Identificação de falhas em motores de indução trifásicos usando sistemas inteligentes / Fernanda Maria da Cunha Santos; orientador Ivan Nunes da . São Carlos, 2013.
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, 2013.
1. Motor de indução trifásico. 2. Sistemas inteligentes. 3. Identificação e diagnóstico de falhas.
4. Redes neurais artificiais. I. Título.

FOLHA DE JULGAMENTO

Candidata: Bacharel FERNANDA MARIA DA CUNHA SANTOS.

Título da tese: "Identificação de falhas em motores de indução trifásicos usando sistemas inteligentes".

Data da defesa: 14/03/2013

Comissão Julgadora:

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

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

Prof. Dr. Edson Bim (Universidade Estadual de Campinas/UNICAMP)

Prof^a. Dr^a. Luciana Cambraia Leite (Universidade Federal de Mato Grosso do Sul/UFMS)

Prof. Dr. Renato Crivellari Creppe (Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP - Bauru)

Resultado:

APROVADO

APROVADO

APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica e Presidente da Comissão de Pós-Graduação: Prof. Titular **Denis Vinicius Coury**

Porque dele e por meio dele, e para ele, são todas as coisas. Glória, pois a ele eternamente. Amém.

Romanos, 11, 36

Agradecimentos

Todo desenvolvimento desta tese de doutorado teve colaboração de diversas pessoas que me ajudaram direta ou indiretamente. Tentarei não esquecer de ninguém.

Primeiramente, preciso agradecer a meu esposo pela imensa paciência, amor e companheirismo. Sempre esteve ao meu lado, apoiando minhas ações, consolando-me nos momentos de stress e alegrando-se com minhas conquistas. Muito obrigada pelo seu apoio e sua dedicação.

Especiais agradecimentos faço à minha família, que foi o alicerce na minha formação pessoal. Minha mãe, um exemplo de mulher e de mãe, que me ensinou a nunca desistir de meus sonhos e que sempre esteve presente em minha vida, disposta a ajudar em tudo. A meu pai, mesmo em sua quietude, mostrou-me com sua valentia e determinação que podemos alcançar o que queremos com muito trabalho. Minhas queridas irmãs, Elisângela e Ana Paula, pelo incondicional amor fraterno, pela torcida e orações que fizeram por mim durante a realização deste trabalho.

Ao meu orientador Prof. Dr. Ivan Nunes da Silva, exemplo marcante de um educador competente, sagaz e, principalmente, solícito com seus alunos. Agradeço pelas valiosas dicas e ensinamentos na elaboração de artigos, o que contribuiu imensamente no crescimento de minha percepção crítica.

Aos ex-colegas de laboratório, pelos incontáveis auxílios e explicações em assuntos relacionados à Engenharia Elétrica, serei eternamente grata. Em especial, ao Prof. Dr. Ricardo Augusto Souza Fernandes, um atencioso colega e um professor demasiadamente dedicado à profissão. O Prof. Dr. Marcelo Suetake, pela imensa paciência nas explicações sobre máquinas elétricas e sobre análise de sinais.

As amigas da república, Maria Angélica Zucareli e Karem Marcomini, pela amizade, companheirismo e cuidados que tiveram comigo durante minha gravidez, sem esquecer das risadas que compartilhamos. Isto tudo são sentimentos que consolidaram uma verdadeira amizade.

Aos amigos dos laboratórios da Pós-Graduação da USP/São Carlos: Danilo Hernane Spatti, Evandra Maria Raymundo, Luciana de Toro Gomes Guimarães, Renan Menechelli, Rodrigo Antonio Faccioli e Yuri Andrey Olivato Assagra.

Aos funcionários da Universidade de São Paulo (USP/EESC/SEL), em especial à

secretária de Pós-Graduação, Jussara Ramos Zoia e Marisa H. R. V. Fortulan, sempre demonstrando competência e eficiência em suas funções.

À CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), pelo auxílio financeiro concedido no período da realização deste trabalho na forma de bolsa de estudos (143635/2008-5) sem a qual o mesmo não seria possível.

À Escola de Engenharia de São Carlos (EESC/USP) que acolheu esta tese de doutorado, por meio da destinação de espaço físico e apoio administrativo, traduzindo assim a grandiosidade da instituição e visão de futuro.

Resumo

SANTOS, F. (2013). "Identificação de Falhas em Motores de Indução Trifásicos Usando Sistemas Inteligentes". Tese de Doutorado – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2013.

Esta tese consiste em desenvolver um sistema de identificação e classificação de falhas em motores de indução trifásico. As falhas analisadas foram simuladas em laboratório e envolvem problemas elétricos, como curto-circuito no estator, e problemas mecânicos, como barras quebradas no rotor. O sistema computacional proposto é formado pela transformada discreta *wavelet*, pelo cálculo de variáveis estatísticas e por redes neurais artificiais. A partir dos sinais elétricos da corrente do estator, a transformada *wavelet* produz os coeficientes característicos das falhas, os quais são usados no cálculo das variáveis estatísticas, como a média, *root mean square, skewness* e *kurtosis*. Estes valores são transmitidos como dados de entrada para as redes neurais que identificam as falhas e classificam a natureza das mesmas. Por fim, resultados obtidos visam validar a metodologia sugerida, que buscou nos sistemas inteligentes soluções eficazes para diagnosticar falhas em máquinas elétricas.

Palavras-chave: Motor de Indução Trifásico, Sistemas Inteligentes, Identificação e Diagnóstico de Falhas, Redes Neurais Artificiais.

Abstract

SANTOS, F. (2013). "Identification of Faults in Three-Phase Induction Motors Using Intelligent Systems". Doctor Thesis – Engineering School of São Carlos, University of São Paulo, 2013.

This thesis consists in developing a system for the identification and classification of faults in three-phase electric motors. The faults were analyzed and simulated in the laboratory and involve electrical problems, such as short circuit in the stator, and mechanical problems, such as broken rotor bars. The proposed computer system is formed by discrete wavelet transform, by calculation of statistical variables and for artificial neural networks. From the electrical signals of the stator current, the wavelet transform produces characteristic coefficients of faults, which are extracted by calculating of statistics variables, such as mean, root mean square, skewness and kurtosis. These values are passed as input to the neural networks that identify faults and the severity of it. Finally, results aimed at validating the methodology suggested that sought effective solutions in intelligent systems to diagnose faults in electrical machines.

Keywords: Three-Phase Induction Motor, Intelligent System, Faults Diagnosis and Identification, Artificial Neural Networks.

Lista de Ilustrações

Representação do padrão da corrente em situações ideais na transformada do	
vetor de Park. (Fonte: Extraído do artigo CRUZ; CARDOSO (2001))	30
Comparação da trajetória das componentes i_d e i_q da corrente do estator em	
duas situações de falhas. (Fonte: Extraído do artigo ONEL; BENBOUZID	
$(2008)) \ldots $	30
Estrutura de uma rede neural MLP	34
Diagrama esquemático de um sistema fuzzy	37
Diagrama esquemático das funções do algoritmo PSO.	40
Exemplo de um banco de filtro.	41
Expansão em dois níveis de um banco de filtro.	42
Diagrama representando a metodologia do sistema de diagnóstico de falhas	46
Formas de onda das correntes trifásicas do MIT sem falhas sob carga de 1,5 Nm.	47
Formas de onda das correntes trifásicas do MIT, acionado pela rede elétrica,	
com uma barra perfurada no rotor	48
Formas de onda das correntes trifásicas do MIT, acionado pelo inversor em	
60 Hz, com uma barra perfurada no rotor	49
Formas de onda das correntes trifásicas do MIT, acionado pela rede elétrica,	
com 4 barras perfuradas no rotor	49
Formas de onda das correntes trifásicas do MIT, acionado pelo inversor, com	
4 barras perfuradas no rotor	50
Formas de onda das correntes trifásicas do MIT com curto-circuito no estator.	51
Coeficientes $wavelets$ da primeira iteração da DWT sob as correntes trifásicas	
de um motor com falhas no rotor	52
Coeficientes $wavelets$ da segunda iteração da DWT sob as correntes trifásicas	
de um motor com falhas no rotor	53
Coeficientes wavelets da terceira iteração da DWT sob as correntes trifásicas	
de um motor com falhas no rotor	54
Coeficientes $wavelets$ da primeira iteração da DWT sob as correntes trifásicas	
de um motor com falhas no estator	55
Coeficientes $wavelets$ da segunda iteração da DWT sob as correntes trifásicas	
de um motor com falhas no estator	56
	Representação do padrão da corrente em situações ideais na transformada do vetor de Park. (Fonte: Extraído do artigo CRUZ; CARDOSO (2001)) Comparação da trajetória das componentes $i_d e i_q$ da corrente do estator em duas situações de falhas. (Fonte: Extraído do artigo ONEL; BENBOUZID (2008))

3.13	Coeficientes $wavelets$ da segunda iteração da DWT sob as correntes trifásicas	
	de um motor com falhas no estator	57
3.14	Delimitação de uma amostra da corrente	58
3.15	Configuração da rede neural MLP.	61
3.16	Configuração da rede neural ELMN.	62
3.17	Arquitetura de uma rede neural RBF	63
4.1	Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural destinada aos motores acionados pela rede elétrica	68
4.2	Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural destinada aos motores acionados por inversores.	69
4.3	Percentagem de acertos na classificação dos conjuntos de treinamento e teste	
	da rede neural ELMN	71
4.4	Percentagem de acertos na classificação dos conjuntos de treinamento e teste	
	da rede neural MLP.	71
4.5	Percentagem de acertos na classificação dos conjuntos de treinamento e teste	
	da rede neural RBF	72
4.6	Percentagem de acertos na classificação dos conjuntos de treinamento e teste	
	da rede neural ELMN	73
4.7	Percentagem de acertos na classificação dos conjuntos de treinamento e teste	
	da rede neural MLP	74
4.8	Percentagem de acertos na classificação dos conjuntos de treinamento e teste	
	da rede neural RBF	74
4.9	Percentagem de acertos dos conjuntos de treinamento e teste da rede neural	
	ELMN, para identificação de falhas no estator	76
4.10	Percentagem de acertos dos conjuntos de treinamento e teste da rede neural	
	MLP, para identificação de falhas no estator	77
4.11	Percentagem de acertos dos conjuntos de treinamento e teste da rede neural	
	RBF, para identificação de falhas no estator	77
4.12	Percentagem de acertos dos conjuntos de treinamento e teste da rede neural	
	ELMN, para identificação de falhas no estator	79
4.13	Percentagem de acertos dos conjuntos de treinamento e teste da rede neural	
	MLP, para identificação de falhas no estator	80
4.14	Percentagem de acertos dos conjuntos de treinamento e teste da rede neural	
	RBF, para identificação de falhas no estator	80
A.1	Esquema geral do laboratório de ensaios de máquinas elétricas	102
A.2	Imagens de um <i>Variac</i> e de sensores Hall	102
A.3	Sistema de aquisição de dados.	103
A.4	Procedimento para a inserção de falhas em rotores.	104

A.5	Disposição das bobinas ao longo das ranhuras do estator	105
A.6	Derivações do enrolamento do estator nos ensaios de curto-circuito. $\ .\ .\ .$	105
A.7	Foto ilustrativa dos terminais de derivação	106

Lista de Tabelas

3.1	Descrição das características das RNAs, empregadas na análise de motores	
	acionados pela rede elétrica	64
3.2	Descrição das características das RNAs, empregadas na análise de motores	
	acionados por inversor trifásico	64
3.3	Padrão de saída das redes neurais para identificar se há falhas	64
3.4	Padrão de saídas das redes neurais MLP, RBF e ELMN para falhas no rotor	64
3.5	Padrão de saídas das redes neurais MLP, RBF e ELMN para falhas no estator.	65
4.1	Matriz de confusão resultante do sistema de diagnóstico para falhas no motor	
	acionado pela rede elétrica.	69
4.2	Matriz de confusão resultante do sistema de diagnóstico para falhas no motor	
	acionado por inversor.	70
4.3	Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede	
	ELMN	72
4.4	Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede	
	MLP	73
4.5	Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede	
	RBF	73
4.6	Matriz de confusão do conjunto de dados resultante do sistema de diagnóstico,	
	constituído pela rede ELMN, para falhas no rotor	75
4.7	Matriz de confusão do conjunto de dados resultante do sistema de diagnóstico,	
	constituído pela rede MLP, para falhas no rotor	75
4.8	Matriz de confusão do conjunto de dados resultante do sistema de diagnóstico,	
	constituído pela rede RBF, para falhas no rotor	75
4.9	Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede	-
	ELMN para falhas no estator.	78
4.10	Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede	-
	MLP para falhas no estator.	78
4.11	Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede	-
1 10	RBF para talhas no estator.	78
4.12	Matriz de confusao resultante do sistema de diagnóstico, constituído pela rede	01
	ELMN para falhas no estator	81

4.13	Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede	
	MLP para falhas no estator.	81
4.14	Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede	
	RBF para falhas no estator.	81

Lista de Siglas

AG Algoritmo Genético AIS Artificial Immune System **DWT** Discrete Wavelet Transform **ELMN** Elman Neural Network **EPVA** Extended Park's Vector Approach FFT Fast Fourier Transform FMM Força Magnetomotriz GCC Gerador de Corrente Contínua **GRNN** General Regression Neural Networks IA Inteligência Artificial FAIS Fuzzy Artificial Immune System LF Lógica Fuzzy MCC Máquina de Corrente Contínua MCSA Motor Current Signature Analysis MIT Motor de Indução Trifásico **MLP** Multilayer Perceptron **MRA** Multiresolution analysis **PCA** Principal Component Analysis **PSO** Particle Swarm Optimization **RBF** Radial Basis Function **RNA** Rede Neural Artificial

SAGNN Self Adaptive Growing Neural Network

- ${\bf SOM} \ {\it Self-Organizing} \ {\it Maps}$
- SVM Support Vector Machine
- ${\bf TLFN} \ \ Time \ Lagged \ Feedforward \ Network$
- ${\bf TW}\,$ Transformada Wavelet
- $\mathbf{WPD} \ \ Wavelet \ Packet \ Decomposition$

Sumário

1	Inti	rodução	21
	1.1	Motivação e Relevância	21
	1.2	Justificativas	24
	1.3	Objetivos e Contribuições	25
	1.4	Organização da Tese	25
2	\mathbf{Est}	ado da Arte	27
	2.1	Introdução	27
	2.2	Métodos Convencionais Utilizados na Identificação de Falhas	27
	2.3	Abordagens Inteligentes Usadas na Identificação de Falhas	33
	2.4	Transformada Wavelet em Sistemas de Diagnóstico de Falhas	41
	2.5	Modos de Acionamentos de MIT	44
3	Ide	ntificação de Falhas em Motores de Indução Trifásicos Usando Re-	
	\mathbf{des}	Neurais Artificiais	45
	3.1	Introdução	45
	3.2	Aspectos dos Dados Experimentais	45
	3.3	Transformada Discreta $\mathit{Wavelet}$ e Delimitação das Amostras $\ .\ .\ .\ .$	50
	3.4	Extração de Características da Corrente Trifásica do MIT	58
	3.5	Organização Estrutural das Redes Neurais Artificiais	60
4	Res	ultados Experimentais	67
	4.1	Introdução	67
	4.2	Testes Experimentais I: Identificação de Falhas	67
	4.3	Testes Experimentais II: Identificação de Quebra de Rotor - Acionamento	
		pela Rede Elétrica	70
	4.4	Testes Experimentais III: Identificação de Quebra de Rotor - Acionamento	
		por Inversor	72
	4.5	Testes Experimentais IV: Identificação de Curto-Circuito no Estator - Aciona-	
		mento pela Rede Elétrica	76

	4.6	Testes Experimentais V: Identificação de Curto-Circuito no Estator - Aciona-	
		mento por Inversor	79
5	Con	clusões Gerais e Diretivas Futuras	83
	5.1	Conclusões Gerais	83
	5.2	Diretivas Futuras	85
Referências 8			87
A	Apêndice 9		
\mathbf{A}	Asp	ectos dos Procedimentos Experimentais de Bancada	101
	A.1	Montagem e Composição da Bancada	101
	A.2	As Falhas Elétricas do Motor de Indução Trifásico	103

Capítulo 1

Introdução

1.1 Motivação e Relevância

Motores de indução possuem uma presença significativa nos setores da industria, principalmente, quando se faz necessário a coversão de energia elétrica em mecânica motriz. Avalia-se que de 70 a 80% da energia elétrica consumida pelo conjunto de todas as indústrias seja transformada em energia mecânica pelos motores elétricos, o que traduz o acionamento de máquinas e de equipamentos mecânicos por motores elétricos um assunto de importância econômica (TRZYNADLOWSKI, 2001). Dentre estes equipamentos mecânicos, destacam-se dispositivos industriais essenciais para o sistema de produção, mas com estruturas físicas não sofisticadas, tais como bombas, ventiladores, compressores, elevadores, esteiras e exaustores.

Por definição, as máquinas rotativas de corrente alternada podem ser classificadas em máquinas síncronas e máquinas assíncronas. As máquinas síncronas possuem a velocidade de rotação fixa e dependente da frequência da tensão de suprimento. Nas máquinas assíncronas, a velocidade varia com a carga mecânica aplicada ao eixo e com a frequência. Ambas máquinas podem funcionar como gerador ou como motor. Os geradores convertem energia mecânica em energia elétrica. Com função inversa, um motor caracteriza-se por absorver energia elétrica e a converter em energia mecânica. No caso da máquina assíncrona, a utilização como gerador é pouco usual, e sua grande utilização na indústria é como motor assíncrono. Um motor é classificado de acordo com a tensão de alimentação durante o seu acionamento. Ou seja, ele é titulado por motor de corrente contínua e motor de corrente alternada, sendo essa última podendo funcionar em corrente alternada monofásica ou polifásica.

Os motores testados neste trabalho foram os motores de corrente alternada assíncronos trifásicos, também denominado Motor de Indução Trifásico (MIT). A escolha deste tipo de motor justifica-se pela sua popularidade nas indústrias, e, principalmente, pela simplicidade da sua estrutura, que o qualificou como um equipamento de baixo custo e de alta confiabilidade. Um motor de indução é composto de duas partes: estator e rotor. O estator constitui a parte estática do motor, e é formado por chapas finas de aço magnético com ranhuras internas, onde são alojados os enrolamentos. O motor recebe alimentação elétrica no enrolamento trifásico do estator, que está fixado em sua carcaça. O rotor é a parte móvel do motor, e que também é composto de chapas finas de aço magnético e enrolamentos alojados longitudinalmente.

Existem dois tipos de MIT, os quais são diferenciados pelo tipo do enrolamento do rotor. O rotor gaiola de esquilo é constituído de barras condutoras paralelas, sobre uma superfície cilíndrica, em cujos extremos são curto circuitadas por dois aros condutores. O segundo tipo é denominado motor de indução de rotor bobinado. Este rotor possui enrolamentos trifásicos, cujos terminais desses enrolamentos possuem anéis condutores que ligam ao reostato trifásico de partida, por meio de escovas de carvão condutor.

Devido aos esforços térmicos, elétricos e mecânicos que ocorrem durante o funcionamento do motor podem surgir falhas mecânicas e elétricas. Uma falha pode ser definida como um desvio de uma propriedade característica do motor, o qual causará um certo nível de redução de desempenho (BARAKAT et al., 2011). O desvio pode ser causado por mudanças físicas permanentes ou temporárias no sistema.

De acordo com BONNETT; YUNG (2008), as porcentagens de falhas em MIT podem ser distribuídas em: rolamentos (69%), enrolamento do estator (21%), barra do rotor (7%) e o eixo (3%). A maneira para detectar estes problemas mecânicos e elétricos pode ser feita direta ou indiretamente por meio da leitura de uma das correntes elétricas nas fases de alimentação ou pela tensão elétrica, medidas de temperatura, monitoramento do campo eletromagnético ou por outros parâmetros (GHATE; DUDUL, 2010).

Sistemas para diagnosticar falhas em motores elétricos, principalmente em MIT, estão sendo pesquisados e desenvolvidos por profissionais da área acadêmica e da indústria. Os objetivos destes estudos são de interpretar precocemente a falha incipiente e definir um correto diagnóstico para que não ocorra uma manutenção não-programada e uma parada no processo produtivo. Prevenindo a ocorrência de falhas, pode-se também evitar conseqüências como aquecimento excessivo, desbalanceamento da corrente e da tensão, decaimento do torque médio, redução da eficiência e grandes perdas financeiras (NANDI; TOLIYAT; LI, 2005).

A crescente demanda por sistemas de manutenção preditivo automatizado e por sistemas de diagnóstico de falhas deve-se ao aumento do uso dos motores e necessidade de elevada confiabilidade. A expansão destes fatores é uma forma de garantir alta produtividade, com baixo custo de manutenção e sem precisar da análise de profissinais especializados. Ademais, métodos de monitoramento implementados em sistemas de diagnóstico de falhas apresentam baixas taxas de erro e reduzidas quantidades de falsos alarmes, o que aumenta a relevância do vínculo desses sistemas aos motores de indução em operação.

Existem diferentes técnicas de análise de sinais aplicadas à identificação de falhas

em motores, como por exemplo *Motor Current Signature Analysis* (MCSA). Esta é uma técnica que reconhece anomalias do motor pela análise espectral da corrente. Outras técnicas convencionais também são confiáveis, porém apresentam inconsistências, como a dificuldade de interpretar sinais que contêm ruídos, de mapear o comportamento não linear das máquinas (HAJI; TOLIYAT, 2001) e de tratar a limitação da precisão de um espectro devido a uma resolução fixa (PAYNE; BALL; GU, 2002).

Uma das relevantes soluções alternativas para automatizar sistemas de monitoramento em motores elétricos são os sistemas inteligentes. Uma das principais vantagens no uso de sistemas inteligentes é sua implementação com baixa complexidade computacional, pois é capaz de determinar o tipo de uma falha num MIT sem necessitar de modelos matemáticos sofisticados. Ademais, a introdução de algoritmos de sistemas inteligentes é um passo em direção a uma maior flexibilidade, pois não são dependentes de um modelo matemático, e tem a capacidade de aprendizado a partir da extração de conhecimentos sobre situações que envolvem o processo.

Recentemente, os sistemas de diagnóstico de falhas estão optando por métodos nãoinvasivos durante a aquisição dos dados, sendo que metodologias inovadoras estão sendo empregadas nas etapas de pré-processamento, processamento e classificação. Dentre estas etapas destacam-se também a aplicação dos sistemas inteligentes: Redes Neurais Artificiais (RNAs), Lógica *Fuzzy* (LF), Algoritmos Genéticos (AGs) e sistemas inteligentes híbridos.

De fato, os sistemas inteligentes têm sido densamente aplicados na área de diagnóstico de falha e de monitoramento das condições dos motores, executando uma ou mais das seguintes tarefas:

- Reconhecimento de padrão e estimação de parâmetros;
- Classificação da falha e prognóstico;
- Previsão de falhas em estágios incipientes devido a anomalias de funcionamento;
- □ Filtragem dos transientes e ruídos do sinais;
- Previsão de operação anormal e localização de elemento defeituoso.

Dessa forma, neste trabalho motivou-se a implementação de diferentes topologias de redes neurais para atuarem na classificação de falhas do sistema de diagnóstico. O sistema de diagnóstico aqui proposto é subdividido nas seguintes etapas: processamento da corrente trifásica do motor, extração de características e classificação de falhas. Na etapa de processamento, a Transformada Wavelet (TW) é aplicada no sinal de corrente trifásica do estator, resultando nos coeficientes *wavelets*, os quais serão amostrados na etapa subsequente. A partir das amostras definidas, o procedimento de extração de características é executado por meio do cálculo de variáveis estatísticas. Os resultados obtidos nesta etapa são normalizados e repassados para as redes neurais, as quais são responsáveis em classificar a situação de funcionamento do motor.

A justificativa pela escolha das técnicas que compõem as etapas do sistema de diagnóstico serão explanadas na Seção 1.2.

1.2 Justificativas

As razões para o desenvolvimento da metodologia proposta ao sistema de diagnóstico devem-se, principalmente, aos artigos AWADALLAH; MORCOS (2003) e BELLINI et al. (2008a) que contêm revisões de trabalhos publicados sobre as técnicas de diagnóstico para máquinas de indução e sobre as principais falhas mecânicas e elétricas. Nestes artigos há a descrição de vantagens e desvantagens de métodos convencionais na análise de sinais, como também destacam a importância dos sistemas inteligentes na identificação e classificação de falhas em MIT. Mediante isto, surge a proposta de usar as RNAs como ferramenta para identificar falhas de um motor de indução de baixa potência e classificar a gravidade delas.

Outros artigos também contribuiram na definição dos procedimentos da fase de processamento do sinal. A TW foi escolhida por realizar análise tempo-frequência, que consiste da representação do tempo, da frequência e da amplitude de um sinal (BELLINI et al., 2008a). Outrossim, a propriedade de análise de multiresolução executada pela TW é responsável por realçar eventos transitórios no sinal, o que qualifica a TW como uma ferramenta computacional capaz de identificar quesitos que representam falhas num sinal elétrico.

No artigo SADEGHIAN; YE; WU (2009), o autor utiliza da Wavelet Packet Decomposition (WPD) junto com uma rede neural Multilayer Perceptron (MLP) para compor o algoritmo de detecção online de barras quebradas no rotor. Os dados analisados pelo algoritmo foram extraídos da corrente do estator, que após a TW, formaram os vetores característicos compostos por diferentes coeficientes wavelets de vários níveis da transformada e pelo escorregamento do motor. Em ASFANI et al. (2012), a combinação da Discrete Wavelet Transform (DWT) com as redes neurais focaram na investigação dos pontos de início e de fim do curto-circuito temporário do enrolamento do estator. Já o artigo BARAKAT et al. (2011) introduz o conceito da rede neural modular por meio da topologia Self Adaptive Growing Neural Network (SAGNN), que apoiada pela DWT classificou falhas de elementos rolantes pertencentes à um sistema de maquinário. É importante destacar neste artigo que a seleção de características foi obtida pelo cálculo da variância e kurtosis sob cada sub-sinal gerado após a execução da DWT.

Desta forma, outros estudos também utilizaram do cálculo de variáveis estatísticas para extrair características relevantes dos sinais, tais como média, variância, *skewness*, *kurtosis* e outras. Nos artigos GHATE; DUDUL (2011) e GHATE; DUDUL (2010), variáveis estatísticas foram geradas a partir dos sinais da corrente do estator para identificar curtocircuito no enrolamento do estator e excentricidade dinâmica do rotor. Ademais, ZAREI (2012) também utiliza do cálculo de variáveis matemáticas para selecionar características dos sinais de vibração. Neste caso, buscou-se investigar falhas nas pistas interna e externa dos rolamento de um MIT.

Baseando-se na literatura supracitada, almeja-se na metodologia desta tese explorar características significativas dentre os coeficientes *wavelets*, a partir do cálculo de variáveis estatísticas, a fim de averiguar falhas nas barras do rotor e em curto-circuitos no enrolamento dos estator. Além deste objetivo, outros estão descritos na próxima Seção (1.3).

1.3 Objetivos e Contribuições

Os objetivos gerais desta tese de doutorado consistem da pesquisa, projeto, implementação e validação de uma metodologia para identificar diferentes tipos de falhas num MIT. Nesta perspectiva, as contribuições desta tese podem ser pautadas nos seguintes itens:

- Desenvolver um sistema computacional capaz de diagnosticar falhas no estator e rotor de um MIT a partir de dados extraídos da corrente trifásica do estator. As falhas a serem examinadas estão na barra do rotor e nos enrolamentos do estator;
- Demonstrar que a TW é uma técnica capaz de realizar a etapa de processamento dos sinais, e compor o sistema de diagnóstico;
- Provar que a junção de variáveis estatísticas caracterizam as amostras dos sinais fidedignamente;
- Identificar as topologias de Rede Neural Artificial (RNA) que melhor se adequam na classificação das falhas definidas nesta tese;
- Analisar se a metodologia proposta ao sistema de diagnóstico é apto a identificar falhas presentes em motores, cujo acionamento se dá por um inversor de frequência.
- □ Formular e implementar um sistema inteligente que identifique características incipientes de falhas em motores elétricos, visando a sua aplicabilidade em sistemas de monitoramento *off-line*.

1.4 Organização da Tese

A tese está organizada em cinco capítulos, os quais apresentam, sequencialmente, a revisão bibliográfica, a metodologia utilizada na implementação do sistema computacional, os resultados e as conclusões geradas pelo sistema proposto. Assim, no Capítulo 1 foi introduzido o tema desta tese, bem como a relevância e as justificativas para o desenvolvimento do sistema de diagnóstico de falhas.

O Capítulo 2 descreve os métodos convencionais empregados na identificação de falhas em MIT, além de detalhar importantes trabalhos que utilizaram os métodos dos sistemas inteligentes para o mesmo fim. Ademais, é descrito a atuação das transformadas *wavelets* na análise de sinais provindos de motores elétricos.

O Capítulo 3 destina-se ao relato dos aspectos gerais e peculiares dos métodos que compõem o sistema de diagnóstico. Os procedimentos experimentais e a estrutura física que formam a bancada do laboratório são relatados no apêndice A.

No Capítulo 4, fornecem-se os resultados experimentais do sistema de identificação de falhas, que são as classificações das falhas relacionadas a quebra nas barras do rotor e a curto-circuitos nos enrolamentos do estator.

Por fim, o Capítulo 5 apresenta as discussões e as conclusões obtidas por esta tese, além das diretivas para a propagação de trabalhos futuros.

Capítulo 2

Estado da Arte

2.1 Introdução

A preocupação das indústrias e das universidades com técnicas preditivas que avaliam o desempenho e as condições dos motores se tornaram uma realidade, devido aos anseios de alta confiabilidade no funcionamento dos motores. Técnicas convencionais são analisadas e aplicadas aos sistemas de diagnóstico, cujos objetivos, para a indústria, são identificar falhas incipientes para evitar paradas não-programadas e garantir redução de custos; e, para as universidades, aprimorar funcionalmente os modelos dos sistemas eletromecânicos complexos e não-lineares que o motor de indução representa. Entretanto, novas metodologias estão sendo propostas para aperfeiçoar as técnicas convencionais e, consequentemente, criar eficientes sistemas de diagnóstico capazes de detectar as falhas incipientes.

A Seção 2.2 discorrerá sobre os métodos convencionais utilizados na identificação de falhas em motores elétricos. Na Seção 2.3, são apresentados as abordagens dos sistemas inteligentes mais relevantes usados em processos de diagnósticos de falhas em MIT, e na sequência, a Seção 2.4 destaca a atuação da transformada *Wavelet* no processamento de sinais provenientes de máquinas elétricas.

2.2 Métodos Convencionais Utilizados na Identificação de Falhas

Técnicas de monitoramento de condição de operação são processos responsáveis em programar a manutenção planejada de equipamentos, de acordo com os dados e estados atuais dos dispositivos. Tais técnicas necessitam da estrutura da planta industrial, onde se encontram os dispositivos, para ser integrado aos procedimentos responsáveis pela aquisição de dados e pela previsão de diagnóstico, pois essas técnicas visam o mínimo tempo de parada do setor produtivo (DAVIES, 1998). Ademais, as técnicas de monitoramento de condição analisam algumas variáveis da máquina, tais como tensão, corrente, velocidade, temperatura e vibração.

Dentre as técnicas convencionais de monitoramento de condição aplicadas aos estudos sobre MIT, destacam-se a corrente de sequência negativa, vetor de Park, *Extended Park's Vector Approach* (EPVA), MCSA e *Support Vector Machine* (SVM).

2.2.1 Corrente de Sequência Negativa

O método das componentes simétricas analisam faltas assimétricas em sistemas de transmissão, como curtos-circuitos, impedância entre linhas, impedância de uma ou duas linhas para a terra, ou condutores abertos (STEVENSON JR., 1986). As componentes simétricas são usadas para calcular as condições de desbalanço de um sistema trifásico, sendo este transformado em sistemas trifásicos equilibrados para diminuir a complexidade na análise do sistema. As componentes simétricas são denominadas de componentes de sequência positiva, negativa e zero.

Nos MIT as correntes das três sequências geralmente são diferentes. Os valores da sequência positiva são aqueles presentes durante condições trifásicas equilibradas, ou seja, o fluxo produzido pela corrente desta sequência é estacionário em relação ao estator. A corrente de sequência negativa, com uma rotação de fase oposta à direção da sequência positiva, gera uma tensão que induz uma corrente substancial no rotor. Assim, as grandezas da sequência negativa medem a quantidade de desbalanço existente no sistema de potência.

Quando apenas a corrente de sequência zero circula no enrolamento do estator, a corrente e a Força Magnetomotriz (FMM) das três fases atingem um valor máximo no mesmo instante. O fluxo resultante da soma das FMM é muito pequeno, porém faz com que exista reatância de sequência zero e gere um fluxo no entreferro. Logo, as grandezas de sequência negativa e zero somente estão presentes com valores substanciais em situações de faltas que geram desequilíbrio no sistema de potência.

As sequências negativas, positivas e zero são usadas para transformar um conjunto genérico de fasores em vetores balanceados. Especificamente, três correntes de linha $(\bar{I}_a), (\bar{I}_b) \in (\bar{I}_c)$ são transformadas em três vetores balanceados conhecidos como sequência positiva (\bar{I}_p) , sequência negativa (\bar{I}_n) e sequência zero (\bar{I}_0) , isto é:

$$\begin{bmatrix} \bar{I}_p \\ \bar{I}_n \\ \bar{I}_0 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & \alpha & \alpha^2 \\ 1 & \alpha^2 & \alpha \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} \bar{I}_a \\ \bar{I}_b \\ \bar{I}_c \end{bmatrix}$$
(2.1)

onde $\alpha = e^{j\theta}, \theta = \frac{2\pi}{3}$.

Em KOHLER; SOTTILE; TRUTT (1992), os sinais de tensão e corrente são adquiridos com a finalidade de calcular a sequência negativa. Visto que o valor dessa sequência é constante num motor em condições normais, sugere-se então que um alarme seja disparado se o desvio da sequência for superior a 6%, levando-se então ao desligamento da máquina antes que aumentem as falhas detectadas.

Muitos trabalhos reconhecem a corrente de sequência negativa como procedimento de diagnóstico que distingue diferentes fenômenos dos motores (KOHLER; SOTTILE; TRUTT, 1992; BELLINI et al., 2000). Dentre esses fenômenos destacam-se a identificação de curto-circuitos nos enrolamentos do estator, principalmente quando estes ocorrem em poucas espiras; tensões desbalanceadas; saturação; assimetrias nos enrolamentos e excentricidades.

2.2.2 Vetor de Park e EPVA

O vetor de Park é outro método usado na detecção de falhas no enrolamento do estator em MIT (CARDOSO; CRUZ; FONSECA, 1999). As componentes de corrente do vetor de Park são representadas por i_d (direta) e i_q (quadratura). Essas componentes são obtidas pelas variáveis que representam as correntes das três fases do motor ($i_a, i_b \in i_c$), isto é:

$$i_d = \sqrt{\frac{2}{3}}i_a - \frac{1}{\sqrt{6}}i_b - \frac{1}{\sqrt{6}}i_c \tag{2.2}$$

$$i_q = \frac{1}{\sqrt{2}}i_b - \frac{1}{\sqrt{2}}i_c \tag{2.3}$$

Em condições ideais, ou seja, o motor operando em regime permanente e transitório, as componentes i_d e i_q são calculadas segundo as equações:

$$i_d = \left(\frac{\sqrt{6}}{2}\right) i_M \sin\left(\omega t\right) \tag{2.4}$$

$$i_q = \left(\frac{\sqrt{6}}{2}\right) i_M \sin\left(\omega t - \frac{\pi}{2}\right)$$
(2.5)

sendo que i_M é o valor máximo da corrente de fase do fornecimento, ω é a freqüência angular do fornecimento e t é a variável tempo.

A corrente de um motor saudável pela abordagem do vetor de Park é esboçada pela forma circular e centrada na origem do eixo de coordenadas, que é formado pelas componentes $i_d e i_q$. Sob condições de falta, este padrão é desviado do centro de acordo com a falta associada. As Figuras 2.1 e 2.2 esboçam, respectivamente, a representação padrão da corrente do estator de um motor saudável e a presença de falhas nas pistas interna e externa de um rolamento segundo o artigo de ONEL; BENBOUZID (2008).

A técnica EPVA é baseada na abordagem do vetor de Park, porém ela fornece uma maior percepção da gravidade dos defeitos nos motores (BARENDSE et al., 2009). Em



Figura 2.1: Representação do padrão da corrente em situações ideais na transformada do vetor de Park. (Fonte: Extraído do artigo CRUZ; CARDOSO (2001))



Figura 2.2: Comparação da trajetória das componentes $i_d \in i_q$ da corrente do estator em duas situações de falhas. (Fonte: Extraído do artigo ONEL; BENBOUZID (2008))

suma, o vetor de Park identifica a falha examinando a forma da trajetória produzida enquanto que EPVA examina o conteúdo espectral da magnitude do vetor de Park.

De forma geral, os métodos convencionais para monitorar as condições de uma máquina de indução utilizam das componentes espectrais da corrente do estator no regime permanente. Mesmo que as máquinas não operem sob as completas condições de regime permanente, as técnicas vetor de Park (CARDOSO; CRUZ; FONSECA, 1999) e EPVA (CRUZ; CARDOSO, 2001; BARENDSE et al., 2009) são capazes de detectar curtos-circuitos nos enrolamentos do estator, além de quebras nas barras do rotor e rachaduras nos anéis finais (KARAMI; POSHTAN; POSHTAN, 2010; PEZZANI et al., 2010).

2.2.3 Análise de Padrões da Corrente do Motor

O método de detecção de falhas, chamado de Análise de Padrões da Corrente do Motor (MCSA), é capaz de verificar assimetrias do rotor pela análise espectral da corrente do estator. As anomalias são percebidas na corrente do estator, o que torna possível estimar as condições reais de operação do motor, não necessitando de uma parada para inspeção ou de um acesso à parte interna da máquina.

Assimetrias de rotor são equivalentes à adição de componentes espectrais na corrente do estator denominadas bandas laterais. A trinca ou quebra de uma barra de rotor ou do segmento de anel de curto circuito altera o valor da corrente que circula nas bandas laterais, influenciando no espectro de freqüências das correntes e/ou tensões de estator, para o caso de inversores com controle de conjugado. Estas componentes espectrais adicionais distam da freqüência fundamental de alimentação em $(1\pm 2s)f$, onde s é o escorregamento e f é a freqüência fundamental. Além disso, a componente do lado esquerdo é diretamente originada pelo efeito destrutivo na barra, enquanto a componente do lado direito é causada pelo *ripple* na velocidade (THOMSON; FENGER, 2001). Por meio de uma transformada rápida de Fourier (*Fast Fourier Transform* (FFT)) é possível obter um gráfico contendo o espectro de freqüências das correntes do motor.

O enrolamento do estator assimétrico e faltoso pode produzir harmônicas espaciais em qualquer onda no campo do entreferro. Entretanto, todas estas harmônicas variam numa única frequência, ou seja, a frequência da fonte de tensão senoidal da rede. As harmônicas do estator induzem correntes na gaiola do rotor e que refletem de volta ao estator, como novas harmônicas do campo do entreferro.

PENMAN et al. (1994) detectaram falhas entre bobinas no enrolamento de um estator através da análise da componente de fluxo axial da máquina utilizando uma grande bobina enrolada de forma concêntrica em torno do eixo da máquina. Os componentes de frequência para detectar a componente de fluxo axial são dadas por:

$$f_t = f\left[k \pm \left(\frac{n}{p}\right)(1-s)\right] \tag{2.6}$$

em que f é a frequência da fonte da rede elétrica, p é o número de pares de pólos, s é o escorregamento, k = 1, 3 e n = 1, 2, 3, ..., (2p - 1).

As harmônicas do campo do entreferro induzidas na corrente do estator apresentam-se na mesma frequência que uma harmônica produzida num motor saudável. Logo, uma falha no enrolamento do estator pode mudar a amplitude das harmônicas da corrente do estator, mas não produz nenhuma nova frequência no espectro da corrente. De acordo com esta análise, pode-se ser difícil detectar falhas do estator pelo espectro da corrente apenas pelo método MCSA (JOKSIMOVIC; PENMAN, 2000).

A presença de excentricidades estáticas ou dinâmicas também pode ser detectada pela técnica MCSA. As frequências específicas relacionadas à esta falta são dadas por (NANDI;

TOLIYAT; LI, 2005):

$$f_{ec} = \left[\left(kR \pm n_d \right) \frac{(1-s)}{p} \pm v \right] f \tag{2.7}$$

em que k é um inteiro positivo, R é o número das barras do rotor, p é o número de pares de pólos, n_d é a ordem da excentricidade (sendo $n_d=0$ para excentricidade estática e $n_d=1,2,3,...$ para a dinâmica), s é o escorregamento do motor, v é a ordem das harmônicas que estão presentes na fonte de alimentação do motor, e f é a frequência fundamental de alimentação.

Dentre as falhas citadas, a quebra na barra do rotor e as rachaduras nos anéis finais compartilham de 5% a 10% das falhas em máquinas de indução (BELLINI et al., 2008a). A MCSA também apresentou bons resultados para falhas em rotores, segundo os artigos AYHAN et al. (2008), CONCARI; FRANCESCHINI; TASSONI (2008), PUCHE-PANADERO et al. (2009), RIERA-GUASP et al. (2010) e CONCARI; FRANCESCHINI; TASSONI (2010).

2.2.4 Support Vector Machine

SVM é um algoritmo que implementa uma técnica de aprendizado de máquinas embasada na teoria do aprendizado estatístico. As técnicas de aprendizado de máquina empregam um princípio de inferência denominado indução, o qual obtém conclusões genéricas a partir de um conjunto particular de exemplos. O aprendizado indutivo pode ser caracterizado pelo tipo supervisionado ou não-supervisionado.

O aprendizado supervisionado necessita do conjunto entrada e saída desejada para que se possa extrair a representação do conhecimento. Por conseguinte, a representação gerada será capaz de produzir saídas corretas para novas entradas que não foram apresentadas previamente. Já o aprendizado não-supervisionado não utiliza da saída desejada do aprendizado anterior, pois sua técnica é aprender a agrupar os dados das entradas segundo uma medida de qualidade.

SVM tem sido empregado com sucesso em sistemas destinados à identificação de padrões, o que caracteriza seu bom desempenho no diagnóstico de falhas em MIT. Dentre os estudos publicados, citam-se o algoritmo do SVM destinados à detecção de curtoscircuitos nos enrolamentos do estator (RADHIKA et al., 2010), à identificação de quebras de barras no rotor (MATIC et al., 2012) e ao reconhecimento de falhas em rolamentos (KANKAR; SHARMA; HARSHA, 2011). SVM também foi aplicado para diagnosticar, duplamente, falhas no estator e quebras na barra do rotor em KARAKOSE; AYDIN; AKIN (2010). Na primeira fase deste sistema, características são extraídas do sinal de corrente do motor para estimar a gravidade da falta. Na segunda fase, diferentes algoritmos de diagnóstico (rede MLP, SVM, Algoritmo Genético (AG), Artificial Immune System (AIS), e Fuzzy Artificial Immune System (FAIS)) são combinados ao choquet fuzzy
integral para diagnosticar com exatidão as falhas, sendo o SVM o algoritmo de diagnóstico que obteve melhores resultados dentre os demais (KARAKOSE; AYDIN; AKIN, 2010).

2.3 Abordagens Inteligentes Usadas na Identificação de Falhas

Inteligência Artificial (IA) é definida por sistemas computacionais que resolvem problemas usando metodologias análogas às utilizadas pelo funcionamento do cérebro humano, ou pelas operações genéticas que ocorrem com as células, ou pelas ações do sistema imunológico humano, ou pela organização social realizada por alguns seres vivos, ou pelos diversos níveis de definições qualitativas utilizadas pelo ser humano. Dentre os sistemas inteligentes apresentados pela literatura destacam-se as RNAs, os AGs, o sistema imunológico artificial, os algoritmos de otimização baseado na Inteligência de Enxame e a LF.

Uma das principais vantagens no uso de sistemas inteligentes é sua implementação com baixa complexidade computacional, pois é capaz de determinar o tipo de uma falha num MIT sem necessitar de modelos matemáticos complexos. Ademais, as RNAs e a LF são as principais técnicas implementadas nos sistemas propostos para o reconhecimento de padrões, o que as também caracterizam como eficazes na identificação de falhas de MIT ao analisarem os sinais oriundos dos motores elétricos. Segundo BONNETT; YUNG (2008), as porcentagens de falhas em MIT podem ser distribuídas em: rolamentos (69%), enrolamento do estator (21%), barra do rotor (7%) e o eixo (3%). Dessa forma, as seguintes subseções relatam alguns trabalhos que implementaram sistemas inteligentes na resolução das principais falhas apresentadas em MIT.

2.3.1 Aplicação das RNAs na Resolução de Falhas em MIT

A RNA é uma das abordagens da inteligência computacional capaz de agregar e agrupar dados, e cuja estrutura é formada por neurônios artificiais (unidades processadoras) interligados por várias conexões. Os neurônios são organizados em camadas, as quais são denominadas de camada neural escondida ou camada neural de saída. As conexões que ligam os neurônios de uma camada à outra possuem um valor (peso sináptico) que vão se ajustando durante a fase de treinamento da rede. A finalidade destes ajustes é para que o conjunto de entradas produza um conjunto de saídas desejadas.

As redes neurais se diferenciam por sua arquitetura e pelo modo de treinamento. Ou seja, pelas diferentes quantidades de camadas neurais e pela fase de treinamento ser supervisionado ou não-supervisionado. A Figura 2.3 ilustra uma rede neural *perceptron* multicamada (MLP). As redes MLP possuem uma arquitetura *feedforward* e são constituídas por pelo menos uma camada neural escondida e uma camada neural de saída. O



processo de treinamento da rede é supervisionado e, geralmente, o algoritmo de aprendizado definido é o *backpropagation*, baseado na técnica do gradiente descendente.

Figura 2.3: Estrutura de uma rede neural MLP.

As RNAs são capazes de aprender com a apresentação de dados durante a fase de treinamento e, pelo conhecimento adquirido, classificar dados não apresentados à rede durante a fase de testes. Logo, as redes neurais conseguem aprender as características dos sinais e diagnosticar falhas presentes nos motores. Em CHOW; YEE (1991) destaca-se uma das primeiras pesquisas na atribuição das RNAs para detecção de falhas incipientes em motores de indução do tipo gaiola de esquilo.

Em relação as falhas no estator, o curto-circuito no enrolamento é uma das falhas mais presentes nas ocorrências de motores industriais e domésticos. As falhas de curtocircuito podem ser detectadas e classificadas pelas redes neurais de acordo com as seguintes topologias: MLP (GHATE; DUDUL, 2010; TALLAM; HABETLER; HARLEY, 2003; BOUZID et al., 2008; GHATE; DUDUL, 2009; LEITE et al., 2009; ASFANI et al., 2012); RBF (*Radial Base Function*) (WU; CHOW, 2004; GHATE; DUDUL, 2011); Hebbian (MARTINS; PIRES; PIRES, 2007); *Self-Organizing Maps* (SOM) (GHATE; DUDUL, 2010); *Elman Neural Network* (ELMN) e *Time Lagged Feedforward Network* (TLFN) (LEITE et al., 2009).

Em GHATE; DUDUL (2010) define um classificador baseado nas redes neurais MLP e SOM, cujo objetivo é detectar curto-circuitos no enrolamento do estator, excentricidade dinâmica do rotor, ambas as falhas simultaneamente ou motor saudável. Os dados de entrada para as redes neurais foram obtidos a partir dos sinais elétricos da corrente do estator estando no domínio do tempo. As três fases da corrente alternada do motor de indução são lidas e amostradas para o cálculo de parâmetros estatísticos, tais como o desvio padrão, valores de máximo e de mínimo, coeficiente de *skewness* e o coeficiente de *kurtosis*. A dimensionalidade destes parâmetros foi reduzida aplicando o método de Análise de Componentes Principais (*Principal Component Analysis* (PCA)), o que gerou outras topologias de RNAs, pois a quantidade de neurônios foi reduzida tanto para a MLP (de 13 para 5 neurônios na camada escondida) quanto para a rede SOM (de 13 para 7 neurônios). Assim, foram testadas 4 topologias de RNAs (MLP, MLP reduzida, SOM e SOM reduzida) com diversas taxas de aprendizado e com várias funções de aprendizado. Em uma análise comparativa, a rede MLP reduzida atuou como um eficaz classificador de diagnóstico de faltas, obtendo-se 98.25% de acertos para o conjunto de dados destinados ao treinamento da rede e 96.22% para o conjunto de validação (dados não usados no treinamento).

A respeito de falhas no rotor, principalmente para quebras nas barras do rotor, implementou-se diferentes arquiteturas e topologias de redes neurais para identificar tais falhas, como: MLP (ARABACI; BILGIN, 2009; AYHAN; CHOW; SONG, 2006; PAWLAK; KOWALSKI, 2010; BOUZID et al., 2010; SADEGHIAN; YE; WU, 2009; SUETAKE, 2012), SOM (CUPERTINO et al., 2005), *General Regression Neural Networks* (GRNN) (KAMINSKI; KOWALSKI; ORLOWSKA-KOWALSKA, 2010), Kohonen (VAS, 1999).

Em SU; CHONG (2007), uma rede neural MLP precedida da transformada de Fourier (STFT) utilizam do espectro de sinais de vibração de motores saudáveis a fim de treinar a rede. Uma vez que o modelo é estabelecido, sinais de vibração obtidos sob condições de falhas serão aplicados ao sistema para gerar uma análise residual e, posteriormente, calcular o nível da falha. O indicador do nível da falha está baseado na distorção entre o sinal de vibração em condições saudáveis e o resultado do residual na presença de falhas. Neste estudo, as falhas analisadas foram divididas entre quatro situações diferentes de barras quebradas e excentricidade. Para todas as falhas, os resíduos de vibração resultantes sobressaiam à linha de base que limitava a condição saudável para um motor, além de que a magnitude do residual aumentava nitidamente com a severidade das falhas.

Outro exemplo é o sistema formado pela transformada WPD e a rede MLP, que pode identificar falhas nas barras do rotor por intermédio das frequências do escorregamento e da corrente do estator (SADEGHIAN; YE; WU, 2009). Este sistema foi dividido em quatro passos: aquisição de dados, pré-processamento, detecção de falta e pós-processamento. No pré-processamento, o sinal da corrente do estator é transformado para o domínio tempo-frequência pela WPD e que, conseqüentemente, gerou os coeficientes característicos. Esses coeficientes possuem resoluções de diferentes frequências, e junto com a frequência de escorregamento, treinaram a rede neural. A etapa do pós-processamento armazenou os diferentes tipos de faltas encontrados pela rede num banco de dados para, posteriormente, ser usado no aperfeiçoamento do algoritmo de detecção de falhas.

Vários trabalhos aplicaram redes neurais em sistemas de diagnóstico de falhas nos rolamentos, como em WU; CHOW (2004), onde é apresentado uma rede neural RBF, com auto-ajuste no número de neurônios na camada escondida, segundo a metodologia da rede SOM. O espectro da corrente e os sinais de vibração do motor forneceram os dados de entrada para as redes neurais. Em relação às falhas, foram induzidos níveis diferentes de desbalanceamento elétrico na alimentação do motor e três extensões de relaxamento no parafuso responsável pela fixação do motor na bancada, provocando-se, conseqüentemente, vibrações de natureza elétrica e mecânica no núcleo do rotor. Os resultados mostraram 100% de acerto na identificação de falhas mecânicas durante os testes da rede, enquanto que as falhas elétricas obtiveram 85.7%, ao passo que o motor sob condições normais obteve 96.0%.

A rede neural do tipo MLP também foi implementada para identificar falhas em rolamentos, conforme formulações descritas em KANKAR; SHARMA; HARSHA (2011), LI et al. (2000), SAMANTA; NATARAJ (2009), YANG (2010), CASTEJóN; LARA; GARCÍA-PRADA (2010) e MAHAMAD; HIYAMA (2010). Entretanto, em alguns sistemas, a rede MLP aparece integrada a diferentes técnicas, como o *Particle Swarm Optimization* (PSO) (SAMANTA; NATARAJ, 2009) e o SVM (KANKAR; SHARMA; HARSHA, 2011). Nestes sistemas, um pré-processamento dos sinais se fez necessário para compilar as entradas da rede neural, tais como aqueles baseados em métodos estatísticos (KANKAR; SHARMA; HARSHA, 2011), analisador biespectral baseado em Hilbert (YANG, 2010) e *Multiresolution analysis* (MRA) (CASTEJóN; LARA; GARCÍA-PRADA, 2010). Além da rede neural MLP, os resultados gerados pelas redes neurais de tipo *Elman*, RBF e pelo sistema neuro-*fuzzy* (ANFIS) foram analisados e comparados em MAHAMAD; HIYAMA (2010).

Sinais de vibração, tensão e corrente do estator são monitorados para detectar falhas relacionadas à excentricidade. Na literatura, estes sinais foram também analisados por sistemas inteligentes, tais como a rede MLP (GHATE; DUDUL, 2009; SU; CHONG, 2007; HUANG; HABETLER; HARLEY, 2007) e a rede *Radial Basis Function* (RBF) aliada à rede MLP (RBF-MLP) (GHATE; DUDUL, 2011).

Em GHATE; DUDUL (2011), alguns parâmetros estatísticos foram calculados a partir da corrente do estator, os quais foram selecionados pela técnica da PCA, e encaminhados à rede RBF-MLP. Ou seja, a primeira camada neural dessa rede assemelha-se à primeira camada de uma rede RBF, que contém a função Gausiana como função de aprendizado, composta por regras competitivas e métricas adequadas para se obter convergência para um mínimo local. Da segunda até a última camada é a representação da rede MLP, que foi anexada à camada da RBF, com a função de otimizar a topologia da rede proposta. A rede neural em cascata RBF-MLP notificou satisfatoriamente as falhas dos tipos excentricidade no rotor e curto-circuito entre os enrolamentos do estator.

2.3.2 Aplicação da LF na Resolução de Falhas em MITs

Dentre os métodos da inteligência artificial, a LF é amplamente utilizada em sistemas para detectar anomalias nos enrolamentos do estator (RODRIGUEZ; ARKKIO, 2008; ZIDANI et al., 2003; MINI; SETTY; USHAKUMARI, 2010; KUMAR et al., 2010; KARAKOSE; AYDIN; AKIN, 2010). A LF surgiu como uma forma de representar a imprecisão em termos linguísticos inerente a um processo, bem como de expressar o conhecimento humano de uma forma mais natural (ZADEH, 1965). As variáveis que representam as condições do motor são convertidas em conjuntos fuzzy, de modo que, posteriormente, possam ser analisados pelo conjunto de regras do sistema *fuzzy*, as quais foram formuladas por peritos desse processo (Figura 2.4). O conhecimento armazenado nestes sistemas faz com que seja possível tomar decisões que requerem informações qualitativas do processo e, consequentemente, é capaz de gerar resultados com altos percentuais de precisão.



Figura 2.4: Diagrama esquemático de um sistema fuzzy.

A lógica fuzzy, em MINI; SETTY; USHAKUMARI (2010), é aplicada para diagnosticar as condições do estator de um motor de indução e as condições de um circuito aberto numa das fases, a partir da amplitude da corrente do estator. As variáveis de entrada são as três fases da corrente (I_a, I_b, I_c) , interpretadas como variáveis linguísticas $T(Q)=\{zero,$ pequeno, médio, grande $\}$, sendo $Q=I_a, I_b, I_c$. A variável de saída é o termo CM, que representa as condições do motor, a qual foi também definida como variável linguística $T(CM)=\{bom, danificado, seriamente danificado, circuito aberto_A, circuito aberto_B,$ $circuito aberto_C\}$. O sistema de decisão fuzzy obteve exatidão em seu diagnóstico.

Qualquer tipo de falha no enrolamento do estator pode levar à parada do motor, o que seria inaceitável em algumas aplicações. Um motor de indução com mais fases foi uma solução proposta por KIANINEZHAD et al. (2008) para garantir confiabilidade e operação contínua do sistema, caso uma das fases de um motor trifásico falhe. Adicionalmente, algoritmos de controle formados pela lógica *fuzzy* e pelo *sliding-mode* foram também usados para obter, com alta precisão, o funcionamento de uma máquina de indução de seis fases em modo saudável ou não (FNAIECH et al., 2010).

Em KARAKOSE; AYDIN; AKIN (2010), o autor apresenta *choquet fuzzy integral* para diagnosticar falhas no estator e quebras na barra do rotor frente às duas fases de processamento que dividiu o sistema. Na primeira fase, características são extraídas do sinal de corrente do motor para estimar a gravidade da falta. Na segunda fase, diferentes algoritmos de diagnóstico (rede MLP, SVM, AG, AIS, e FAIS) são combinados ao *choquet fuzzy integral* para diagnosticar com exatidão as falhas do motor, sendo o SVM o algoritmo de diagnóstico que obteve melhores resultados dentre os demais.

Além das redes neurais, a lógica *fuzzy* tem também atuado tanto na detecção de falha (ZOUZOU et al., 2009) quanto na exatidão e quantificação do índice de falha dos rotores

(KARAKOSE; AYDIN; AKIN, 2010; RAZIK; CORREA; SILVA, 2009). Em RAZIK; CORREA; SILVA (2009) é descrita uma metodologia constituída pela transformada Concordia, AG e um sistema baseado na lógica *fuzzy*. O primeiro é responsável pela filtragem e síntese das três correntes de linha do estator; o AG busca a falha no espectro de frequência; e o nível da gravidade da falha é definido pela abordagem *fuzzy*. Este sistema foi capaz de informar ao operador da máquina, por meio de indicadores luminosos, sobre o estado da mesma, o qual poderia ser classificado como saudável, falha incipiente no rotor, ou presença de uma barra quebrada no rotor. Tais estados foram notificados e testados ao operar o motor sob 50%, 75% ou 100% de sua carga nominal.

A LF aliada à entropia da informação compôs um sistema em tempo-real de detecção de falhas simples ou compostas, sendo implementado em hardware num dispositivo FPGA (ROMERO-TRONCOSO et al., 2011). A análise da entropia da informação ofereceu referências quantitativas da informação inserida numa fase da corrente, e a inferência da LF, aplicada sob cada valor retornado da entropia, fez uma exata identificação da condição da falha simples ou múltipla, que poderia ser quebra na barra do rotor, desbalanceamento ou falhas nos rolamentos. O sistema gerou 100% de exatidão para motores saudáveis e com as três falhas juntas. Porém, a identificação das outras combinações de falhas (individuais e múltiplas) diminui a eficiência, mas os resultados ainda foram considerados satisfatórios.

Em YAN et al. (2010), espectros de energia extraídos pela transformada *Wavelet Packet* foram repassados ao algoritmo PCA, que selecionou características e encaminhou ao algoritmo da lógica *fuzzy*, responsável em unir dados que representam defeitos iniciantes nas esferas, nas pistas interna e externa do rolamento, com diâmetros de 7, 14 e 21 milímetros. A metodologia proposta foi eficiente para diagnosticar as falhas incipientes; porém, resultados mais promissores foram alcançados ao aumentar a estratificação dos padrões de falhas.

2.3.3 Arquiteturas Inteligentes Híbridas na Identificação de Falhas

Com objetivo de produzir metodologias mais eficazes, duas ou mais técnicas da inteligência artificial podem ser combinadas e implementadas num único sistema computacional, sendo intitulado por sistema híbrido avançado ou inteligente híbrido. Os sistemas híbridos avançados podem ser classificados de acordo com sua constituição, isto é, seqüencial, auxiliar ou incorporado. No sistema híbrido seqüencial, executa-se, primeiramente, a técnica de um subsistema e em seguida a técnica do outro. O sistema híbrido auxiliar também é formado por dois subsistemas, sendo que um deles tem a função de realizar uma tarefa auxiliar ao subsistema principal. Em D'ANGELO et al. (2011), falhas nos enrolamentos do estator foram analisadas por um sistema híbrido auxiliar mediante análise dos sinais da corrente do estator e da velocidade angular do rotor. Neste artigo, inicialmente, os dados foram processados pela clusterização *fuzzy*, cujos centros dos clusters foram determinados por uma rede neural do tipo Kohonen, seguido da execução do algoritmo Metropolis-Hastings.

Os sistemas neuro-fuzzy são geralmente técnicas ideais para definir um sistema híbrido incorporado, ou seja, não há como separar os procedimentos de cada subsistema. No sistema neuro-fuzzy a inferência fuzzy é implementada segundo a estrutura de uma rede neural, o que fornece o raciocínio heurístico do processo de detecção de falhas. Dentre os trabalhos publicados sob falhas em MIT, os sistemas neuro-fuzzy apresentam-se combinados à outras metodologias, como a árvore de classificação e regressão (CART) (TRAN et al., 2009) e o analisador threshold representado por uma curva empírica da velocidade-torque (TAN; HUO, 2005).

Os sistemas neuro-*fuzzy* são capazes de descrever as condições reais de falha no estator, tais como as abordagens formuladas em GOODE (1995a), GOODE (1995b), CAMINHAS; TAVARES; GOMIDE (1996), BALLAL et al. (2007) e TRAN et al. (2009); como tolerar efeitos e reações do motor na presença de barras quebradas no rotor por meio de um controlador neuro-*fuzzy* (UDDIN; WANG; HUANG, 2010).

Em relação à falhas em rolamentos, observou-se uma diferente atuação dos sistemas neuro-fuzzy em relação à diversidade de variáveis usadas como dados de entrada. Medidas de velocidade, torque e corrente foram os dados de entrada gerados pelo motor para os sistemas ANFIS e FALCON (*Fuzzy Adaptive Learning Control/Decision Network*) definido em ALTUG; TRUSSELL (1999); ruído, temperatura do mancal, temperatura do enrolamento, velocidade e corrente foram os dados de entrada para o sistema ANFIS apresentado em BALLAL et al. (2007); as três fases da corrente do estator, a velocidade e o torque da carga foram as variáveis de entrada para o sistema neuro-fuzzy descrito em ABU-RUB et al. (2010); e apenas os sinais de vibração foram usados pelos sistemas ANFIS desenvolvidos em MAHAMAD; HIYAMA (2010) e ZHANG et al. (2010), e pelo IFAM (*improved Fuzzy* ARTMAP) em XU et al. (2009).

2.3.4 Outras Técnicas de Sistemas Inteligentes

Inovadores métodos computacionais, que simulam o comportamento de seres vivos ou o funcionamento de orgãos do corpo humano, também foram aplicados na resolução de falhas de MIT. Como por exemplo, o algoritmo PSO (KENNEDY; EBERHART, 1995) que em RAZIK; CORREA; SILVA (2010) foi utilizado para explorar o espaço de busca e extrair os espectros de frequência, que representam falhas no rotor.

O algoritmo PSO é uma técnica de otimização que simula a habilidade de um indivíduo dentro de uma sociedade durante um processo de conhecimento. Em outras palavras, é um algoritmo que modela a exploração do espaço do problema por uma população de indivíduos, tal que suas buscas são influenciadas por bons resultados adquiridos pelos indivíduos dentro da população e por ele próprio (KENNEDY, 1997). A Figura 2.5 esboça as principais funções do algoritmo PSO. O princípio básico de operação do PSO assemelha-se ao comportamento do bando de pássaros, quando estes estão a procura de um alimento ou de um local de repouso.



Figura 2.5: Diagrama esquemático das funções do algoritmo PSO.

Em RAZIK; CORREA; SILVA (2010), o algoritmo PSO identificou frequências na corrente de linha do estator, que representavam uma barra quebrada no rotor, estando o escorregamento já no regime permanente e sob uma carga nominal de 75%. Durante os testes, observou-se que as partículas que não apresentavam bom desempenho desapareciam durante as iterações. Além disso, deduziu-se o bom desempenho do algoritmo PSO no caso em que o motor estivesse operando sob carga leve, pois nessa situação as correntes de linhas faltosas estariam muito próximas uma das outras, o que poderia confundir o processo de otimização. No entanto, o algoritmo PSO evitou soluções locais independentemente do tamanho do espaço de busca.

Recentemente, uma metodologia inspirada no sistema imunológico humano tem se tornado destaque na área da inteligência computacional, denominada de sistema imunológico artificial (CASTRO; TIMMIS, 2002; LAURENTYS; PALHARES; CAMINHAS, 2010). Em CHILENGUE; DENTE; BRANCO (2011), o sistema imunológico artificial foi aplicado na resolução de problemas de identificação de falhas no estator e no rotor. Com base na teoria subjacente a esta abordagem, um novo método de programação, chamado Programação de Seleção de Clones (CSP), foi proposto em GAN; CHOW; CHAU (2009a) para melhorar a eficácia da codificação de programas e dos mecanismos de busca. Já em GAN; ZHAO; CHOW (2009b), o CSP foi aplicado no classificador responsável pela detecção de falhas da máquina a partir dos sinais de vibração.

2.4 Transformada *Wavelet* em Sistemas de Diagnóstico de Falhas

A TW é a decomposição de um sinal entre uma versão deslocada e redimensionada da wavelet original (MERRY; STEINBUCH, 2005). Em outras palavras, a função wavelet, também denominada wavelet mãe ($\psi(t)$), é a base para a expansão de novas funções a partir de operações de dilação e translação de uma wavelet mãe. As operações de translação e dilação de $\psi(t)$ podem ser representadas por: $\psi(\frac{x-b}{a}), (a, b) \in \mathbb{R}^+ \times \mathbb{R}$, em que os valores de $a \in b$ devem ser selecionados convenientemente na criação da base, tal que: $a = 2^{-j} \in b = k \cdot 2^{-j}$, onde $k \in j$ são inteiros (VIDAKOVIC; MUELLER, 1991).

A DWT usa banco de filtros na análise de multiresolução, o que resulta na transformação do sinal para o plano tempo-frequência. Um banco de filtros é formado por filtros que separam um sinal em bandas de frequência, como mostra a Figura 2.6. O sinal discreto x(k) é filtrado pelos fitros L(z), o passa-baixa, e H(z), o passa-alta, os quais separam o conteúdo da frequência do sinal de entrada em bandas de frequência de tamanho igual. Ou seja, em cada saída dos filtros contém a metade do conteúdo da frequência, mas a quantidade de dados igual ao sinal x(k). Por isso, o operador downsampling por um fator de 2, representado por $\downarrow 2$, é aplicado nos dados de saída dos filtros, resultando nos coeficientes $y_h(k) e y_l(k)$ que contém à metade da quantidade de dados do sinal de entrada. Estes coeficientes são chamados de coeficientes wavelet e contém detalhes e aproximações do sinal x(k) que representam o conteúdo do sinal em várias bandas de frequência. Os coeficientes $y_h(k) e y_l(k)$ são obtidos pelas equações:

$$y_h(k) = D^{(n)}H(z)x(k)$$
 (2.8)

$$y_l(k) = D^{(n)}L(z)x(k)$$
 (2.9)

sendo $D^{(n)}$ a representação do operador downsampling.



Figura 2.6: Exemplo de um banco de filtro.

O banco de filtros pode ser expandido em vários níveis, dependendo da resolução desejada. A Figura 2.7 mostra dois níveis de um banco de filtro. As saídas dos filtros H(z) e L(z) do segundo nível aumenta a resolução do tempo e diminui o conteúdo da frequência, o que caracteriza o aumento do tamanho da janela usado na análise dos coeficientes *wavelet* (MERRY; STEINBUCH, 2005). Ademais, a saída do filtro passa-alta, após a passagem de cada nível, representa a metade com conteúdo de maior frequência do filtro passa-baixa do nível anterior. Esta metodologia, que está esboçada na Figura 2.7, é denominada DWT.



Figura 2.7: Expansão em dois níveis de um banco de filtro.

Em relação ao monitoramento e identificação de falhas em MIT, a análise da transformada Fourier provou ser uma eficiente ferramenta na análise de sinais estacionários (FILIPPETTI et al., 2000). A transformada de Fourier sendo executada sob a corrente do estator obtém as características de operação do motor, assumindo que o motor esteja operando em regime permanente e que a tensão de entrada seja ondas senoidais simétricas (SADEGHIAN; YE; WU, 2009). No entanto, dificuldades e limitações são encontradas quando a análise de Fourier é aplicada em sistemas *online* de diagnóstico de falhas em motores de indução, pois a corrente do estator é um sinal dinâmico variante no tempo, e cujas propriedades depende das condições operacionais do motor (BELLINI et al., 2008a; SADEGHIAN; YE; WU, 2009). Logo, a transformada de Fourier não oferece informações suficientes e exatas para o reconhecimento de falhas entre um motor em condições normais e um motor em condições faltosas para sinais não-estacionários.

Como alternativa à transformada de Fourier, diferentes trabalhos tem focado no uso da TW na identificação de falhas em motores elétricos, além de apresentar melhorias sob à análise Fourier (BARENDSE et al., 2009). Por exemplo, o tamanho da janela da TW é ajustado automaticamente para vários componentes da frequência: janelas estreitas para frequências altas e janelas largas para frequências mais baixas. A habilidade de localização no tempo e a análise de multiresolução também são propriedades da TW que a diferencia da transformada Fourier. Assim, diferentes métodos da transformada *wavelet* e diversos filtros *wavelet* estão sendo aplicadas em vários aspectos para a análise de falhas em motores. Em especial, destacam-se as falhas mecânicas como barras quebradas do rotor (YE; WU; SADEGHIAN, 2003; LEE; WANG; SONG, 2010; GARCIA-ESCUDERO et al., 2011; EBRAHIMI et al., 2012) e excentricidade (YE; WU; SADEGHIAN, 2003; LEE; WANG; SONG, 2010).

No artigo ASFANI et al. (2012) a investigação para detecção da falha no motor está direcionada ao fenômeno do transiente que ocorre durante os pontos de início e de fim da falta pela corrente do motor. A finalidade desta idéia é detectar curto-circuitos temporários que aparecem como falhas incipientes no enrolamento do estator. Para isso, foi combinado a DWT junto com as redes neurais MLP, ELMN e RBF. Em relação à segmentação do sinal, as amostras foram definidas por três períodos consecutivos do sinal de uma das fases da corrente. A transformada *Wavelet* Haar atuou no processamento de sinais, com o objetivo de separar os sinais de alta frequência da corrente elétrica e calcular os níveis de energia, os quais foram definidos como dados de entrada para as RNAs.

Todas as redes neurais foram constituídas pelas camada de entrada, camada neural escondida e camada neural de saída. A última camada foi formada por quatro neurônios representando as condições de operação do motor: normal (sem falhas), início da falha, durante a ocorrência da falha e fim da falha. As redes RBF e MLP obtiveram melhor desempenho na fase de treinamento, porém a rede ELMN foi mais eficiente na fase de teste, correspondendo a 100% de acertos em verdadeiros positivos, e 97,5% e 87,5% para as redes neurais MLP e RBF, respectivamente.

Os bons resultados do artigo ASFANI et al. (2012) deve-se à filtragem que a transformada *Wavelet* realizou sob o sinal, separando com clareza a faixa de alta frequência para o cálculo dos níveis de energia. Porém, a metodologia apresentada neste artigo não identificaria a localização do curto-circuito, ou seja, se o curto-circuito ocorresse entre bobinas da mesma fase ou entre enrolamentos de diferentes fases.

Em SADEGHIAN; YE; WU (2009) é proposto um algoritmo para diagnóstico de falhas em barras do rotor formado pela WPD e rede neural MLP. Este artigo usa a TW para decompor a corrente do estator no espectro tempo-frequência e extrair coeficientes característicos de diferentes níveis e nós da transformada para diferenciar a condição normal ou com defeito do motor. Os coeficientes característicos, de diferentes resoluções de frequência, junto com a frequência de escorregamento do motor são usados no treinamento da rede neural. Conclui-se com este trabalho que a implementação da WPD não exige uma exata medida da velocidade do escorregamento, o que é uma variável necessária quando está se usando a FFT em metodologias que extraem características operacionais do motor.

Desta forma, observa-se que a TW possui vantagens e atuações eficazes no processamento de sinais elétricos, o que a qualifica como uma preponderante ferramenta para filtrar sinais de motores elétricos em condições normais ou com falhas no rotor ou no estator.

2.5 Modos de Acionamentos de MIT

Os MIT podem ser acionados diretamente pela rede elétrica, cujos sinais são caracterizados como senoidais, ou por inversores de frequência, cujos sinais são não-senoidais. Os inversores de frequência PWM, composto pelo modo de controle *open-loop* ou *closed-loop*, são responsáveis em controlar a frequência da velocidade do rotor.

Os inversores *open-loop* aparecem como uma fonte controladora de tensão AC para o motor. Já o inversor *closed-loop*, em princípio, tem um regulador de corrente de alta largura de banda, o que o faz aparecer para o motor como uma fonte controladora de corrente AC. No entanto, vários dispositivos de controle *closed-loop* surgem como fontes controladoras de corrente e tensão. Nesta situação, a assinatura da falta estará presente tanto na corrente do motor quanto na tensão, o que aumenta a dificuldade em definir falhas num MIT (PIRES et al., 2009).

Métodos convencionais para análise de sinais de MIT são ineficientes ao identificar falhas em motores acionados por inversores. Isto se justifica pelo controlador de realimentação de corrente que mascara a assinatura da falta, ou ainda, pela mudança constante da carga, ou senão, pela produção de componentes de frequências próximos à componente fundamental, os quais indicam a quebra na barra do rotor (BELLINI et al., 2008a; KIM et al., 2011).

Todavia, diversos trabalhos de detecção de falha relatam o aumento da presença de inversores nos sistemas elétricos, sendo estes responsáveis pelo fornecimento de variáveis elétricas para o sistema, além de atuarem como mais um componente gerador de falhas. Na literatura, destacam-se o uso de inversores *closed-loop* ou *open-loop*, aliados aos modelos matemáticos e às técnicas de processamento de sinais, a fim de identificar falhas no rotor, principalmente as quebras nas barras do rotor (AYHAN et al., 2008; NEMEC et al., 2010; KIM et al., 2011; WOLBANK et al., 2011) e as falhas no enrolamento do estator (BRIZ et al., 2008; CHENG; ZHANG; HABETLER, 2011). No artigo LEE et al. (2011) os autores não relatam falhas específicas do motor; porém, destacam uma metodologia que analisam variáveis de todo o sistema e que podem levar às principais falhas.

Como os métodos tradicionais podem esconder problemas dos MIT acionados por inversores, reforça-se aqui a busca por novos métodos para analisar o estado técnico dos dispositivos elétricos. Dentre estes métodos destacam os sistemas inteligentes, os quais podem ser implementados em controladores ou em aplicações off-line do sistema de diagnóstico. Em trabalhos recentes encontram-se as RNA aplicadas na identificação de falhas do rolamento (ONEL; AYÇIÇEK; SENOL, 2009; CHO et al., 2010), em barras quebradas do rotor (KAMINSKI; KOWALSKI; ORLOWSKA-KOWALSKA, 2010) e em falhas no enrolamento do estator (CHO et al., 2010). A LF é utilizada na detecção de curtos-circuitos nos enrolamentos do estator (RODRIGUEZ; ARKKIO, 2008) e os sistemas híbridos neuro-fuzzy no diagnóstico de falhas no rotor (UDDIN; WANG; HUANG, 2010) e no rolamento (ABU-RUB et al., 2010).

Capítulo 3

Identificação de Falhas em Motores de Indução Trifásicos Usando Redes Neurais Artificiais

3.1 Introdução

Neste capítulo será detalhada a estrutura lógica da metodologia do sistema de diagnóstico para detecção de falhas em MIT, bem como a descrição de todos os procedimentos realizados sob as correntes trifásicas do motor. A Figura 3.1 ilustra o sistema de diagnóstico proposto, por meio de um diagrama em blocos.

No Apêndice há a descrição da bancada do laboratório, onde foram realizados os experimentos e que contém todos os equipamentos utilizados para as simulações do funcionamento do MIT. É importante mencionar que a montagem da bancada do laboratório e os ensaios obtidos por esta, também foram fonte de estudo da tese de doutorado entitulada "Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos" (SUETAKE, 2012).

3.2 Aspectos dos Dados Experimentais

As correntes trifásicas do motor são consideradas a fonte de dados para o sistema de diagnóstico. As correntes que alimentam o estator são provenientes da rede elétrica ou do inversor trifásico. O acionamento do motor pela rede elétrica recebeu uma tensão nominal de linha de 220 V equilibrada, com frequência da rede de 60 Hz. Já o acionamento pelo inversor trifásico, aplicou uma tensão no MIT resultante de tensões com formato de onda retangulares e moduladas por largura de pulso (PWM). Os ensaios experimentais realizados com o uso do inversor consideraram frequências de acionamento de 40 Hz, 50 Hz e 60 Hz.



Figura 3.1: Diagrama representando a metodologia do sistema de diagnóstico de falhas.

Com o objetivo de analisar a atuação do sistema de identificação de falhas em diferentes situações de execução do motor, foram aplicados diferentes cargas sob o eixo do MIT. Para os ensaios em motores acionados pelo inversor, foram aplicados os torques de carga de 0,5 Nm, 1,0 Nm, 1,5 Nm e 2,0 Nm naqueles com falhas nos rotores e 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm nos motores com falhas no estator; e para os motores faltosos e sem falha, acionados pela rede, foram aplicados as cargas 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. É importante destacar que as leituras dos sinais da corrente do MIT e, consequentemente, a aplicação dos torques de carga, foram realizadas após o motor atingir o seu regime permanente. A aquisição e a transformação dos sinais de analógico para digital foi realizada pela placa NIDAQmx PCIe-6259 e pelo computador, no qual a placa está conectada. A Figura 3.2 ilustra os primeiros ciclos das correntes de linha de um motor normal, cujo acionamento foi realizado pela rede elétrica e pelo inversor à 60 Hz. Em ambas situações da Figura 3.2, foi aplicado o torque de carga de 1,5 Nm.



(a) Motor acionado pela rede elétrica.



(b) Motor acionado pelo inversor em 60 Hz.

Figura 3.2: Formas de onda das correntes trifásicas do MIT sem falhas sob carga de 1,5 Nm.

Na literatura, há citação que num motor ideal a corrente do estator é formada por ondas senodais perfeitas. De fato, isto não ocorre devido à distribuição do fluxo magnético ao longo das ranhuras e por inúmeros outros fatores. Isto pode ser observado na Figura 3.2(a). Ademais, observa-se na Figura 3.2(b) que este sinal da corrente é mais distorcido que a corrente de acionamento da rede elétrica.

As Figuras 3.3 e 3.4 apresentam os primeiros ciclos das correntes do motor com uma barra perfurada no rotor, cujos acionamentos foram pela rede elétrica e pelo inversor trifásico em 60 Hz, respectivamente. Ademais, as Figuras 3.5 e 3.6 correspondem aos primeiros ciclos das correntes do motor com quatro barras perfuradas no rotor, cujos acionamentos foram pela rede elétrica e pelo inversor trifásico em 60 Hz. O motor indicado nas Figuras 3.3 e 3.4 foram acionados com um torque de carga de 2,0 Nm, e o das Figuras 3.5 e 3.6 sob um torque de carga de 4,0 Nm.



Figura 3.3: Formas de onda das correntes trifásicas do MIT, acionado pela rede elétrica, com uma barra perfurada no rotor.

Ao analisar as Figuras 3.3 e 3.5 atenta-se que não há nenhum atributo nos gráficos que os diferencie de um motor sem falha. Assim, estes sinais ilustram a dificuldade em identificar barras quebradas no rotor e, consequentemente, a necessidade de aplicar métodos matemáticos na análise dos sinais, como por exemplo, a aplicação da TW, que é capaz de ajustar o tamanho da janela de processamento para várias componentes de frequência.

As Figuras 3.4 e 3.6 esboçam a presença de ruídos, o que impede as comparações destes sinais com o gráfico do motor normal. Motores de indução estão sujeitos à ruídos e



Figura 3.4: Formas de onda das correntes trifásicas do MIT, acionado pelo inversor em 60 Hz, com uma barra perfurada no rotor.

à harmônicas quando são acionados por inversores eletrônicos de potência (SADEGHIAN; YE; WU, 2009).



Figura 3.5: Formas de onda das correntes trifásicas do MIT, acionado pela rede elétrica, com 4 barras perfuradas no rotor.



Figura 3.6: Formas de onda das correntes trifásicas do MIT, acionado pelo inversor, com 4 barras perfuradas no rotor.

Em relação à falha no estator, as Figuras 3.7(a) e 3.7(b) correspondem às correntes trifásicas de um motor com curto-circuito entre as bobinas do enrolamento do estator, com acionamento pela rede elétrica e pelo inversor trifásico sob um torque de carga de 4,0 Nm. No momento em que o modo de operação do MIT atinge o regime permanente, aciona-se então a chave que efetua a combinação de curto-circuito nas bobinas do estator. Este procedimento está ilustrado no Apêndice.

3.3 Transformada Discreta *Wavelet* e Delimitação das Amostras

Diante dos gráficos apresentados na seção anterior, faz-se necessário manipulações sobre as correntes do MIT para identificar a real situação de operação do motor. Devido a isso, a TW foi escolhida para realçar os espectros do sinal que exibem as falhas do motor, além de alterar no sinal o domínio do tempo para o domínio tempo-frequência. O tipo de TW implementada foi a DWT com a base de Haar, pois a simplicidade e confiabilidade desta *wavelet* são propriedades marcantes nas diversas resoluções de problemas na área da engenharia e matemática (MALLAT, 2009; FUGAL, 2009).

A wavelet de Haar decompõem o sinal digital x[k], em um nível j, em coeficientes que representam a baixa frequência $(c_j(k))$ e a alta frequência $(d_j(k))$ do sinal, por meio da convolução de x[k] com a transformada wavelet $(W_T[n])$. Os coeficientes $c_j(k)$ são deno-





Figura 3.7: Formas de onda das correntes trifásicas do MIT com curto-circuito no estator.

minados coeficientes de aproximação, e os $d_j(k)$ coeficientes de detalhes. Estes coeficientes

podem ser gerados pelas seguintes equações:

$$\begin{bmatrix} c_j(k) \\ d_j(k) \end{bmatrix} = W_T[n] \ x[n]$$
(3.1)

$$W_T[n] = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{bmatrix}$$
(3.2)

As formas de onda que compõem as Figuras 3.8, 3.9 e 3.10 representam os coeficientes *wavelets* de aproximação e de detalhe das correntes trifásicas de um MIT, correspondentemente, resultantes da primeira, segunda e terceira execuções consecutivas da DWT.



(b) Coeficientes *wavelets* de detalhes.

Figura 3.8: Coeficientes *wavelets* da primeira iteração da DWT sob as correntes trifásicas de um motor com falhas no rotor.





Figura 3.9: Coeficientes *wavelets* da segunda iteração da DWT sob as correntes trifásicas de um motor com falhas no rotor.

As correntes trifásicas das Figuras 3.8, 3.9 e 3.10 foram lidas de um MIT acionado diretamente pela rede elétrica (frequência fundamental de 60 Hz), com um torque de carga de 4,0 Nm e com a presença de quatro barras quebradas no rotor. Ademais, a taxa de amostragem foi de 34 microssegundos com uma frequência de amostragem de 30 kHz.





Figura 3.10: Coeficientes *wavelets* da terceira iteração da DWT sob as correntes trifásicas de um motor com falhas no rotor.

Igualmente, as Figuras 3.11, 3.12 e 3.13 representam os coeficientes *wavelets* de aproximação e de detalhe das correntes trifásicas de um MIT, decorrentes da primeira, segunda e terceira execuções consecutivas da DWT. Os sinais esboçados nestas figuras foram lidos de um MIT, cujo estator contém um curto-circuito entre bobinas de uma mesma fase, acionado pela rede elétrica e com um torque de carga de 4,0 Nm.



(b) Coeficientes *wavelets* de detalhes.

Figura 3.11: Coeficientes *wavelets* da primeira iteração da DWT sob as correntes trifásicas de um motor com falhas no estator.

O cálculo da DWT foi executado até o terceiro nível para os sinais provindos dos motores de indução acionados pela rede elétrica e, executado até o quarto nível para aqueles lidos de motores de indução acionados pelo inversor trifásico. A adição de uma iteração da DWT deve-se a maior presença de ruídos nesses sinais e que, posteriormente, auxiliou na melhoria da seleção e identificação de atributos desses sinais nas etapas subsequentes



(b) Coeficientes *wavelets* de detalhes.

Figura 3.12: Coeficientes *wavelets* da segunda iteração da DWT sob as correntes trifásicas de um motor com falhas no estator.

do sistema de diagnóstico.

Os coeficientes de aproximação provenientes do último nível da transformada *wavelet* foram subdivididos em janelas, com o objetivo de criar exemplos para a base de dados experimentais. Cada janela, ou segmento será formado por dezesseis ciclos completos de uma onda do sinal. A delimitação de uma janela foi estabelecida tendo como valor inicial



(b) Coeficientes *wavelets* de detalhes.

Figura 3.13: Coeficientes *wavelets* da segunda iteração da DWT sob as correntes trifásicas de um motor com falhas no estator.

o ponto do sinal contendo a frequência e o tempo zero, ou seja, o início do ciclo de uma onda. A razão de um segmento ser formado por ciclos completos de uma das correntes trifásicas é para evitar a ocorrência do efeito de borda durante o processo de segmentação do sinal e, consequentemente, evitar perdas de dados significantes. A Figura 3.14 ilustra um sinal de corrente de um dos motores em estudo com os pontos de delimitação de um



Figura 3.14: Delimitação de uma amostra da corrente.

segmento.

Realizada as segmentações dos sinais, cada exemplo da base de dados será analisado e extraído características que determinarão se aquele segmento indica um motor com falhas ou um motor normal. A próxima seção descreve o método definido na fase de extração de características do sistema de diagnóstico.

3.4 Extração de Características da Corrente Trifásica do MIT

A seleção das características de um sinal é de primordial importância para um diagnóstico exato do status do motor. Ou seja, as características de cada segmento serão geradas e organizadas em conjuntos de dados, os quais servirão para o treinamento e teste das RNAs. A partir do conjunto de dados de treinamento, as redes neurais serão capazes de aprender a identificar se há ou não falhas num sinal de corrente, e se houver uma falha, classificá-la. Por isso, a extração de características é fundamental para um correto aprendizado das redes neurais e, consequentemente, um correto diagnóstico.

Diante da relevância desse procedimento no sistema de diagnóstico, buscou-se no cálculo de variáveis estatísticas uma metodologia objetiva e eficiente, capaz de generalizar informações contidas num segmento de dados. Variáveis ou medidas estatísticas são aplicadas a um conjunto de dados com o intuito de analisá-lo para criar um modelo, e expor este modelo para a população. As medidas estatísticas são classificadas de acordo com a localização, a variabilidade e a forma de distribuição (assimétrica ou não) de um conjunto de dados.

Assim sendo, foram escolhidas quatro medidas estatísticas para extrair características das três correntes de alimentação do motor. São elas: média, *root mean square, skewness*

e *kurtosis*. A média é a medida da localização, pois representa um valor que melhor descreve o conjunto de dados. A medida da variabilidade é *root mean square*, e as medidas da forma de distribuição são *skewness* e *kurtosis*. Estas variáveis estatísticas podem ser obtidas pelas seguintes funções matemáticas:

 \Box média:

$$\mu^{i} = \frac{1}{N} \sum_{j=1}^{N} x_{j}^{i}$$
(3.3)

sendo que N é o número total de amostras, x_j^i é o valor do j-ésimo elemento da amostra i.

 \Box root mean sqare:

$$rms = \sqrt{\frac{1}{N} (\sum_{j=1}^{N} x_j^i)^2}$$
 (3.4)

 \Box skewness:

$$SK = \frac{1}{(N-1)s^3} \sum_{j=1}^{N} \left(x_j^i - \mu^i \right)^3$$
(3.5)

sendo que s é o desvio padrão.

 \Box kurtosis:

$$KU = \frac{1}{(N-1)s^4} \sum_{j=1}^{N} \left(x_j^i - \mu^i \right)^4$$
(3.6)

Os coeficientes de *skewness* e de *kurtosis* são também identificados, respectivamente, como o terceiro e quarto momento de um conjunto. O termo momento refere-se a potência que os dados serão elevados no cálculo destas medidas estatísticas, como descrito nas equações(3.5) e (3.6) (COCHRAN, 1967).

Skewness é uma medida que indica o quão simétrica uma distribuição está em torno de sua média, o que traduz o valor zero para uma distribuição normal com dados simétricos em torno da média. O coeficiente skewness possui valor negativo para dados que estejam distribuídos à esquerda da média, e valor positivo para o conjunto de dados com maior concentração à direita da média (LIVINGSTONE, 2009).

O coeficiente *kurtosis* mede a forma como a concentração dos dados estão do pico da média. *Kurtosis* é usado em conjunto com *skewness* para determinar se um conjunto de dados é aproximademente uma distribuição normal. Os valores de *kurtosis* para algumas distribuições são os seguintes: uma distribuição normal, o *kurtosis* é igual a 3; uma distribuição uniforme, o *kurtosis* é igual a 1,8; uma distribuição triangular, *kurtosis* é igual a 2,387; e uma distribuição exponencial, *kurtosis* é igual a 9.

As medidas estatísticas, principalmente, de variabilidade e de forma de distribuição, possibilita identificar o quanto um conjunto de dados está próximo de ser uma distribuição normal. Isto significa que estas medidas representam com segurança o conjunto de dados que está sendo analisado (LIVINGSTONE, 2009). Logo, para cada segmento que compõe a base de dados experimental foi realizado o cálculo destas quatro medidas estatísticas. Como cada segmento representa uma das correntes trifásicas, foi então agrupado os valores das medidas estatísticas das três correntes numa amostra da base de dados, resultando em um vetor formado por doze elementos.

Organizado a base de dados experimentais numa matriz constituída por doze colunas, o próximo procedimento do sistema de diagnóstico é normalizar os dados desta matriz. A normalização é efetuada em cada coluna, separadamente, no intervalo de [-1, 1]. Em seguida, cada nova amostra da base de dados foi direcionada para o conjunto de treinamento ou para o conjunto de teste das RNAs. A Seção 3.5 descreve as topologias das redes neurais implementadas nesta tese.

3.5 Organização Estrutural das Redes Neurais Artificiais

Para avaliar e identificar o status do motor, foram então implementadas algumas RNAs de diferentes arquiteturas. Inicialmente, foram desenvolvidas duas redes neurais: uma para motor acionado direto da rede e a outra para o motor acionado pelo inversor trifásico, ambas para analisar e classificar o motor como normal (sem falhas), ou com falhas no rotor ou com falhas no estator.

Posteriormente, foram definidas redes neurais para identificar os padrões de falhas nos rotores e os padrões de falhas nos estatores. As redes neurais MLP, RBF e ELMN foram escolhidas devido à competência que já demonstraram na classificação de padrões. Para identificar cada um dos padrões de falhas foram geradas redes neurais distintas, isto é, redes neurais MLP, RBF e ELMN para classificarem as falhas no rotor e outras três redes neurais, da mesma topologia, para classificarem as falhas no estator. Todavia, ambos conjuntos de redes neurais avaliaram uma mesma base de dados experiental, a qual também continha dados que representavam um motor sem falhas. As redes neurais de mesma topologia possuem alguns atributos em comum, como a taxa de aprendizagem e o valor do critério de parada.

Desta forma, as RNAs deverão classificar a gravidade da falha, como por exemplo, as falhas no estator serão agrupadas entre curto-circuito entre bobinas da fase "a", curtocircuito entre bobinas da fase "b", motor sem falhas e outra falha. Em relação às barras seccionadas do rotor, foram categorizadas uma barra seccionada, duas barras seccionadas, quatro barras seccionadas, motor sem falhas e outra falha. Todas estas possíveis condições foram tanto consideradas para o motor acionado pela rede elétrica como para o motor acionado por um inversor trifásico. Os dados de entrada das redes neurais são formados por vetores constituídos de 12 unidades. Ou seja, quatro unidades são valores resultantes do cálculo das variáveis estatísticas (média, *root mean square, skewness, kurtosis*) de um segmento de dado, o qual é formado por 16 ciclos completos de uma das fases da corrente trifásica do MIT. Em paralelo, executa-se o cálculo das variáveis estatísticas nos segmentos de dados que representam as outras duas fases da corrente trifásica, totalizando 12 unidades.

As topologias das redes MLP, implementadas para os motores acionados pela rede e para os motores acionados pelo inversor, foram definidas pelo método *cross-validation*, alterando a quantidade de camadas neurais intermediárias e a quantidade de neurônios destas camadas para alcançar a rede neural mais eficiente. A Figura 3.15 ilustra a rede MLP determinada para os motores acionados pela rede elétrica e para as falhas no rotor. Esta rede é constituída por 12 unidades na camada de entrada, 30 neurônios na camada neural intermediária e 5 neurônios na camada neural de saída. A função de ativação dos neurônios da camada intermediária é a função tangente hiperbólica, enquanto a dos neurônios da camada de saída é a função linear. O algoritmo de treinamento da rede MLP é o *backpropagation*, baseado na técnica de otimização *Levenberg-Marquardt*. Ademais, o critério de parada usado para avaliar a evolução durante o treinamento da rede neural foi efetuado pelo erro quadrático médio, cujo valor limite é igual a 10^{-10} .



Figura 3.15: Configuração da rede neural MLP.

Todavia, as redes MLP designadas para os motores acionados pelo inversor obtiveram topologias diferentes para classificar as falhas nos rotores e nos estatores. A topologia da rede prescrita para analisar o motor com falhas no rotor é constituída por 12 unidades na camada de entrada, 26 neurônios na primeira camada neural intermediária, 10 neurônios na segunda camada neural intermediária e 5 neurônios na camada neural de saída. Já a rede MLP para analisar motor com falhas no estator é constituída por 12 unidades na camada de entrada, 20 neurônios na primeira camada neural intermediária e 4 neurônios na camada neural de saída. O critério de parada usado para ambas as redes MLP foi o erro quadrático médio, cujo valor limite é igual a 10^{-10} .

Redes neurais MLP foram implementadas para avaliar se o motor está sem falhas ou se há falhas no estator ou no rotor. Tanto a rede neural designada para os motores acionados pela rede quanto os motores acionados pelo inversor, são constituídas por 12 unidades na camada de entrada, 23 neurônios na primeira camada neural intermediária e 3 neurônios na camada neural de saída.

A rede ELMN é uma rede neural recorrente, cujas estruturas de processamento são capazes de representar uma grande variedade de comportamentos dinâmicos. Contudo, a presença da realimentação da informação da saída dos neurônios da camada neural intermediária para entrada desta mesma camada, permite a criação de representações internas e dispositivos de memória capazes de processar e armazenar informações temporais durante o treinamento da rede. Após o cálculo e atualizações dos pesos e do limiar de ativação da rede ELMN durante a fase de treinamento, estes não serão modificados na fase de validação da rede neural. A Figura 3.16 ilustra a configuração de uma rede neural ELMN.



Figura 3.16: Configuração da rede neural ELMN.

Também, pelo método cross-validation foi determinado a quantidade de neurônios na camada neural intermediária das redes ELMN. Para diagnosticar motores acionados pela rede elétrica, foi criado a rede ELMN para falhas em rotores, constituída de 22 neurônios na camada neural intermediária, e 24 neurônios na rede ELMN designada para motores com falhas no estator. Todas as duas redes possuem o algoritmo de treinamento back-propagation baseado no método BFGS quasi-Newton, e o critério de parada avaliado pelo

erro quadrático médio com valor limite de 0,07. Em contrapartida, as duas redes neurais ELMN definidas para os motores acionado pelo inversor são iguais, com 20 neurônios na camada neural intermediária e erro quadrático médio com valor limite de 0,09, conforme ilustrada na Figura 3.16.

As redes neurais RBF determinadas para examinar motores acionados pela rede elétrica são formadas pelas 12 unidades de entrada e 325 neurônios na camada neural intermediária. Analogamente, as redes RBF projetadas para analisar motores acionado por inversor compõem de 425 neurônios na camada neural intermediária. A quantidade significativa de neurônios na camada intermediária deve-se à função pré-definida *newrb* da linguagem de programação Matlab, que acrescenta neurônios nesta camada até atingir o erro quadrático médio especificado. A função *newrb* cria o projeto da rede RBF. A Figura 3.17 ilustra a arquitetura de uma rede neural RBF.



Figura 3.17: Arquitetura de uma rede neural RBF.

Em síntese, as Tabelas 3.1 e 3.2 detalham as características estruturais das RNAs destinadas, respectivamente, a avaliação de motores de indução acionados pela rede elétrica e a motores de indução acionados pelo inversor trifásico.

Todas as redes neurais definidas realizam o treinamento supervisionado; assim, para cada dado de entrada um respectivo padrão de saída desejado foi analisado pelas redes durante o seu treinamento. Logo, as Tabelas 3.3, 3.4 e 3.5 descrevem os possíveis status dos motores e as respectivas saídas desejadas pelas redes neurais. Tabela 3.1: Descrição das características das RNAs, empregadas na análise de motores acionados pela rede elétrica.

64

Tipo da RNA	Número de Neurônios ¹	Critério de Parada ²
MLP (rede geral)	[23,3]	10^{-10}
ELMN (falhas no rotor)	[22,5]	0,08
ELMN (falhas no estator)	[24,4]	0,07
MLP (falhas no rotor)	[30,5]	10^{-10}
MLP (falhas no estator)	[30,4]	10^{-10}
RBF (falhas no rotor)	[325,5]	10^{-10}
RBF (falhas no estator)	[325,4]	10^{-10}

 1 Quantidade de neurônios na
(s) camada(s) intermediária(s) e na camada de saída $^2 {\rm Erro}$ Quadrático Médio

Tabela 3.2: Descrição das características das RNAs, empregadas na análise de motores acionados por inversor trifásico.

Tipo da RNA	Número de Neurônios ¹	Critério de Parada ²
MLP (rede geral)	[23,3]	10^{-10}
ELMN (falhas no rotor)	[20,5]	0,09
ELMN (falhas no estator)	[20,4]	0,09
MLP (falhas no rotor)	[26,10,5]	10^{-10}
MLP (falhas no estator)	[20,4]	10^{-10}
RBF (falhas no rotor)	[425,5]	10^{-8}
RBF (falhas no estator)	[425,4]	10^{-6}

 1 Quantidade de neurônios na
(s) camada(s) intermediária(s) e na camada de saída $^2 {\rm Erro}$ Quadrático Médio

Tabela 3.3: Padrão de saída das redes neurais para identificar se há falhas.

Status do Motor	Saídas Desejadas
Normal	[1 -1 -1]
Barra Quebrada no rotor	[-1 1 -1]
Curto-circuito no estator	[-1 -1 1]

Tabela 3.4: Padrão de saídas das redes neurais MLP, RBF e ELMN para falhas no rotor.

Status do Motor	Saídas Desejadas
Outras falhas	[1 -1 -1 -1 -1]
Normal	[-1 1 -1 -1 -1]
Uma barra quebrada	[-1 -1 1 -1 -1]
Duas barras quebradas	[-1 -1 -1 1 -1]
Quatro barras quebradas	[-1 -1 -1 -1 1]

Tabela 3.5: Padrão de saídas das redes neurais MLP, RBF e ELMN para falhas no estator.

Status do Motor	Saídas Desejadas
Outras falhas	[1 -1 -1 -1]
Normal	[-1 1 -1 -1]
Curto-circuito na fase a	[-1 -1 1 -1]
Curto-circuito na fase b	[-1 -1 -1 1]

Capítulo 4

Resultados Experimentais

4.1 Introdução

Neste capítulo serão apresentados os resultados obtidos pelas redes neurais ao identificar uma das seguintes situações para um MIT: normal, falhas nas barras do rotor, curtocircuito nas bobinas do estator. Os ensaios consideram um MIT operando em regime permanente sob circunstâncias de cargas constantes, com acionamento direto da rede elétrica ou por um inversor trifásico. A conexão do motor foi configurada em Δ , com tensão de alimentação de linha de 220 V equilibrada.

Neste contexto, a base de dados experimentais é constituída pelos seguintes ensaios: a) motor sem falha; b) motor com uma barra seccionada; c) motor com duas barras seccionadas; d) motor com quatro barras seccionadas; e) motor com curto-circuito entre bobinas da fase "a"; f) motor com curto-circuito entre bobinas da fase "b". Para os ensaios em motores acionados pelo inversor, foram aplicados os torques de carga de 0,5 Nm, 1,0 Nm, 1,5 Nm e 2,0 Nm naqueles com falhas nos rotores e 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm nos motores com falhas no estator; e para os motores faltosos e sem falha, acionados pela rede, foram aplicados as cargas 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm. Os torques de cargas de 0,5 Nm, 1,0 Nm, 2,0 Nm, 3,0 Nm e 4,0 Nm e 4

Todo sistema de diagnóstico foi implementado no MATLAB 7.11 (R2010b), qualificado como uma linguagem de programação de alto nível.

4.2 Testes Experimentais I: Identificação de Falhas

Nesta seção serão apresentados os resultados obtidos pela redes neurais MLP para diagnosticar se o sinal da corrente provindo de motores acionados pela rede elétrica ou por inversores, contém falhas no estator (curto-circuito nas bobinas do estator), ou no rotor (barras seccionadas), ou não contém falhas. O propósito da criação destas redes neurais são para ilustrar um sistema computacional elementar, capaz de ser traduzido para dispositivos eletrônicos, como microprocessadores, e de auxiliar produtivamente profissionais do âmbito industrial responsáveis pelo funcionamento de MIT.

As Figuras 4.1 e 4.2 apresentam as percentagens de acertos para os conjuntos de treinamento e teste das redes neurais destinadas ao diagnóstico de motores acionados direto pela rede elétrica e acionados por inversores de frequência. As duas redes neurais possuem 12 neurônios na camada de entrada, 23 neurônios na camada neural intermediária e 3 neurônios na camada neural de saída. A quantidade de amostras representadas na Figura 4.1 são 886 amostras para o conjunto de treinamento e 281 amostras para o conjunto de teste. Em proporção, a Figura 4.2 possui 454 amostras para o conjunto de treinamento e 307 amostras para o conjunto de teste.



Figura 4.1: Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural destinada aos motores acionados pela rede elétrica.

Pela Figura 4.1 nota-se o resultado ruim na identificação de motores de indução sem falhas (abaixo de 50%) acionados pela rede. Esse resultado poderia ser aperfeiçoado executando o treinamento da rede neural apenas com dados experimentais de motores normais operando com torque de carga nominal acima de 50%.

Em consequência da presença de ruídos nos sinais provindos dos motores acionados por inversores, fez-se necessário executar a DWT em mais um nível dos coeficientes de aproximação. Estas alterações favoreceram a identificação dos status do motor, como pode ser certificado na matriz de confusão descrita na Tabela 4.2.


Figura 4.2: Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural destinada aos motores acionados por inversores.

Uma matriz de confusão oferece uma medida efetiva do modelo de classificação, ao mostrar o número de classificações corretas e as classificações preditas para cada classe em um determinado conjunto de exemplos. Os valores contidos na diagonal principal da matriz de confusão indicam as percentagens de acertos no reconhecimento dos padrões, que estão sendo indicados pelas respectivas colunas e linhas. As Tabelas 4.1 e 4.2 representam as matrizes de confusão dos conjuntos de dados de teste resultantes das redes neurais.

Tabela 4.1:	Matriz	de confusão	resultante	do sistema	ı de dia	agnóstico	para fa	lhas no	motor
acionado pe	ela rede	elétrica.							

Status		Classificação do Sistema						
do Motor	Normal	Falha no Rotor	Falha no Estator					
Normal	21	18	5	44				
Falha no Rotor	0	151	2	153				
Falha no Estator	7	5	72	84				
Total	28	174	79	281				

Status		Classificação do Sistema						
do Motor	Normal	Falha no Rotor	Falha no Estator					
Normal	35	3	0	38				
Falha no Rotor	0	103	26	129				
Falha no Estator	1	0	139	140				
Total	36	106	165	307				

Tabela 4.2: Matriz de confusão resultante do sistema de diagnóstico para falhas no motor acionado por inversor.

4.3 Testes Experimentais II: Identificação de Quebra de Rotor - Acionamento pela Rede Elétrica

As redes neurais descritas nesta seção realizaram a identificação de diferentes perfurações nas barras do rotor, além de distinguir um motor normal e outra possível falha. Ademais, foi implementado redes neurais destinadas a base de dados composta por sinais que provinham de motores acionados pela rede elétrica. Os resultados gerados pelas redes neurais ELMN, MLP e RBF serão apresentados em sequência, para auxiliar na interpretação e comparação dos dados emergentes. A base de dados experimentais foi subdividida aleatoriamente entre o conjunto de dados para treinamento e o conjunto de dados para teste das redes neurais. A quantidade de amostras destinadas ao conjunto de treinamento totalizou 548, e para o conjunto de teste 272 amostras. As Figuras 4.3, 4.4 e 4.5 ilustram, respectivamente, as percentagens de acertos na classificação de falhas das amostras pertencentes aos conjuntos de treinamento e teste das redes ELMN, MLP e RBF.

As Tabelas 4.3, 4.4 e 4.5 representam as matrizes de confusão dos conjuntos de dados de teste resultantes das redes neurais.

Os dados de saída da rede neural MLP apresentaram dois valores positivos para algumas amostras, e para metade destas ocorrências, o menor valor positivo representava a classificação correta para aquele padrão. Então, para estas amostras, a rede neural MLP gerou duas possíveis respostas.

Diante dos resultados apresentados, a rede neural MLP teve um melhor desempenho na identificação de falhas em rotores.



Figura 4.3: Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural ELMN.



Figura 4.4: Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural MLP.



Figura 4.5: Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural RBF.

Tabela 4.3: Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede ELMN.

Status		Classificação do Sistema					
do Motor	Normal	1 B. Q. ¹	2 B. Q. ¹	4 B. Q. ¹	Outras falhas		
Normal	42	0	3	0	0	45	
1 barra quebrada	0	39	6	0	0	45	
2 barras quebradas	0	5	23	17	0	45	
4 barras quebradas	0	2	0	45	0	47	
Outras falhas	0	0	1	3	86	90	
Total	42	46	33	65	86	272	

¹B. Q. : Barra Quebrada

4.4 Testes Experimentais III: Identificação de Quebra de Rotor - Acionamento por Inversor

Nesta seção, serão exibidos os resultados alcançados pelas redes neurais ELMN, MLP e RBF, que identificaram falhas no rotor de motores acionados por inversores de frequência. A quantidade de amostras destinadas ao conjunto de treinamento totalizou 370, e para o conjunto de teste 307 amostras. As Figuras 4.6, 4.7 e 4.8 ilustram, respectivamente, as percentagens de acertos na classificação de falhas das amostras pertencentes aos conjuntos

Tabela 4.4:	Matriz	de confusão	$\operatorname{resultante}$	do sistema d	e diagnóstico,	constituído	pela rede
MLP.							

Status		Classificação do Sistema						
do Motor	Normal	1 B. Q. ¹	2 B. Q. ¹	4 B. Q. ¹	Outras falhas			
Normal	38	0	0	0	7	45		
1 barra quebrada	0	41	2	2	0	45		
2 barras quebradas	0	0	42	2	1	45		
4 barras quebradas	0	2	6	39	0	47		
Outras falhas	2	0	0	0	88	90		
Total	29	30	30	28	87	272		

¹B. Q. : Barra Quebrada

Tabela 4.5: Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede RBF.

Status		Classificação do Sistema					
do Motor	Normal	1 B. Q. ¹	2 B. Q. ¹	4 B. Q. ¹	Outras falhas		
Normal	42	1	2	0	0	45	
1 barra quebrada	3	31	11	0	0	45	
2 barras quebradas	8	1	36	0	0	45	
4 barras quebradas	10	2	0	35	0	47	
Outras falhas	6	0	0	0	84	90	
Total	69	35	49	35	84	272	

 $^1\mathrm{B.}$ Q. : Barra Quebrada

de treinamento e teste das redes ELMN, MLP e RBF.



Figura 4.6: Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural ELMN.

73



Figura 4.7: Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural MLP.



Figura 4.8: Percentagem de acertos na classificação dos conjuntos de treinamento e teste da rede neural RBF.

As Tabelas 4.6, 4.7 e 4.8 representam as matrizes de confusão dos conjuntos de dados de teste resultantes das redes neurais.

4.4. Testes Experimentais III: Identificação de Quebra de Rotor - Acionamento POR INVERSOR

Tabela 4.6: M	atriz de confusão	do conjunto de	dados resultante	e do sistema	de diagnóstico,
constituído pe	ela rede ELMN, p	ara falhas no r	otor.		

Status		Classificação do Sistema						
do Motor	Normal	1 B. Q. ¹	2 B. Q. ¹	4 B. Q. ¹	Outras falhas			
Normal	38	0	0	0	0	38		
1 barra quebrada	2	43	0	0	0	45		
2 barras quebradas	9	0	36	0	0	45		
4 barras quebradas	0	0	3	39	0	42		
Outras falhas	0	0	0	25	112	137		
Total	49	43	39	64	112	307		

¹B. Q. : Barra Quebrada

Tabela 4.7: Matriz de confusão do conjunto de dados resultante do sistema de diagnóstico, constituído pela rede MLP, para falhas no rotor.

Status		Classificação do Sistema						
do Motor	Normal	1 B. Q. ¹	2 B. Q. ¹	4 B. Q. ¹	Outras falhas			
Normal	31	1	4	2	0	38		
1 barra quebrada	0	15	18	12	0	45		
2 barras quebradas	0	7	37	1	0	45		
4 barras quebradas	3	4	0	35	0	42		
Outras falhas	1	0	0	0	136	137		
Total	35	27	59	50	136	307		

¹B. Q. : Barra Quebrada

Tabela 4.8: Matriz de confusão do conjunto de dados resultante do sistema de diagnóstico, constituído pela rede RBF, para falhas no rotor.

Status		Classificação do Sistema						
do Motor	Normal	1 B. Q. ¹	2 B. Q. ¹	4 B. Q. ¹	Outras falhas			
Normal	9	4	1	19	5	38		
1 barra quebrada	2	14	11	18	0	45		
2 barras quebradas	0	0	30	10	5	45		
4 barras quebradas	0	9	5	28	0	42		
Outras falhas	0	0	0	0	137	137		
Total	11	27	47	75	147	307		

¹B. Q. : Barra Quebrada

Como pode ser notado pelos dados da Tabela 4.8, a rede RBF obteve péssimos resultados, levando quase todas as amostras da base de dados tendenciarem a classificar como 4 barras seccionadas do rotor. Ao analisar os dados resultantes desta rede neural, 95% das classificações erradas obtiveram dois valores positivos em sua saída: uma para o padrão errado e a outra para o padrão correto. Porém, o valor positivo do padrão errado era maior que o padrão correto.

75

Diante dos resultados mostrados nas Tabelas 4.6, 4.7 e 4.8, conclui-se que as redes neurais não atingiram desempenhos significativos e desejáveis para uma boa classificação de falhas em rotores de motores acionados por inversores de frequência.

4.5 Testes Experimentais IV: Identificação de Curto-Circuito no Estator - Acionamento pela Rede Elétrica

Nesta seção, as redes neurais ELMN, MLP e RBF foram geradas para diagnosticar curtoscircuitos em diferentes bobinas do estator, além de também diferenciar um motor normal e outra possível falha. A base de dados utilizada por estas redes neurais é composta por sinais de corrente de motores acionados pela rede elétrica e subdividida em 548 amostras para o conjunto de treinamento e 272 amostras para o conjunto de teste. As Figuras 4.9, 4.10 e 4.11 ilustram, respectivamente, as percentagens de acertos na classificação de falhas das amostras dos conjuntos de treinamento e teste das redes ELMN, MLP e RBF.



Figura 4.9: Percentagem de acertos dos conjuntos de treinamento e teste da rede neural ELMN, para identificação de falhas no estator.



Figura 4.10: Percentagem de acertos dos conjuntos de treinamento e teste da rede neural MLP, para identificação de falhas no estator.



Figura 4.11: Percentagem de acertos dos conjuntos de treinamento e teste da rede neural RBF, para identificação de falhas no estator.

As Tabelas 4.9, 4.10 e 4.11 representam as matrizes de confusão dos conjuntos de dados de teste resultantes das redes neurais.

Tabela 4.9: Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede ELMN para falhas no estator.

Status		Classificação do Sistema						
do Motor	Normal	Curto Fase "a"	Curto Fase "b"	Outras falhas				
Normal	44	0	1	0	45			
Curto Fase "a"	2	40	1	2	45			
Curto Fase "b"	0	0	45	0	45			
Outras falhas	1	0	0	136	137			
Total	47	40	47	138	272			

Tabela 4.10: Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede MLP para falhas no estator.

Status	Classificação do Sistema				Total
do Motor	Normal	Curto Fase "a"	Curto Fase "b"	Outras falhas	
Normal	28	11	1	5	45
Curto Fase "a"	0	42	0	3	45
Curto Fase "b"	1	0	42	2	45
Outras falhas	0	5	1	131	137
Total	29	58	44	141	272

Tabela 4.11: Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede RBF para falhas no estator.

Status	Classificação do Sistema				Total
do Motor	Normal	Curto Fase "a"	Curto Fase "b"	Outras falhas]
Normal	38	0	1	6	45
Curto Fase "a"	3	42	0	0	45
Curto Fase "b"	3	4	38	0	45
Outras falhas	10	17	0	110	137
Total	54	63	39	116	272

Diante dos resultados apresentados pelas Tabelas 4.9, 4.10 e 4.11, as redes neurais ELMN e RBF obtiveram um bom desempenho. Porém, a rede MLP seria considerada uma excelente classificadora de falhas no estator, se não fosse os erros que apresentou ao identificar o padrão motor normal, que também é uma saída analisada pela redes neurais.

4.6 Testes Experimentais V: Identificação de Curto-Circuito no Estator - Acionamento por Inversor

O sistema de diagnóstico para falhas no estator, proveniente de motores acionados por inversor de frequência, é composto pela redes neurais ELMN, MLP e RBF. A base de dados utilizada para testar este sistema foi formada por 370 amostras destinadas ao conjunto de treinamento e 307 amostras para o conjunto de teste. As Figuras 4.12, 4.13 e 4.14 ilustram, respectivamente, as percentagens de acertos na classificação de falhas das amostras dos conjuntos de treinamento e teste das redes ELMN, MLP e RBF.



Figura 4.12: Percentagem de acertos dos conjuntos de treinamento e teste da rede neural ELMN, para identificação de falhas no estator.

As Tabelas 4.12, 4.13 e 4.14 representam as matrizes de confusão dos conjuntos de dados de teste resultantes das redes neurais.

Pelos resultados exibidos nas Tabelas 4.12, 4.13 e 4.14, a rede neural ELMN obteve o melhor desempenho dentre as três redes testadas. A rede RBF gerou resultados notórios na classificação do padrão para falha em curto-circuito, mas para as outras classificações não teve bom desempenho.



Figura 4.13: Percentagem de acertos dos conjuntos de treinamento e teste da rede neural MLP, para identificação de falhas no estator.



Figura 4.14: Percentagem de acertos dos conjuntos de treinamento e teste da rede neural RBF, para identificação de falhas no estator.

Status	Classificação do Sistema				Total
do Motor	Normal	Curto Fase "a"	Curto Fase "b"	Outras falhas	
Normal	37	0	1	0	38
Curto Fase "a"	0	66	0	1	67
Curto Fase "b"	0	1	69	0	70
Outras falhas	0	0	17	115	132
Total	37	67	87	116	307

Tabela 4.12: Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede ELMN para falhas no estator.

Tabela 4.13: Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede MLP para falhas no estator.

Status	Classificação do Sistema				Total
do Motor	Normal	Curto Fase "a"	Curto Fase "b"	Outras falhas	
Normal	37	0	1	0	38
Curto Fase "a"	0	55	0	12	67
Curto Fase "b"	3	0	67	0	70
Outras falhas	5	0	14	113	132
Total	45	55	82	125	307

Tabela 4.14: Matriz de confusão resultante do sistema de diagnóstico, constituído pela rede RBF para falhas no estator.

Status	Classificação do Sistema				Total
do Motor	Normal	Curto Fase "a"	Curto Fase "b"	Outras falhas	
Normal	27	0	0	11	38
Curto Fase "a"	4	63	0	0	67
Curto Fase "b"	0	2	68	0	70
Outras falhas	31	0	0	101	132
Total	62	65	68	112	307

Capítulo 5

Conclusões Gerais e Diretivas Futuras

5.1 Conclusões Gerais

Nesta tese foi apresentada uma metodologia para um sistema de diagnóstico de falhas em MIT, acionado tanto pela rede elétrica quanto por inversores trifásicos. As falhas consideradas são falhas elétricas relacionadas a barras seccionadas nos rotores e curtoscircuitos entre bobinas da mesma fase do estator. Assim sendo, ressalta os métodos que compõem o sistema diagnóstico, pois foram os responsáveis pelos bons resultados alcançados.

No primeiro procedimento do sistema de diagnóstico, a DWT transforma a corrente trifásica para o domínio tempo-frequência e, pelas sucessivas execuções da transformada, características relevantes dos sinais são realçadas. Na sequência, a seleção do início e fim de uma amostra de dados foi pertinente para evitar o efeito de borda e, com isso, não ocorrer perdas de informações importantes do sinal.

O processo de extração de características, que é realizado pelo cálculo das medidas estatísticas, foi essencial para formar o conjunto de dados coeso destinado ao treinamento e teste das redes neurais. Além disso, estas medidas estatísticas são cálculos sem complexidade que exploram de forma eficiente e fidedigna um conjunto amostral.

Por fim, as RNAs efetuaram a classificação dos padrões, que retratam as falhas no rotor e no estator dos motores de indução. As três topologias ELMN, MLP e RBF, são descritas na literatura como excelentes ferramentas computacionais para identificação de padrões, além de bons resultados já obtidos em problemas envolvendo MIT. Contudo, tiveram comportamentos diferentes ao avaliar as amostras do conjunto de testes que representam um motor sem falhas, ou com falhas no rotor ou no estator.

Em relação as redes neurais gerais definidas para diagnosticar se há falhas ou não na corrente de um MIT, tanto os motores acionados pela rede elétrica quanto aqueles acionados pelo inversor, conseguiram identificar nos sinais analisados, o mínimo de 80% de exatidão nas ocorrências de falhas. Logo, estas RNAs satisfazem o propósito de serem implementadas em dispositivos eletrônicos para auxiliar a produtividade no âmbito industrial.

A rede neural MLP destinada à classificação de barras seccionadas no rotor de um motor acionado pela rede elétrica, gerou ótimos resultados com valores acima de 83% de acertos e com pequeno tempo de processamento durante o treinamento, o que já é uma propriedade das redes MLP. Ademais, esta rede neural obteve 98% de acertos no reconhecimento do padrão outras falhas, e 84% de acertos no reconhecimento do padrão motor sem falhas. Contudo, a rede ELMN foi a topologia mais eficaz na classificação de barras seccionadas no rotor de um motor acionado pelo inversor, mesmo consumindo um alto tempo de processamento durante o treinamento da rede, aproximadamente 35 minutos. Todavia, a rede neural RBF não alcançou bons resultados, o que conclui uma topologia inadequada para esse padrão.

A particularidade do sinal que indica a falha no curto-circuito do estator é notória em relação à falha nas barras seccionadas do rotor, a qual gera pequenas distorções no sinal. A rede neural ELMN foi a topologia mais eficiente no reconhecimento de curtos-circuitos no estator em motor de indução acionado pela rede elétrica. Além disto, a rede neural MLP apresentou resultados coesos na classificação das falhas no estator, com 93% de exatidão, mas apenas 62% de exatidão na classificação de motor normal. Esta inabilidade da rede neural MLP poderia ser corrigida selecionando apenas correntes trifásicas de um motor sem falhas com torque de carga nominal acima de 50%.

Em referência as redes neurais para a identificação de curtos-circuitos no estator em motor de indução acionado pelo inversor, a rede ELMN foi a melhor topologia apresentando resultados acima de 95% de acertos para este padrão e para o padrão motor sem falha, e 87% de exatidão para outras falhas.

Enfim, as redes neurais Elman exibiram o melhor desempenho para compor um sistema de diagnóstico de falhas elétricas em rotor e estator de motores de indução, sugerindo o acréscimo das redes neurais MLP em tais sistemas para assegurar a precisão nas soluções das redes neurais ELMN.

Em decorrência dos elementos conclusivos, as principais contribuições da tese podem ser delineadas nos tópicos:

- Desenvolvimento de uma metodologia capaz de identificar e classificar falhas elétricas no rotor e no estator de um MIT. Esta metodologia alicerciou a criação de um sistema de diagnóstico de falhas, composto por ferramentas computacionais objetivas e eficientes;
- □ Aplicação de variáveis estatísticas para extrair características relevante do sinal e, consequentemente, identificar as reais condições de funcionamento de um motor.

- A proposição de um método baseado em redes neurais artificiais para o reconhecimento do status de um MIT, o qual define uma das seguintes situações: motor sem falhas, motor com curto-circuito entre bobinas do estator, motor com uma barra seccionada no rotor, motor com duas barras seccionadas no rotor e motor com quatro barras seccionadas no rotor.
- Criação de um sistema computacional que não necessitou desenvolver um modelo matemático, que expressasse as propriedades físicas e exigências de funcionamento do motor.
- □ Estudo e avaliação da metodologia proposta para detecção de falhas em rotores e estatores, avaliando o seu comportamento diante de várias condições de funcionamento do motor. Neste contexto, citam-se as seguintes circunstâncias: 1) um MIT acionado pela rede elétrica, cuja tensão trifásica é equilibrada, senoidal e frequência de 60 Hz; 2) um MIT acionado por um inversor trifásico, cuja tensão é modulada por largura de pulso com frequências fundamentais em 40 Hz, 50 Hz e 60 Hz; 3) aplicação de diversos torques de carga, variando entre 0.5 Nm a 4.0 Nm.

5.2 Diretivas Futuras

As diretivas de trabalhos futuros desta pesquisa consistem em aperfeiçoar os sistemas computacionais para identificar falhas presentes em MIT de baixa tensão. Neste contexto, os seguintes tópicos são sugeridos:

- Alterar o sistema de diagnóstico de falhas para MIT acionado por inversor, retirando mais informações da corrente trifásica, como por exemplo a tensão, com o objetivo de melhorar o desempenho do sistema.
- Alterar a técnica da TW, de DWT para a WPD. A WPD retira coeficientes wavelets de detalhes e de aproximação, resultantes de diferentes níveis da transformada, de acordo com os propósitos para os quais estão sendo empregados.
- Desenvolver métodos de detecção de falhas em rolamentos defeituosos presentes em MIT.
- Ampliar a base de dados experimentais para conter amostras constituídas por duas falhas simultâneas.

Referências

- ABU-RUB, H.; Moin Ahmed, S.; IQBAL, A.; RAHIMIAN, M.; TOLIYAT, H. Incipient bearing fault diagnostics for inverter fed induction motor drive using ANFIS. In: PROCEEDING OF THE XIX INTERNATIONAL CONFERENCE ON ELECTRI-CAL MACHINES (ICEM), 2010. Anais... [S.l.: s.n.], 2010. p.1–5.
- ALTUG, S.; TRUSSELL, H. Fuzzy inference systems implemented on neural architectures for motor fault detection and diagnosis. IEEE Transactions on Industrial Electronics, [S.l.], v.46, n.6, p.1069–1079, Dec. 1999.
- ARABACI, H.; BILGIN, O. Automatic detection and classification of rotor cage faults in squirrel cage induction motor. Neural Computing and Applications, [S.l.], v.19, n.5, p.713–723, Dec. 2009.
- ASFANI, D. A.; MUHAMMAD, A. K.; SYAFARUDDIN; PURNOMO, M. H.; HIYAMA, T. Temporary short circuit detection in induction motor winding using combination of wavelet transform and neural network. Expert Systems with Applications, [S.l.], v.39, n.5, p.5367–5375, Apr. 2012.
- AWADALLAH, M. A.; MORCOS, M. M. Application of AI tools in fault diagnosis of electrical machines and drives-an overview. IEEE Transactions on Energy Conversion, [S.l.], v.18, n.2, p.245–251, June 2003.
- AYHAN, B.; CHOW, M.-Y.; SONG, M.-H. Multiple discriminant analysis and neuralnetwork-based monolith and partition fault-detection schemes for broken rotor bar in induction motors. **IEEE Transactions on Industrial Electronics**, [S.I.], v.53, n.4, p.1298–1308, June 2006.
- AYHAN, B.; TRUSSELL, H. J.; CHOW, M.-Y.; SONG, M.-H. On the use of a lower sampling rate for broken rotor bar detection with DTFT and AR-based spectrum methods. IEEE Transactions on Industrial Electronics, [S.l.], v.55, p.1421–1434, Mar. 2008.
- BALLAL, M. S.; KHAN, Z. J.; SURYAWANSHI, H. M.; SONOLIKAR, R. L. Adaptive neural fuzzy inference system for the detection of inter-turn insulation and bearing wear faults in induction motor. **IEEE Transactions on Industrial Electronics**, [S.l.], v.54, n.1, p.250–258, Feb. 2007.

- BARAKAT, M.; F., D.; LEFEBVRE, D.; KHALIL, M.; MUSTAPHA, O. Self adaptive growing neural network classifier for faults detection and diagnosis. Neurocomputing, [S.l.], v.74, n.18, p.3865–3876, Nov. 2011.
- BARENDSE, P. S.; HERNDLER, B.; KHAN, M. A.; PILLAY, P. The application of wavelets for the detection of inter-turn faults in induction machines. In: IEEE INTER-NATIONAL ELECTRIC MACHINES & DRIVES CONFERENCE (IEMDC), 2009. Proceedings... [S.l.: s.n.], 2009. p.1401–1407.
- BELLINI, A.; FILIPPETTI, F.; FRANCESCHINI, G.; TASSONI, C. Closed-loop control impact on the diagnosis of induction motors faults. IEEE Transactions on Industry Applications, [S.l.], v.36, n.5, p.1318–1329, Sept./Oct. 2000.
- BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G. A. Advances in diagnostic techniques for induction machines. IEEE Transactions on Industrial Electronics, [S.l.], v.55, n.12, p.4109–4126, Dec. 2008a.
- BONNETT, A.; YUNG, C. Increased efficiency versus increased reliability. **IEEE Industry Applications Magazine**, [S.l.], v.14, n.1, p.29–36, Jan. 2008.
- BOUZID, M. B. K.; CHAMPENOIS, G.; BELLAAJ, N. M.; SIGNAC, L.; JELASSI, K. An effective neural approach for the automatic location of stator interturn faults in induction motor. **IEEE Transactions on Industrial Electronics**, [S.l.], v.55, n.12, p.4277–4289, Dec. 2008.
- BOUZID, M.; CHAMPENOIS, G.; BELLAAJ, N.; JELASSI, K. Automatic and robust diagnosis of broken rotor bars fault in induction motor. In: PROCEEDING OF THE XIX INTERNATIONAL CONFERENCE ON ELECTRICAL MACHINES - (ICEM), 2010. Anais... [S.l.: s.n.], 2010. v.2, p.1–7.
- BRIZ, F.; DEGNER, M. W.; GARCIA, P.; DIEZ, A. B. High-frequency carrier-signal voltage selection for stator winding fault diagnosis in inverter-fed AC machines. IEEE Transactions on Industrial Electronics, [S.l.], v.55, n.12, p.4181–4190, Dec. 2008.
- CAMINHAS, W. M.; TAVARES, H.; GOMIDE, F. A neurofuzzy approach for fault diagnosis in dynamic systems. In: PROCEEDING OF IEEE INTERNATIONAL CON-FERENCE ON FUZZY SYSTEMS, 1996. Anais... [S.l.: s.n.], 1996. p.2032–2037.
- CARDOSO, A. J. M.; CRUZ, S. M. A.; FONSECA, D. S. B. Inter-turn stator winding fault diagnosis in three-phase induction motors, by Park's vector approach. IEEE Transactions on Energy Conversion, [S.l.], v.14, n.3, p.595–598, Sept. 1999.
- CASTEJÓN, C.; LARA, O.; GARCÍA-PRADA, J. C. Automated diagnosis of rolling bearings using MRA and neural networks. Mechanical Systems and Signal Processing, [S.l.], v.24, n.1, p.289–299, Jan. 2010.

- CASTRO, L. N. D.; TIMMIS, J. Artificial Immune Systems: a new computational intelligence approach. 1st.ed. London: Springer, 2002. 380p.
- CHENG, S.; ZHANG, P.; HABETLER, T. G. An impedance identification approach to sensitive detection and location of stator turn-to-turn faults in a closed-loop multiplemotor drive. **IEEE Transactions on Industrial Electronics**, [S.l.], v.58, n.5, p.1545– 1554, May 2011.
- CHILENGUE, Z.; DENTE, J. A.; BRANCO, P. J. C. An artificial immune system approach for fault detection in the stator and rotor circuits of induction machines. Electric Power Systems Research, [S.l.], v.81, n.1, p.158–169, Jan. 2011.
- CHO, H. C.; KNOWLES, J.; FADALI, M. S.; LEE, K. S. Fault detection and isolation of induction motors using recurrent neural networks and dynamic bayesian modeling. IEEE Transactions on Control Systems Technology, [S.l.], v.18, n.2, p.430–437, Mar. 2010.
- CHOW, M.; YEE, S. Methodology for on-line incipient fault detection in single-phase squirrel-cage induction motors using artificial neural networks. **IEEE Transactions** on Energy Conversion, [S.l.], v.6, n.3, p.536–545, Sept. 1991.
- COCHRAN, W. G. **Statistical methods**. The Iowa State University: Ames, Iowa, 1967. 593p.
- CONCARI, C.; FRANCESCHINI, G.; TASSONI, C. Differential diagnosis based on multivariable monitoring to assess induction machine rotor conditions. **IEEE Transactions on Industrial Electronics**, [S.l.], v.55, n.12, p.4156–4166, Dec. 2008.
- CONCARI, C.; FRANCESCHINI, G.; TASSONI, C. A MCSA procedure to diagnose low frequency mechanical unbalances in induction machines. In: PROCEEDING OF XIX INTERNATIONAL CONFERENCE ON ELECTRICAL MACHINES (ICEM), 2010. Anais... [S.l.: s.n.], 2010. p.1–6.
- CRUZ, S. M. A.; CARDOSO, A. J. M. Stator winding fault diagnosis in three-phase synchronous and asynchronous motors, by the extended Park's vector approach. IEEE Transactions on Industry Applications, [S.l.], v.37, n.5, p.1227–1233, Sept./Oct. 2001.
- CUPERTINO, F.; GIORDANO, V.; MININNO, E.; SALVATORE, L. Application of supervised and unsupervised neural networks for broken rotor bar detection in induction motors. In: PROCEEDING OF IEEE INTERNATIONAL CONFERENCE ON ELEC-TRIC MACHINES AND DRIVES, 2005. Anais... [S.l.: s.n.], 2005. p.1895–1901.

- D'ANGELO, M. F. S. V.; PALHARES, R. M.; TAKAHASHI, R. H. C.; LOSCHI, R. H.; BACCARINI, L. M. R.; CAMINHAS, W. M. Incipient fault detection in induction machine stator-winding using a fuzzy-Bayesian change point detection approach. Applied Soft Computing, [S.l.], v.11, n.1, p.179–192, Jan. 2011.
- DAVIES, A. Handbook of condition monitoring techniques and methodology. 1.ed. [S.l.]: Chapman & Hall, 1998. 561p.
- EBRAHIMI, B. M.; FAIZ, J.; LOTFI-FARD, S.; PILLAY, P. Current signature analysis of induction motor mechanical faults by wavelet packet decomposition. Mechanical Systems and Signal Processing, [S.l.], v.30, p.131–145, 2012.
- FILIPPETTI, F.; FRANCESCHINI, G.; TASSONI, C.; VAS, P. Recent developments of induction motor drives fault diagnosis using AI techniques. IEEE Transactions on Industrial Electronics, [S.l.], v.47, n.5, p.994–1004, 2000.
- FNAIECH, M. A.; BETIN, F.; CAPOLINO, G.-A.; FNAIECH, F. Fuzzy logic and slidingmode controls applied to six-phase induction machine with open phases. IEEE Transactions on Industrial Electronics, [S.l.], v.57, n.1, p.354–364, Jan. 2010.
- FUGAL, D. L. Conceptual Wavelets In Digital Signal Processing: an in-depth, practical approach for the non-mathematician. [S.l.]: Space and Signals Technical Publishing, 2009. 374p.
- GAN, Z.; CHOW, T.; CHAU, W. Clone selection programming and its application to symbolic regression. Expert Systems with Applications, [S.l.], v.36, n.2, p.3996– 4005, Mar. 2009a.
- GAN, Z.; ZHAO, M.-B.; CHOW, T. W. Induction machine fault detection using clone selection programming. Expert Systems with Applications, [S.l.], v.36, n.4, p.8000– 8012, May 2009b.
- GARCIA-ESCUDERO, L.; DUQUE-PEREZ, O.; MORINIGO-SOTELO, D.; PEREZ-ALONSO, M. Robust condition monitoring for early detection of broken rotor bars in induction motors. Expert Systems with Applications, [S.l.], v.38, n.3, p.2653–2660, 2011.
- GHATE, V. N.; DUDUL, S. V. Fault diagnosis of three phase induction motor using neural network techniques. In: SECOND INTERNATIONAL CONFERENCE ON EMERG-ING TRENDS IN ENGINEERING & TECHNOLOGY (ICETET), 2009. Proceedings... [S.l.: s.n.], 2009. n.I, p.922–928.
- GHATE, V. N.; DUDUL, S. V. Optimal MLP neural network classifier for fault detection of three phase induction motor. Expert Systems with Applications, [S.l.], v.37, n.4, p.3468–3481, Apr. 2010.

- GHATE, V. N.; DUDUL, S. V. Cascade neural network based fault classifier for three phase induction motor. IEEE Transactions on Industrial Electronics, [S.l.], v.58, n.5, p.1555–1563, May 2011.
- GOODE, P. Using a neural/fuzzy system to extract heuristic knowledge of incipient faults in induction motors: part ii-application. IEEE Transactions on Industrial Electronics, [S.l.], v.42, n.2, p.139–146, Apr. 1995.
- GOODE, P. V. Using a neural/fuzzy system to extract heuristic knowledge of incipient faults in induction motors. Part I-Methodology. IEEE Transactions on Industrial Electronics, [S.l.], v.42, n.2, p.131–138, Apr. 1995.
- HAJI, M.; TOLIYAT, H. A. Pattern recognition: a technique for induction machines rotor broken bar detection. IEEE Transactions on Energy Conversion, [S.l.], v.16, n.4, p.312–317, Dec. 2001.
- HUANG, X.; HABETLER, T. G.; HARLEY, R. G. Detection of rotor eccentricity faults in a closed-loop drive-connected induction motor using an artificial neural network. IEEE Transactions on Power Electronics, [S.I.], v.22, n.4, p.1552–1559, July 2007.
- JOKSIMOVIC, G. M.; PENMAN, J. The detection of inter-turn short circuits in the stator windings of operating motors. IEEE Transactions on Industrial Electronics, [S.l.], v.47, n.5, p.1078–1084, Oct. 2000.
- KAMINSKI, M.; KOWALSKI, C. T.; ORLOWSKA-KOWALSKA, T. General Regression Neural Networks as rotor fault detectors of the induction motor. In: PROCEEDING OF IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY (ICIT), 2010. Anais... [S.l.: s.n.], 2010. p.1239–1244.
- KANKAR, P. K.; SHARMA, S. C.; HARSHA, S. P. Fault diagnosis of ball bearings using machine learning methods. Expert Systems with Applications, [S.l.], v.38, n.3, p.1876–1886, Mar. 2011.
- KARAKOSE, M.; AYDIN, I.; AKIN, E. The intelligent fault diagnosis frameworks based on fuzzy integral. In: PROCEEDING OF INTERNATIONAL SYMPOSIUM ON POWER ELECTRONICS ELECTRICAL DRIVES AUTOMATION AND MO-TION (SPEEDAM), 2010. Anais... [S.l.: s.n.], 2010. p.1634–1639.
- KARAMI, F.; POSHTAN, J.; POSHTAN, M. Broken bar fault detection in induction motors based on modified winding function. In: IEEE INTERNATIONAL CONFER-ENCE ON CONTROL APPLICATIONS, 2010. Proceedings... [S.l.: s.n.], 2010. p.1951–1956.

- KENNEDY, J. The particle swarm: social adaptation of knowledge. In: PROCEEDING OF IEEE INTERNATIONAL CONFERENCE ON EVOLUTIONARY COMPUTA-TION (ICEC), 1997. Anais... [S.l.: s.n.], 1997. p.303–308.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: PROCEEDING OF INTERNATIONAL CONFERENCE ON NEURAL NETWORKS (ICNN), 1995.Anais... [S.l.: s.n.], 1995. v.3, n.1, p.1942–1948.
- KIANINEZHAD, R.; NAHID-MOBARAKEH, B.; BAGHLI, L.; BETIN, F.; CAPOLINO, G.-A. Modeling and control of six-phase symmetrical induction machine under fault condition due to open phases. **IEEE Transactions on Industrial Electronics**, [S.I.], v.55, n.5, p.1966–1977, May 2008.
- KIM, B.; LEE, K.; YANG, J.; LEE, S. B.; WIEDENBRUG, E. J.; SHAH, M. R. Automated detection of rotor faults for inverter-fed induction machines under standstill conditions. **IEEE Transactions on Industry Applications**, [S.l.], v.47, n.1, p.55–64, Jan./ 2011.
- KOHLER, J. L.; SOTTILE, J.; TRUTT, F. C. Alternatives for assessing the electrical integrity of induction motors. IEEE Transactions on Industry Applications, [S.I.], v.28, n.5, p.1109–1117, Sept./Oct. 1992.
- KUMAR, K. V.; KUMAR, S. S.; PRAVEENA, B.; JOHN, J. P.; PAUL, J. E. Soft computing based fault diagnosis. In: PROCEEDING OF INTERNATIONAL CONFER-ENCE ON COMPUTING COMMUNICATION AND NETWORKING TECHNOLO-GIES (ICCCNT), 2010. Anais... [S.l.: s.n.], 2010. p.1–7.
- LAURENTYS, C. A.; PALHARES, R. M.; CAMINHAS, W. M. Design of an artificial immune system based on Danger Model for fault detection. Expert Systems with Applications, [S.l.], v.37, n.7, p.5145–5152, July 2010.
- LEE, S. B.; YANG, J.; HONG, J.; YOO, J.; KIM, B.; LEE, K.; YU, J.; KIM, M.; LEE, K.; WIEDENBRUG, E. J.; NANDI, S. A new strategy for condition monitoring of adjustable speed induction machine drive systems. **IEEE Transactions on Power Electronics**, [S.l.], v.26, n.2, p.389–398, Feb. 2011.
- LEE, S.; WANG, Y.; SONG, J. Fourier and wavelet transformations application to fault detection of induction motor with stator current. Journal of Central South University of Technology, [S.l.], v.17, n.1, p.93–101, 2010.
- LEITE, D. F.; HELL, M. B.; Costa Jr., P.; GOMIDE, F. Real-time fault diagnosis of nonlinear systems. Nonlinear Analysis: Theory, Methods & Applications, [S.l.], v.71, n.12, p.e2665–e2673, Dec. 2009.

- LI, B.; CHOW, M.-Y.; TIPSUWAN, Y.; HUNG, J. C. Neural-network-based motor rolling bearing fault diagnosis. IEEE Transactions on Industrial Electronics, [S.l.], v.47, n.5, p.1060–1069, Oct. 2000.
- LIVINGSTONE, D. A practical guide to scientific data analysis. [S.l.]: John Wiley and Sons, 2009. 341p.
- MAHAMAD, A. K.; HIYAMA, T. Fault classification performance of induction motor bearing using AI methods. In: PROCEEDING OF 5TH IEEE CONFERENCE ON INDUSTRIAL ELECTRONICS AND APPLICATIONS, 2010. Anais... [S.l.: s.n.], 2010. p.56–61.
- MALLAT, S. A Wavelet Tour of Signal Processing: the sparse way. 3.ed. [S.l.]: Elsevier, 2009. 832p.
- MARTINS, J. F.; PIRES, V. F.; PIRES, A. J. Unsupervised neural-network-based algorithm for an on-line diagnosis of three-phase induction motor stator fault. IEEE Transactions on Industrial Electronics, [S.l.], v.54, n.1, p.259–264, Feb. 2007.
- MATIC, D.; KULIC, F.; PINEDA-SANCHEZ, M.; KAMENKO, I. Support vector machine classifier for diagnosis in electrical machines: application to broken bar. **Expert Systems with Applications**, [S.l.], v.39, n.10, p.8681–8689, Aug. 2012.
- MERRY, R.; STEINBUCH, M. Wavelet Theory and Applications, a Literature Study. [S.l.]: Eindhoven University of Technology, Department of Mechanical Engineering, Control Systems Technology Group, 2005.
- MINI, V.; SETTY, S.; USHAKUMARI, S. Fault detection and diagnosis of an induction motor using fuzzy logic. In: PROCEEDING OF IEEE REGION 8 INTERNATIONAL CONFERENCE ON COMPUTATIONAL TECHNOLOGIES IN ELECTRICAL AND ELECTRONICS ENGINEERING (SIBIRCON), 2010. Anais... [S.l.: s.n.], 2010. n.3, p.459–464.
- NANDI, S.; TOLIYAT, H.; LI, X. Condition monitoring and fault diagnosis of electrical motors - A review. IEEE Transactions on Energy Conversion, [S.l.], v.20, n.4, p.719–729, Dec. 2005.
- NEMEC, M.; DROBNIC, K.; NEDELJKOVIC, D.; FISER, R.; AMBROZIC, V. Detection of broken bars in induction motor through the analysis of supply voltage modulation. IEEE Transactions on Industrial Electronics, [S.l.], v.57, n.8, p.2879–2888, Aug. 2010.
- ONEL, I. Y.; AYÇIÇEK, E.; SENOL, I. An experimental study, about detection of bearing defects in inverter fed small induction motors by Concordia transform. Journal of Intelligent Manufacturing, [S.I.], v.20, n.2, p.243–247, Jan. 2009.

- ONEL, I. Y.; BENBOUZID, E. H. Induction motor bearing failure detection and diagnosis: park and concordia transform approaches comparative study. IEEE/ASME Transactions On Mechatronics, [S.l.], v.13, n.2, p.257–262, Apr. 2008.
- PAWLAK, M.; KOWALSKI, C. Low-cost embedded system for the IM fault detection using neural networks. In: PROCEEDING OF THE XIX INTERNATIONAL CON-FERENCE ON ELECTRICAL MACHINES (ICEM), 2010. Anais... [S.l.: s.n.], 2010. p.1–5.
- PAYNE, B.; BALL, A.; GU, F. Detection and diagnosis of induction motor faults using statistical measures. International Journal of COMADEM, [S.l.], v.2, n.5, p.5–19, Apr. 2002.
- PENMAN, J.; SEDDING, H. G.; LLOYD, B. A.; FINK, W. T. Detection and location of interturn short circuits in the stator windings of operating motors. IEEE Transactions Energy Conversion, [S.l.], v.9, p.652–658, Dec. 1994.
- PEZZANI, C. M.; DONOLO, P. D.; CASTELLINO, A. M.; BOSSIO, G. R.; De Angelo, C. H. A new approach to the Park's vector for broken bars and load oscillation diagnosis on IM. In: INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY (ICIT), 2010. Proceedings... [S.l.: s.n.], 2010. p.1221–1226.
- PIRES, D. F.; PIRES, V. F.; MARTINS, J. F.; PIRES, A. J. Rotor cage fault diagnosis in three-phase induction motors based on a current and virtual flux approach. Energy Conversion and Management, [S.l.], v.50, n.4, p.1026–1032, Apr. 2009.
- PUCHE-PANADERO, R.; PINEDA-SANCHEZ, M.; RIERA-GUASP, M.; ROGER-FOLCH, J.; HURTADO-PEREZ, E.; PEREZ-CRUZ, J. Improved resolution of the MCSA method via Hilbert transform, enabling the diagnosis of rotor asymmetries at very low slip. **IEEE Transactions on Energy Conversion**, [S.l.], v.24, n.1, p.52–59, Mar. 2009.
- RADHIKA, S.; SABAREESH, G.; JAGADANAND, G.; SUGUMARAN, V. Precise wavelet for current signature in 3/IM. Expert Systems with Applications, [S.l.], v.37, n.1, p.450–455, Jan. 2010.
- RAZIK, H.; CORREA, M. B. R.; SILVA, E. R. C. da. A novel monitoring of load level and broken bar fault severity applied to squirrel-cage induction motors using a genetic algorithm. **IEEE Transactions on Industrial Electronics**, [S.l.], v.56, n.11, p.4615– 4626, Nov. 2009.
- RAZIK, H.; CORREA, M. B. R.; SILVA, E. R. C. da. The tracking of induction motor's faulty lines through particle swarm optimization using chaos. In: PROCEEDING

OF IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY (ICIT), 2010. Anais... [S.l.: s.n.], 2010. n.2, p.1245–1250.

- RIERA-GUASP, M.; CABANAS, M. F.; ANTONINO-DAVIU, J. a.; PINEDA-SáNCHEZ, M.; GARCÍA, C. H. R. Influence of nonconsecutive bar breakages in motor current signature analysis for the diagnosis of rotor faults in induction motors. IEEE Transactions on Energy Conversion, [S.l.], v.25, n.1, p.80–89, Mar. 2010.
- RODRIGUEZ, P. V. J.; ARKKIO, A. Detection of stator winding fault in induction motor using fuzzy logic. Applied Soft Computing, [S.l.], v.8, n.2, p.1112–1120, Mar. 2008.
- ROMERO-TRONCOSO, R. J.; SAUCEDO-GALLAGA, R.; CABAL-YEPEZ, E.; GARCIA-PEREZ, A.; OSORNIO-RIOS, R. A.; ALVAREZ-SALAS, R.; MIRANDA-VIDALES, H.; HUBER, N. FPGA-based online detection of multiple combined faults in induction motors through information entropy and fuzzy inference. **IEEE Transac**tions on Industrial Electronics, [S.l.], v.58, n.11, p.5263–5270, Nov. 2011.
- SADEGHIAN, A.; YE, Z.; WU, B. Online detection of broken rotor bars in induction motors by wavelet packet decomposition and artificial neural networks. IEEE Transactions on Instrumentation and Measurement, [S.l.], v.58, n.7, p.2253–2263, July 2009.
- SAMANTA, B.; NATARAJ, C. Use of particle swarm optimization for machinery fault detection. Engineering Applications of Artificial Intelligence, [S.l.], v.22, n.2, p.308–316, Mar. 2009.
- STEVENSON JR., W. D. Elementos de Análise de Sistemas de Potência. [S.l.]: McGraw-Hill, 1986.
- SU, H.; CHONG, K. T. Induction machine condition monitoring using neural network modeling. IEEE Transactions on Industrial Electronics, [S.l.], v.54, n.1, p.241– 249, Feb. 2007.
- SUETAKE, M. Sistemas inteligentes para monitoramento e diagnósticos de falhas em motores de indução trifásicos. 2012. Tese de Doutorado — Universidade de São Paulo (EESC-USP).
- TALLAM, R. M.; HABETLER, T. G.; HARLEY, R. G. Stator winding turn-fault detection for closed-loop induction motor drives. IEEE Transactions on Industry Applications, [S.l.], v.39, n.3, p.720–724, May 2003.
- TAN, W. W.; HUO, H. A generic neurofuzzy model-based approach for detecting faults in induction motors. IEEE Transactions on Industrial Electronics, [S.l.], v.52, n.5, p.1420–1427, Oct. 2005.

- THOMSON, W. T.; FENGER, M. Current signature analysis to detect induction motor faults. IEEE Industry Applications Magazine, [S.l.], v.7, n.4, p.26–34, July/Aug. 2001.
- TRAN, V.; YANG, B.; OH, M.; TAN, A. Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference. Expert Systems with Applications, [S.l.], v.36, n.2, p.1840–1849, Mar. 2009.
- TRZYNADLOWSKI, A. M. Control of Induction Motors. 1st.ed. University of Nevada, Reno, U.S.A.: Academic Press, 2001. 228p.
- UDDIN, M. N.; WANG, W.; HUANG, Z. R. Modeling and minimization of speed ripple of a faulty induction motor with broken rotor bars. IEEE Transactions on Industry Applications, [S.l.], v.46, n.6, p.2243–2250, Nov. 2010.
- VAS, P. Artificial-Intelligent-Based Electrical Machines and Drives: application of fuzzy, neural, fuzzy-neural and genetic-algorithm-based techniques. New York: Oxford University Press, 1999. 625p.
- VIDAKOVIC, B.; MUELLER, P. Wavelets for kids: a tutorial introduction. [S.l.]: Duke University, 1991.
- WOLBANK, T. M.; NUSSBAUMER, P.; CHEN, H.; MACHEINER, P. E. Monitoring of rotor-bar defects in inverter-fed induction machines at zero load and speed. IEEE Transactions on Industrial Electronics, [S.l.], v.58, n.5, p.1468–1478, May 2011.
- WU, S.; CHOW, T. Induction machine fault detection using SOM-based RBF neural networks. IEEE Transactions on Industrial Electronics, [S.l.], v.51, n.1, p.183– 194, Feb. 2004.
- XU, Z.; XUAN, J.; SHI, T.; WU, B.; HU, Y. A novel fault diagnosis method of bearing based on improved fuzzy ARTMAP and modified distance discriminant technique.
 Expert Systems with Applications, [S.I.], v.36, n.9, p.11801–11807, Nov. 2009.
- YAN, J.; LU, L.; ZHAO, D.; WANG, G. Diagnosis of bearing incipient faults using fuzzy logic based methodology. In: PROCEEDING OF SEVENTH INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS AND KNOWLEDGE DISCOVERY, 2010. Anais... [S.l.: s.n.], 2010. p.1229–1233.
- YANG, D.-M. The application of artificial neural networks to the diagnosis of induction motor bearing condition using Hilbert-based bispectral analysis. In: PROCEEDING OF 5TH IEEE CONFERENCE ON INDUSTRIAL ELECTRONICS AND APPLICA-TIONS, 2010. Anais... [S.l.: s.n.], 2010. n.2, p.1730–1735.

- YE, Z.; WU, B.; SADEGHIAN, A. Current signature analysis of induction motor mechanical faults by wavelet packet decomposition. IEEE Transactions on Industrial Electronics, [S.l.], v.50, n.6, p.1217–1228, 2003.
- ZADEH, L. Fuzzy sets. Information and Control, [S.l.], v.8, n.3, p.338–353, June 1965.
- ZAREI, J. Induction motors bearing fault detection using pattern recognition techniques. Expert Systems with Applications, [S.l.], v.39, n.1, p.68–73, Jan. 2012.
- ZHANG, L.; XIONG, G.; LIU, H.; ZOU, H.; GUO, W. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference. Expert Systems with Applications, [S.1.], v.37, n.8, p.6077–6085, Aug. 2010.
- ZIDANI, F.; El Hachemi Benbouzid, M.; DIALLO, D.; NAIT-SAID, M. Induction motor stator faults diagnosis by a current concordia pattern-based fuzzy decision system. IEEE Transactions on Energy Conversion, [S.l.], v.18, n.4, p.469–475, Dec. 2003.
- ZOUZOU, S.; LAALA, W.; GUEDIDI, S.; SAHRAOUI, M. A fuzzy logic approach for the diagnosis of rotor faults in squirrel cage induction motors. In: PROCEEDING OF SECOND INTERNATIONAL CONFERENCE ON COMPUTER AND ELEC-TRICAL ENGINEERING (ICCEE), 2009. Anais... [S.l.: s.n.], 2009. p.173–177.

Apêndice

Apêndice A

Aspectos dos Procedimentos Experimentais de Bancada

A.1 Montagem e Composição da Bancada

A bancada de hardware responsável em gerar os ensaios foi constituída por uma máquina de indução trifásica; uma Máquina de Corrente Contínua (MCC), a qual atua como gerador; um *encoder*; um torquímetro; um quadro de comando; um circuito de alimentação da bobina de campo do Gerador de Corrente Contínua (GCC), cuja carga é conectada à bobina de armadura; e os circuitos ligados à placa de aquisição de dados, a qual está localizada em um computador. No quadro de comando podem ser realizados o ajuste da tensão aplicada no motor de indução, as escolhas do tipo de acionamento (estrela ou triângulo) e do tipo de alimentação (tensão direta da rede ou inversor trifásico). A Figura A.1 ilustra a disposição de todos os hardwares que compõem a bancada.

O MIT utilizado neste trabalho caracteriza-se por ser um motor da linha *standard*, 1,0 cv, 220V/380V, 3,02A/1,75A, 4 pólos, 60 Hz, 4,1 Nm e velocidade nominal de 1715 rpm. Já a MCC consiste de uma máquina de 2 kW de potência, 190 V de tensão nominal de campo e 250 V de tensão nominal de armadura. O *encoder* óptico incremental apresenta uma resolução de 2000 pulsos por rotação, com a função de medir a velocidade angular do MIT. Os dados gerados pelo *enconder* não foram considerados na identificação das falhas, porém a sua aferição foi essencial para o monitoramento do estado de funcionamento do MIT.

O eixo da MCC, também visto como gerador, está acoplado ao MIT por intermédio de um torquímetro rotativo. O GCC é responsável pela simulação experimental de uma determinada carga acoplada ao eixo do MIT, uma vez que o torque resistente imposto pelo gerador pode ser alterado, conforme a variação da tensão do enrolamento de campo. O ajuste manual do torque de carga é realizado por meio da variação da tensão dos terminais do variador de tensão (*variac*), o qual é ilustrado pela Figura A.2(a).

O sensor Hall de corrente utilizado na bancada de experimentos é o LAH-25 NP do



Figura A.1: Esquema geral do laboratório de ensaios de máquinas elétricas.

fabricante LEM. A corrente nominal deste dispositivo é de 25 A. O condicionamento de sinal é realizado utilizando-se o amplificador operacional TL081 com ajuste de *offset*. O sensor Hall de corrente é ilustrado na Figura A.2(b).



Figura A.2: Imagens de um Variac e de sensores Hall.

O sistema de aquisição de dados é de suma importância para efetuar análises e validação dos ensaios experimentais. O laboratório de pesquisa é equipado por uma placa de aquisição de dados que dispõe de uma quantidade de canais analógicos suficientes para aferição de diversos sinais envolvidos nos ensaios realizados. A Figura A.3(a) ilustra a placa de aquisição de dados da *National Instruments* (modelo NIDAQmx PCIe-6259). As principais características do NIDAQmx PCIe-6269 consistem na presença de 32 canais analógicos de entrada de 16 bits, com taxa de aquisição de 1,25 mega-amostras por segundo; 4 canais analógicos de saída de 16 *bits*, com taxa de 2,8 mega-amostras por segundo, e 48 canais de I/O digitais com capacidade de operar na frequência de *clock* de até 10 MHz.

A placa NIDAQmx PCIe-6259 é conectada no barramento PCI-*Express* do computador. As interconexões com os dispositivos externos são realizadas por um bloco conector SCB-68 ilustrado na Figura A.3(b). Em tal bloco, além da interface de conexões relativas a todas as portas analógicas e digitais, permite-se também a implementação de filtros de sinais em hardware.



(a) Placa de aquisição de dados da *National In*struments (NIDAQmx PCIe-6259).

(b) Bloco de conexões SCB-68.

Figura A.3: Sistema de aquisição de dados.

A.2 As Falhas Elétricas do Motor de Indução Trifásico

Perante a infra-estrutura da bancada de hardware montada para realização dos testes em motores elétricos, foram preparados alguns rotores e motores para simular as falhas elétricas que serão analisadas pelo sistema inteligente de diagnóstico. A base de dados formada por sinais elétricos das três correntes que alimentam o MIT, armazenará as informações que serão fornecidas ao sistema. Assim, a partir dos sinais aferidos do MIT, foram analisados as seguintes falhas:

- □ barras seccionadas do rotor;
- □ curto-circuito no enrolamento do estator;

Para seccionar as barras do rotor foi utilizado uma broca de dimensão 6,0 mm, que é suficientemente maior que a largura da barra. A Figura A.4(a) ilustra a imagem do momento em que o rotor estava sendo perfurado. Foram realizados três tipos de perfurações: rotor com uma barra seccionada, rotor com duas barras seccionadas e rotor com quatro barras seccionadas.

A Figura A.4(b) ilustra com mais nitidez o orifício seccionado de uma das barras da gaiola de esquilo. A Figura A.4(c) ilustra a imagem de um rotor com duas barras seccionadas. A Figura A.4(d) ilustra um rotor sem falhas.



(a) Processo de seccionamento da barra da gaiola.



(c) Imagem de duas barras seccionadas.



(b) Imagem da barra seccionada.



(d) Imagem de barra sem falha.

Figura A.4: Procedimento para a inserção de falhas em rotores.

Os ensaios experimentais foram conduzidos mediante sucessivas substituições de rotores defeituosos. Este procedimento deve ser cuidadosamente realizado por meio da montagem\desmontagem do MIT, a fim de não danificar e\ou desalinhar a sua estrutura física.

Em relação as falhas do enrolamento do estator num motor de indução de baixa tensão, podem ser classificadas em: curto-circuito entre bobinas da mesma fase, curto-circuito entre bobinas de diferentes fases e curto-circuito entre as bobinas das três fases. A Figura A.5 exemplifica o arranjo de bobinas do estator de um motor de 4 pólos com 36 ranhuras do estator. As bobinas em vermelho representam os enrolamentos da fase a e as bobinas em azul e verde indicam os enrolamentos das fases b e c, respectivamente.
A ocorrência de falhas entre bobinas da mesma fase é maior, devido as bobinas estarem alocadas na mesma ranhura. Ou seja, o aumento da temperatura resultante das condições de funcionamento do MIT pode ocasionar degradação da isolação e provocar o curtocircuito.

As bobinas de fases distintas não compartilham a mesma ranhura, assim a taxa de ocorrência de curto-circuito nesta situação é menor. No entanto, esta falha é possível de surgir no caminho entre uma ranhura e outra.

A probabilidade de ocorrência de falhas entre as três fases simultaneamente é mínima, como pode ser deduzido pela Figura A.5, pois não há pontos em comum entre as três fases. Eventualmente, esta falha pode ocorrer em pontos onde os terminais de acesso aos enrolamentos são levados para a caixa de alimentação.



Figura A.5: Disposição das bobinas ao longo das ranhuras do estator.

Em conformidade com essas observações, projetaram-se então as derivações do enrolamento do estator para efetuar os ensaios de curto-circuito entre as bobinas, conforme ilustrado na Figura A.6. Cada fase é representada por seis bobinas que estão alocadas em seis ranhuras. As derivações são realizadas nos pontos intermediários e das extremidades das bobinas situadas em cada ranhura.



Figura A.6: Derivações do enrolamento do estator nos ensaios de curto-circuito.

Assim sendo, foram preparadas falhas entre bobinas de uma mesma fase. A Figura A.7 ilustra as fotos das derivações dos pontos de curto-circuito realizadas no MIT. A adaptação dos enrolamentos do estator foi realizada por uma empresa de manutenção de motores de indução situada na cidade de São Carlos - SP.



Figura A.7: Foto ilustrativa dos terminais de derivação.