

**UNESP – UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA DE BAURU
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

NELSON MEDEIROS DA SILVA FILHO

**DIAGNÓSTICO DE DEFEITOS EM ESTADORES DE MOTORES DE
INDUÇÃO TRIFÁSICOS POR MEIO DE SENSORES PIEZELÉTRICOS
DE BAIXO CUSTO E REDES NEURAS ARTIFICIAIS**

**BAURU - SP
2017**

NELSON MEDEIROS DA SILVA FILHO

**DIAGNÓSTICO DE DEFEITOS EM ESTADORES DE MOTORES DE
INDUÇÃO TRIFÁSICOS POR MEIO DE SENSORES PIEZELÉTRICOS
DE BAIXO CUSTO E REDES NEURAIAS ARTIFICIAIS**

Dissertação apresentada à Faculdade de Engenharia de Bauru, como requisito para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. José Alfredo Covolan Ulson

Coorientador: Prof. Dr. Renato Crivellari Creppe

**BAURU - SP
2017**

Silva Filho, Nelson Medeiros da.

Diagnóstico de defeitos em estatores de motores de indução trifásicos por meio de sensores piezelétricos de baixo custo e redes neurais artificiais / Nelson Medeiros da Silva Filho, 2017

127 f. : il.

Orientador: José Alfredo Covolan Ulson

Coorientador: Renato Crivellari Creppe

Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2017

1. Motor de indução trifásico. 2. Diagnóstico de falhas. 3. Redes neurais artificiais. 4. Diafragmas piezelétricos de baixo custo. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE Mestrado de NELSON MEDEIROS DA SILVA FILHO, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 29 dias do mês de setembro do ano de 2017, às 15:00 horas, no(a) Sala de reuniões do Departamento de Engenharia Elétrica, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. JOSE ALFREDO COVOLAN ULSO - Orientador(a) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. RUDOLF RIBEIRO RIEHL do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru, Prof. Dr. CAIO CÉSAR OBA RAMOS do(a) Departamento de Engenharia Mecatrônica / Instituto Federal Catarinense, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE Mestrado de NELSON MEDEIROS DA SILVA FILHO, intitulada **DIAGNÓSTICO DE DEFEITOS EM ESTADORES DE MOTORES INDUÇÃO TRIFÁSICOS POR MEIO DE SENSORES PIEZELÉTRICOS DE BAIXO CUSTO E REDES NEURAIS ARTIFICIAIS**. Após a exposição, o discente foi arguido oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: APROVADO. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.



Prof. Dr. JOSE ALFREDO COVOLAN ULSO



Prof. Dr. RUDOLF RIBEIRO RIEHL



Prof. Dr. CAIO CÉSAR OBA RAMOS

Dedicatória

Dedico este trabalho aos meus pais, Nelson e Zilda (*in memoriam*), por todo amor e carinho dedicados a mim.

Agradecimentos

Gostaria de agradecer primeiramente e sobretudo a Deus, por me dar forças e perseverança para concluir essa etapa em minha vida.

Ao professor Dr. José Alfredo Covolan Ulson pela orientação e apoio nos diversos momentos de dificuldade.

Ao professor Dr. Renato Crivellari Creppe pela coorientação, pelo apoio na montagem da bancada de ensaios e pelos conselhos durante este período.

Ao professor Dr. André Luiz Andreoli pelo importante apoio para realização dos ensaios, realizando as modificações necessárias no motor utilizado, e pelos comentários construtivos durante a etapa de qualificação.

Ao professor Dr. Rudolf Ribeiro Riehl por aceitar o convite para compor minhas bancas de qualificação e defesa de dissertação, pelos apontamentos e sugestões importantes para melhoria do trabalho.

Ao professor Dr. Caio César Oba Ramos, pelos esclarecimentos técnicos nas conversas durante o desenvolvimento desse trabalho e por aceitar o convite para compor minha banca de defesa de dissertação.

Agradeço a minha esposa Michely Fernanda Mantovani da Silva, pela paciência e apoio nos momentos difíceis e atribulados, que implicavam muitas vezes na falta de tempo dedicado à família.

Ao grande amigo de laboratório de pesquisa Guilherme Marabezzi Clerice, pessoa de grande caráter, agradeço imensamente não apenas pelos conselhos e esclarecimentos de dúvidas técnicas, mas principalmente pelo apoio nos momentos difíceis e pela ajuda imprescindível para a realização desse trabalho.

Aos professores e funcionários do Departamento de Engenharia Elétrica, e aos funcionários da Sessão Técnica de Pós-Graduação da Unesp de Bauru.

Agradeço aos meus amigos de trabalho do Departamento de Engenharia Elétrica da FEB/UNESP, os técnicos de laboratório Edson, Helton, Manoel e Osmar, pela ajuda e companheirismo.

Por fim, agradeço à todos as pessoas que contribuíram de alguma forma para que eu obtivesse êxito na realização desse trabalho.

RESUMO

O Motor de Indução Trifásico (MIT) é o mais utilizado em aplicações industriais e acionamentos eletromecânicos diversos, por ser um motor de construção robusta, ter baixo custo de fabricação e bom rendimento elétrico. Nesse cenário, destaca-se a importância de um correto diagnóstico de falhas de uma forma incipiente, evitando perdas nos processos produtivos e danos severos nessas máquinas. A estratégia da manutenção corretiva impõe, nos processos produtivos, paradas inesperadas da linha de produção podendo causar grandes prejuízos financeiros. Nesse contexto, a manutenção preditiva, auxiliada por sistemas de monitoramento constante, vem de encontro as necessidades dos processos industriais pois, além de prever paradas inesperadas, permite um planejamento da produção mais seguro, no que tange a continuidade do processo e administração da equipe de manutenção especializada. Entretanto, requer monitoramento constante com uma análise dos dados e conhecimento prévio do sistema para a avaliação dos parâmetros e das variáveis envolvidas. Esse trabalho de pesquisa propôs o desenvolvimento de uma abordagem para diagnosticar defeitos em MIT, por meio de diafragmas piezelétricos de baixo custo e sistemas inteligentes do tipo Redes Neurais Artificiais (RNA). Mais especificamente, defeitos elétricos do tipo curto-circuito entre espiras de uma mesma bobina nos estatores dessas máquinas. Para tal, foi implementada uma bancada experimental em ambiente de laboratório, onde foram realizados ensaios com simulações de falhas relacionadas a curto-circuito entre espiras das bobinas do enrolamento do estator, visando a obtenção de dados de corrente elétrica e vibração do MIT, para o treinamento das arquiteturas de RNA. Em seguida essas redes foram treinadas e validadas, e a análise dos resultados obtidos foi realizada através de critérios estatísticos como taxa de acerto percentual, erro relativo percentual, desvio padrão e coeficiente de correlação entre os dados. Os resultados indicam que a abordagem proposta mostrou-se precisa e robusta, sinalizando a factibilidade do uso da técnica em motores de maior potência e tensão elétrica de operação, que possuem valores de custo para aquisição relativamente altos.

Palavras-chave: Motor de Indução Trifásico. Diagnóstico de falhas. Redes Neurais Artificiais. Diafragmas piezelétricos de baixo custo.

ABSTRACT

The three-phase induction motor (MIT) is the most widely used in industrial applications and various electromechanical drives, as it is a robust construction engine, low manufacturing cost and good electrical performance. In this scenario, the importance of a correct fault diagnosis in an incipient way is highlighted, avoiding losses in the productive processes and severe damages in these machines. The strategy of corrective maintenance imposes, in the productive processes, unexpected stops of the production line and can cause great financial losses. In this context, the predictive maintenance, aided by constant monitoring systems, meets the needs of industrial processes because, in addition to anticipating unexpected stops, it allows a safer production planning regarding the continuity of the process and administration of the maintenance team specialized. However, it requires constant monitoring with an analysis of the data and prior knowledge of the system for the evaluation of the parameters and variables involved. This research project proposed the development of an approach to diagnose defects in MIT, through low cost piezoelectric diaphragms and intelligent artificial neural networks (ANNs). More specifically, short-circuit electrical defects between turns of the same coil in the stators of these machines. For this, an experimental bench was implemented in a laboratory environment, where tests were performed with fault simulations related to short circuits between turns of the coils of the stator winding, aiming to obtain data of electrical current and vibration of the MIT for the training of ANN architectures. Afterwards, these networks were trained and validated, and the analysis of the results obtained was performed through statistical criteria such as percentage success rate, relative percentage error, standard deviation and correlation coefficient between the data. The results indicated that the proposed approach proved to be accurate and robust, signaling the feasibility of using the technique in engines with higher power and operating voltage, which have relatively high acquisition cost values.

Keywords: Three Phase Induction Motor. Troubleshooting. Artificial neural networks. Low cost piezoelectric diagrams.

LISTA DE FIGURAS

Figura 1 – Evolução do aspecto construtivo do MIT e seu rendimento, na análise da relação peso/potência	16
Figura 2 – Demonstração da evolução dos conceitos de manutenção	24
Figura 3 – Modelos de MIT comumente encontrados no mercado	27
Figura 4 – Aspecto construtivo com estrutura básica de um MITRGE	28
Figura 5 – Classificação das falhas presentes em MIT	30
Figura 6 – Danos na camada de isolante do condutor elétrico (imagem aumentada de um fio de cobre) devido a sobreaquecimento.....	32
Figura 7 – Características das possíveis falhas elétricas em estatores de MIT	33
Figura 8 – Características físicas de algumas avarias em enrolamentos de estatores	35
Figura 9 – Representação gráfica da resultante do vetor de Park para um motor simétrico (a) e para um motor com defeito no estator (b).....	39
Figura 10 – Imagem termográfica de um motor em regime de trabalho.....	40
Figura 11 – Principais níveis para medição da amplitude de vibração	44
Figura 12 – Estrutura interna durante o processo de formação da piezeletricidade..	45
Figura 13 – Construção do diafragma piezelétrico de baixo custo	47
Figura 14 – Sistema de oscilação da membrana piezelétrica de baixo busto	48
Figura 15 – Representação organizacional dos sistemas inteligentes	50
Figura 16 – Modelo de neurônio artificial	52
Figura 17 – Representação das principais funções de ativação	54
Figura 18 – Arquitetura das redes neurais artificiais	55
Figura 19 – Configuração da rede Perceptron Multicamadas	56
Figura 20 – Fases <i>Forward</i> e <i>Backward</i> em uma rede PMC.....	57
Figura 21 – Diagrama esquemático do sistema proposto implementado para os ensaios com o MIT	62
Figura 22 – Especificações técnicas do Motor de Indução trifásico utilizado na pesquisa.....	63
Figura 23 – Etapas do processo de modificação do estator do MIT.....	64
Figura 24 – Aspecto construtivo final do MIT após rebobinamento e montagem.....	64
Figura 25 – Representação das conexões das bobinas modificadas.....	65

Figura 26 – Disposição final dos bornes de acesso as derivações para ligações dos taps	66
Figura 27 – Visão geral da bancada de ensaios montada em laboratório.....	67
Figura 28 – Especificações Técnicas da Fonte de Alimentação Trifásica.....	68
Figura 29 – Especificações Técnicas da Máquina de Corrente Contínua.....	69
Figura 30 - Curva Torque x Velocidade característica de um MIT	69
Figura 31 – Especificações Técnicas do Tacômetro para aferição da velocidade do MIT	70
Figura 32 – Especificações Técnicas do Transformador Variador de Tensão	70
Figura 33 – Especificações Técnicas do Multímetro Digital	71
Figura 34 – Especificações Técnicas do Banco Resistivo utilizado como carga para MCC	71
Figura 35 – Impedâncias resistivas utilizadas nas simulações das falhas de curto-circuito controladas	73
Figura 36 – Aspecto construtivo do diafragma piezelétrico de baixo custo utilizado ..	74
Figura 37 – Disposição da fixação dos diafragmas piezelétricos no MIT	74
Figura 38 – Pontos normatizados para medição de vibração em MIT	75
Figura 39 – Diagrama eletrônico do circuito amplificador para sinais dos diafragmas piezelétricos	76
Figura 40 – Reprodução gráfica da placa de circuito impresso com oito amplificadores INA128P.....	77
Figura 41 – Especificações Técnicas do Sensor de Corrente.....	77
Figura 42 – Especificações do Oscilógrafo Digital	78
Figura 43 – Instrumentação utilizada para aquisição dos sinais de corrente elétrica, vibração e tensão	78
Figura 44 – Etapas metodológicas adotadas para o desenvolvimento da pesquisa ..	79
Figura 45 – Aquisição simultânea dos sinais de corrente elétrica e vibração do motor.	80
Figura 46 – Formas de onda dos sinais de corrente elétrica do MIT.....	83
Figura 47 – Formas de onda dos sinais de vibração dos PZT dianteiros.....	84
Figura 48 – Formas de onda dos sinais de vibração dos PZT traseiros.....	84
Figura 49 – Exemplo de seleção do janelamento sobre o sinal periódico para aplicação do critério RMS.....	85

Figura 50 – Evolução do desempenho do erro de treinamento e teste para RNA-PMC (40).....	96
Figura 51 – Histograma de Erros médios para RNA-PMC (40).....	97
Figura 52 – Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para a RNA-PMC (40) – ROTEIRO I.....	98
Figura 53 – Orientação global dos dados de teste para a RNA-PMC (40) – ROTEIRO I.....	99
Figura 54 – Média da Dispersão dos dados para valores estimados x desejados para RNA PMC (40) ROTEIRO I.....	99
Figura 55 – Evolução do desempenho do erro de treinamento e teste para RNA-PMC (15 15 15) ROTEIRO II.....	101
Figura 56 – Histograma de Erros médios para RNA-PMC (15 15 15) ROTEIRO II.....	102
Figura 57 – Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para a RNA-PMC (15 15 15) – ROTEIRO II.....	103
Figura 58 – Orientação global dos dados de teste para a RNA-PMC (15 15 15) – ROTEIRO II.....	104
Figura 59 – Média da Dispersão dos dados para valores estimados x desejados para RNA PMC (15 15 15) ROTEIRO II.....	104
Figura 60 – Evolução do desempenho do erro de treinamento e teste para RNA RBF (0.6) ROTEIRO III.....	106
Figura 61 – Histograma de Erros médios para RNA-RBF (0.6) ROTEIRO III.....	107
Figura 62 – Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para a RNA-RBF(0.6) – ROTEIRO III.....	108
Figura 63 – Orientação global dos dados de teste para a RNA-RBF(0.6) – ROTEIRO III.....	109
Figura 64 – Média da dispersão dos dados para valores das falhas estimados x desejados para RNA RBF (0.6) ROTEIRO III.....	109
Figura 65 – Evolução do desempenho do erro de treinamento e teste para RNA RBF (0.2) - ROTEIRO IV.....	111
Figura 66 – Histograma de Erros médios para RNA-RBF (0.2) ROTEIRO IV.....	112

Figura 67 – Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para RNA RBF (0.2)	113
Figura 68 – Orientação global dos dados de teste para a RNA-RBF (0.2) – ROTEIRO IV	114
Figura 69 – Média da dispersão para a rede RBF (0.2) ROTEIRO IV.....	114
Figura 70 – Gráfico comparativo de desempenho entre as RNA com melhores taxas de acerto (%).....	115

LISTA DE TABELAS

Tabela 1 – Distribuição das falhas nos MIT de acordo com a origem	20
Tabela 2 - Funções de Base Radial mais comuns	59
Tabela 3 – Metodologia para realização das simulações de falhas de curto-circuito durante os ensaios	81
Tabela 4 – Tabela com parcial do conjunto de dados dos Vetores de Entrada de treinamento da rede	86
Tabela 5 – Nomenclatura dos sinais de entrada utilizados para alimentação das RNA	87
Tabela 6 – Roteiro de treinamento para topologias de rede PMC utilizando todas as entradas de sinais	89
Tabela 7 – Roteiro de treinamento para topologias de rede PMC utilizando entradas de sinais dos PZT	90
Tabela 8 – Roteiro de treinamento para topologia de rede RBF utilizando todas as entradas de sinais	91
Tabela 9 – Roteiro de treinamento para topologias de rede RBF utilizando entradas de sinais dos PZT	91
Tabela 10 – Resultados obtidos para treinamento e validação do ROTEIRO I.....	95
Tabela 11 – Resultados obtidos para treinamento e validação do ROTEIRO II.....	100
Tabela 12 – Resultados obtidos para treinamento e validação do ROTEIRO III.....	105
Tabela 13 – Resultados obtidos para treinamento e validação do ROTEIRO IV	110

LISTAS DE ABREVIATURA E SIGLAS

IA	Inteligência Artificial
AG	Algoritmos Genéticos
DpERM	Desvio padrão do erro relativo médio
EAM	Erro absoluto médio
EPRI	<i>Electric Power Research Institute</i>
EPVA	<i>Extend Park's Vector Approach</i>
EQM	Erro quadrático médio
ERM	Erro relativo médio
FMM	Força magnetomotriz
Hz	Hertz
IEC	<i>International Electrotechnical Commission</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
LF	Logica Fuzzy
ms	Milissegundo
MCC	Máquina de Corrente Contínua
MCSA	<i>Motor Current Signature Analysis</i>
MS/s	<i>Mega samples por segundo</i>
MIT	Motor de Indução Trifásico
MITRGE	Motor de Indução Trifásico Tipo Rotor Gaiola de Esquilo
LAQEE	Laboratório de Qualidade de Energia Elétrica
PMC	<i>Perceptron Multicamadas</i>
PZT	Titanato Zirconato de Chumbo
RBF	<i>Radial Base Function</i>
REQM	Raiz do erro quadrático médio
RMS	<i>Root Mean Square</i>
RNA	Redes neurais artificiais
SI	Sistemas Inteligentes
µs	Microsegundo

SUMÁRIO

1	CONSIDERAÇÕES INICIAIS	15
1.1	Motivação e relevância do trabalho	15
1.2	Justificativa e objetivo	18
1.3	Publicações científicas relacionadas	22
2	REVISÃO BIBLIOGRÁFICA E CONCEITUAL	23
2.1	Conceitos de manutenção e evolução histórica	23
2.2	Classificação das atividades de manutenção industrial	24
2.3	Motores elétricos de indução trifásicos (MIT)	26
2.4	Aspectos construtivos e características funcionais	27
2.5	Tipos de falhas em motores de indução trifásicos	30
2.6	Análise de falhas em estatores de MIT	31
2.7	Técnicas de Análise de Vibrações em MIT	42
2.8	Características da piezeletricidade	45
2.9	Sensores piezelétricos de baixo custo	46
2.10	Sistemas Computacionais Inteligentes	48
2.11	Redes Neurais Artificiais	50
3	MATERIAIS UTILIZADOS E METODOLOGIA PROPOSTA	62
3.1	Preparação do MIT para inserção de simulação de falhas	63
3.2	Montagem da bancada de ensaios proposta	66
3.3	Sistema de aquisição, amplificação e condicionamento dos sinais	76
3.4	Processamento dos sinais	83
3.5	Critérios para treinamento das Redes Neurais Artificiais	87
3.6	Critérios para validação das RNAS	92
4	RESULTADOS E DISCUSSÕES	94
4.1	Resultados das RNA PMC para classificação das falhas utilizando sinais de corrente elétrica e vibração – ROTEIRO I	94
4.2	Resultados das RNA PMC para classificação das falhas utilizando sinais de vibração – ROTEIRO II	100
4.3	Resultados das RNA RBF para classificação das falhas utilizando sinais de corrente elétrica e vibração – ROTEIRO III	105
4.4	Resultados das RNA RBF para classificação das falhas utilizando sinais de vibração – ROTEIRO IV	110
4.5	Análise comparativa entre os resultados fornecidos pelas RNA	115
5	CONCLUSÕES	117
5.1	Sugestões para trabalhos futuros	119
	REFERÊNCIAS	120

1 CONSIDERAÇÕES INICIAIS

1.1 Motivação e relevância do trabalho


Nos dias atuais, pode-se afirmar que a dependência da energia elétrica pela população mundial nunca se fez tão grande. Trata-se de uma sociedade cada vez mais consumista dessa forma de energia, principalmente no que tange ao caráter tecnológico e industrial. Nesse contexto, os motores elétricos desempenham o papel de protagonista na questão do avanço crescente do aumento do consumo de energia elétrica dos processos produtivos, pois são o principal instrumento de conversão de energia elétrica em energia mecânica motriz, gerando torque e movimento (SUETAKE, 2012).

Dentre os tipos de motores elétricos existentes, o Motor de Indução Trifásico (MIT) é o mais utilizado nas aplicações industriais, mais especificamente o Motor de Indução Trifásico Tipo Rotor Gaiola de Esquilo (MITRGE). Estudos estimam que esse modelo representa 90% dos motores elétricos em atividade no mundo, sendo o dispositivo responsável pelo maior consumo de energia elétrica dentro da sociedade industrial moderna (TOLIYAT *et al*, 2012; TRZYNADLOWSKI, 2001). Estes motores se destacam devido ao fato de serem máquinas de construção robusta, longa vida útil, baixo custo de fabricação e aquisição, métodos de acionamento simples, possibilidades de emprego de variadores de velocidade eletrônicos como inversores de frequência, versatilidade de utilização e boas características de funcionamento (BELLINI *et al*, 2008; GOEDEL, 2007; SUETAKE, 2012). Soma-se a isso outra grande vantagem: seu aspecto construtivo, onde a eliminação de contatos elétricos deslizantes de construção simples, o que possibilita um custo mais baixo, sendo estas máquinas fabricadas para uma grande variedade de aplicações (FITZGERALD *et al*, 2008; TOLIYAT *et al*, 2012).

A evolução tecnológica, principalmente no campo da ciência dos materiais, permitiu um grande avanço nas técnicas de produção do MIT, possibilitando que estes ficassem mais leves com o passar do tempo. Tanto sua massa quanto o seu volume foram reduzidos com esse avanço, permitindo a aplicação do MIT em sistemas e processos onde antes não se era possível, devido a limitação técnica de seu tamanho. A relação tamanho/potência foi mudando fortemente, conforme pode ser visto na Figura 1, sendo possível a construção de motores menores e cada vez mais potentes.

Observando-se a massa de um motor de mesma potência no decorrer do tempo, pode-se verificar que o motor atual tem 8% da massa do seu antecessor de 1891. O tamanho das máquinas vem diminuindo cerca de 20% a cada década. As pesquisas se concentraram, desde então, no aperfeiçoamento e na redução da massa da máquina elétrica em relação à potência fornecida. O maior avanço tecnológico neste sentido se deve ao desenvolvimento dos isolantes elétricos. A questão do rendimento e da eficiência energética também acompanhou essa evolução, sendo possível encontrar máquinas com rendimento de 95% (WEG, 2014a).

Figura 1 – Evolução do aspecto construtivo do MIT e seu rendimento, na análise da relação peso/potência



Fonte: WEG (2014a).

Durante muito tempo, o MIT foi utilizado para acionamentos em que o motor girava a velocidades constantes (desprezando-se o escorregamento) sendo que a regulação da velocidade era realizada por sistemas mecânicos como polias, correias, etc. Para sistemas onde era necessária precisão na regulação e variação de velocidade, utilizavam-se motores de corrente contínua em razão do controle da rotação ser mais fácil e preciso, entretanto, possuindo um alto custo quando comparado com o MIT. Com o avanço da eletrônica de potência, o desenvolvimento dos conversores CC/CA (inversores de frequência) representou um salto significativo para o acionamento e controle do MIT, permitindo sua utilização em grande escala em

sistemas com necessidade de variação de velocidade, substituindo gradativamente os motores de corrente contínua (TOLIYAT *et al*, 2012).

Dentro do ambiente industrial, a maior parte dos MIT encontram-se inseridos em processos complexos, que congregam diversos subsistemas. Em grande parte dos casos, o valor material agregado do próprio equipamento, não é financeiramente tão significativo frente ao valor estratégico da posição/função chave em que o motor se encontra inserido dentro da cadeia produtiva. Mais ainda, essa posição é especialmente importante quando um desligamento inesperado pode resultar na interrupção de operações e serviços críticos como centrais de geração de energia elétrica, hospitais e centros médicos, serviços de transporte ou operações militares.

Estas máquinas, invariavelmente, estão expostas aos mais diversos tipos de ambientes operacionais prejudiciais, estando sujeitas muitas vezes a condições que obrigam o funcionamento no limite de suas especificações. Isso significa que o equipamento está normalmente sujeito a esforços mecânicos repetitivos e contínuos, condições de alta temperatura ambiente e umidade, além de intempéries climáticas (SUETAKE, 2012).

Apesar das qualidades como robustez e alta durabilidade do MIT, a questão da falha é inerente à operação desses dispositivos. Os defeitos, no início de suas manifestações, por mais incipientes que sejam, já alteram o desempenho do motor, antes mesmo que falhas significativas apareçam, trazendo assim prejuízos ao processo. Dessa forma, um constante monitoramento de suas condições de operação se faz cada vez mais necessário dentro do ambiente industrial, principalmente com o intuito de reduzir o seu índice de falhas e evitar perdas de produção, eliminando prejuízos resultantes de sua indisponibilidade e das máquinas a eles associadas (LEE *et al*, 2011).

Nesse contexto, os estudos de técnicas de manutenção preditiva vão de encontro a essas necessidades. Essa área tem evoluído muito nas últimas décadas e contribuído, expressivamente, para manter a confiabilidade, disponibilidade e durabilidade dos motores elétricos.

Sabe-se que o modelo de manutenção preditiva tem melhor eficácia comparativamente com as técnicas de manutenção preventiva ou corretiva, devido a evitar paradas inesperadas de linhas produtivas ou manutenções desnecessárias. Atuando de maneira a prever e antecipar a ocorrência de falhas, consegue-se evitar consequências como desbalanceamento da corrente e da tensão, aquecimento

excessivo da máquina, decaimento do torque médio, redução da eficiência energética e de perdas financeiras (NANDI *et al*, 2005). Entretanto, requer um tipo de monitoramento em tempo real e constante e uma análise recursiva dos dados com um conhecimento prévio para avaliação dos parâmetros. Nesse cenário, observa-se atualmente uma crescente demanda por sistemas de manutenção preditivos e de diagnóstico de falhas automatizados que possam aumentar a confiabilidade e garantir maior disponibilidade dos MIT.

No sentido de atender a essas necessidades, os Sistemas Inteligentes (SI) têm apresentado resultados promissores na identificação de falhas em sistemas complexos e não lineares, como é o caso do MIT (BACCARINI, 2005; SUETAKE, 2012). São técnicas atraentes e confiáveis em suas abordagens pois são métodos de simples implementação durante o tratamento dos dados, que não necessitam de um modelo matemático preciso, além de apresentarem uma grande facilidade de integração computacional com as técnicas convencionais, permitindo facilidade de aplicação e implementação no processo. (GOEDEL, 2007; SUETAKE, 2012)

Dentro das propostas de sistemas inteligentes, a utilização das Redes Neurais Artificiais (RNA) se mostra uma alternativa interessante pois, sua arquitetura de processamento é implementada sem cálculos matemáticos complexos, possibilitando uma abordagem diferenciada dos modelos convencionais (SANTOS *et al*, 2012a). Elas são capazes de aprender e generalizar o conhecimento adquirido, a partir de dados de exemplos em grande quantidade, o que é característico do sistema de funcionamento dos MIT.

1.2 Justificativa e objetivo

Historicamente, a necessidade de se prever com antecedência eventos potencialmente destrutivos e falhas que gerem manutenção em sistemas elétricos, sempre foi uma questão ímpar para setores importantes da sociedade, como linhas de produção e sistemas de geração de energia elétrica. De acordo com dados divulgados pela Empresa de Pesquisa Energética (EPE), sobre o cenário energético brasileiro em 2015, o setor industrial é responsável pelo consumo de mais de 47% da demanda ofertada de energia elétrica do país (EPE, 2016). Dentro dessa porcentagem, estima-se que mais de 50% estão empregados à sistemas de conversão de energia elétrica em força mecânica motriz (ELETROBRAS, 2015).

Segundo Ristic e Jeftenic (2012), o consumo de energia por parte de motores elétricos alcança 70% do total de energia elétrica, sendo que deste montante tem-se 60% destinados aos MIT.

A importância dos MIT nas plantas industriais torna a confiabilidade da operação destas máquinas um ponto crítico, devido ao alto custo de uma parada no processo produtivo, os quais podem impactar fortemente no custo total de muitos produtos (AVELAR *et al*, 2011). Uma vez que é economicamente inviável manter máquinas sobressalentes, o monitoramento online dos MIT se torna ferramenta importante para uma operação segura, e aumento da qualidade da produção (BACCARINI *et al*, 2005).

De acordo com Almeida (2000), os custos de manutenção correspondem à parte principal dos custos operacionais das plantas industriais de manufatura e de produção, podendo, dependendo da indústria, representar entre 15% a 30% do custo dos bens produzidos.

Soma-se a isso o fato de que, em média, 92% das despesas anuais de manutenção em fábrica provém da manutenção das máquinas elétricas (TAVNER, 2008). Entretanto, dentro desse universo, estima-se que apenas 10% dos equipamentos substituídos nas verificações e manutenções periódicas estão realmente com alguma avaria que o incapacitam de realizar as suas funções (TAVNER, 2008). Nesse sentido, surge a necessidade de um monitoramento contínuo da condição dos MIT de modo a minimizar e otimizar os custos associados. Adotando este tipo de monitoramento torna-se possível encontrar um equilíbrio econômico visto que, sendo conhecida a condição do motor, evita-se atingir extremos onde falhas provocam danos que impossibilitam o funcionamento do mesmo, permitindo que este opere durante o tempo para o qual foi projetado. Por outro lado, elimina-se a necessidade dos ciclos de inspeção periódica, onde os motores necessitam ser verificados fora do seu local de operação. Como já mencionado, mesmo com a provada robustez dos MIT, inevitavelmente acabarão por surgir falhas nos componentes principais do motor, sejam nos enrolamentos do estator, nas barras do rotor e nos rolamentos que suportam o rotor.

De modo a identificar quais os componentes constituintes de um MIT apresentam mais falhas, institutos como o *Institute of Electrical and Electronic Engineers* (IEEE) (IEEE,1997), e o *Electric Power Research Institute* (EPRI)

(ALBRECHT *et al*,1986), e pesquisadores como Bellini *et al* (2008) e Seinsch (2001), realizaram vários estudos específicos em MIT, conforme demonstrados na Tabela 1.

Tabela 1 – Distribuição das falhas nos MIT de acordo com a origem

COMPONENTES DO MOTOR	ESTUDOS REALIZADOS			
	IEEE (%) de falhas	EPRI (%) de falhas	SEINSCH (%) de falhas	BELLINI <i>et al</i> (%) de falhas
ROLAMENTOS	44	41	13	69
ESTATOR	26	36	63	21
ROTOR	8	9	13	7
OUTROS DEFEITOS	22	14	8	3

Fonte: Autoria própria (2017).

Um sistema de detecção e diagnóstico de falhas pode auxiliar o setor de manutenção de uma indústria de diversas maneiras. Uma das principais vantagens desse sistema está na possibilidade de detectar a falha em seu estágio inicial, o que auxilia a manutenção preditiva e pode também evitar uma parada não programada da máquina. Nesse sentido, a motivação para o desenvolvimento deste trabalho se faz justa, visto que se observa uma crescente demanda por sistemas de manutenção preditiva e diagnóstico de falhas automatizados cada vez mais eficientes, para auxílio nas manutenções programadas das linhas de produção industrial e setores críticos, sendo alvo de pesquisas tanto da comunidade acadêmica quanto das empresas especializadas em manutenção industrial.

Dentro do universo dos métodos disponíveis atualmente para diagnóstico de falhas, escolheu-se para essa pesquisa a abordagem através de Sistemas Inteligentes (SI), especificamente os baseados em Redes Neurais Artificiais (RNA). Essa escolha amparou-se em algumas características das RNA como a de ser uma ferramenta simples, com possibilidade de avaliação do equipamento em regime de trabalho e em tempo real, com baixa complexidade computacional, apresentar um baixo custo de implementação do sistema e ter a capacidade de determinar o tipo de uma falha num MIT sem necessitar de modelos matemáticos complexos (SANTOS, 2012b). Além disso, de acordo com Santos (2012b), a utilização das RNA oferece vantagens como a possibilidade de treinamento a partir dos sinais do motor em ambos os domínios (tempo ou frequência), o reconhecimento de padrões e mapeamento não-linear no

monitoramento das condições do motor e a alta porcentagem nos acertos das validações e classificações das falhas.

A análise de sinais de vibração pode acusar eventuais problemas em uma máquina e orientar sobre a execução ou não de manutenção. Toda máquina apresenta emissão de ruído e vibração devido à própria operação e excitações externas. Contudo, uma parcela das vibrações se deve a pequenos defeitos que comprometem a performance do equipamento. O aumento de determinado tipo de nível de vibração é reflexo do agravamento do defeito.

O que faz da análise de vibrações um processo eficiente é que cada elemento da máquina possui uma característica de excitação própria, gerando maneiras específicas de vibração. É justamente por essa razão que os defeitos nesses elementos podem ser detectados. As vibrações em motores elétricos são normalmente classificadas em vibrações de origem magnética e vibrações de origem mecânica. As perturbações magnéticas nos motores podem ser conseqüências de problemas elétricos internos ou de defeitos dinâmicos na rede externa de alimentação elétrica (ARAÚJO, 2015).

Nesse contexto, o objetivo deste trabalho foi o estudo e desenvolvimento de uma abordagem para identificar e classificar defeitos em Motores de Indução Trifásicos (MIT) por meio de diafragmas piezelétricos de baixo custo e sistemas inteligentes do tipo RNA, mais especificamente, defeitos do tipo curto-circuito entre espiras de uma mesma bobina nos estatores dessas máquinas. Diafragmas piezelétricos de baixo custo foram empregados como sensores para a captação dos sinais de vibração do MIT, sinais que, juntamente com os sinais de corrente elétrica trifásicos, após condicionamento e processamento, foram levados a sistemas inteligentes computacionais baseados em redes neurais artificiais. Essas redes processaram os dados de forma a identificar precocemente uma falha, classificando-a corretamente para se definir um diagnóstico.

Assim sendo, o estudo da identificação e classificação precoce de defeitos em MIT possui uma conotação econômica de grande relevância, quando se leva em conta os altos custos gerados por manutenções corretivas desprogramadas, ou mesmo pelas interrupções no processo de geração de energia elétrica causadas por estas não conformidades nos MIT. Além disso, muitas vezes a integridade dessas máquinas passa a ser de suma importância em função dos altos custos os altos custos de aquisição e manutenção corretivas para as máquinas de grandes dimensões e alta

potência. O desenvolvimento desta pesquisa, com a abordagem do tema proposto, mostra seu valor no desenvolvimento científico da área e seu grande impacto de caráter econômico no cenário atual.

1.3 Publicações científicas relacionadas

SILVA FILHO, N. M.; Ulson, J. A. C.; Creppe, R. C. Aplicação de Sistemas Inteligentes no Diagnóstico de defeitos em motores elétricos de indução trifásicos. In: **V Seminário da Pós-Graduação em Engenharia Elétrica**, 2015, Bauru/SP.

SILVA FILHO, N. M.; Ulson, J. A. C.; Clerice, G. A. M.; Oba Ramos, C. C., Castro, B. A.; Andreoli, A. L.; Creppe, R. C. Identificação de Anomalias na Alimentação de Motores de Indução Trifásicos utilizando Sensores PZT e Redes Perceptron Multicamadas. In: **IEEE/IAS International Conference on Industry Applications - INDUSCON**, Curitiba, 2016.

SILVA FILHO, N. M.; Ulson, J. A. C.; Creppe, R. C. Aplicação de Sistemas Inteligentes no Diagnóstico de defeitos em motores elétricos de indução trifásicos. In: **VI Seminário da Pós-Graduação em Engenharia Elétrica**, 2016, Bauru/SP.

2 REVISÃO BIBLIOGRÁFICA E CONCEITUAL

Neste capítulo são abordadas questões conceituais importantes para o desenvolvimento do trabalho, bem como observações sobre o cenário atual das pesquisas e desenvolvimento dos temas envolvidos, que são: Manutenção Industrial, Motores de Indução Trifásicos, Métodos para Diagnóstico de Falhas em MIT, Piezeletricidade e Sistemas Inteligentes.

2.1 Conceitos de manutenção e evolução histórica

Historicamente, o conceito e as práticas de manutenção industrial nunca evoluíram tão rapidamente e de maneira significativa quanto nas últimas décadas. Grande parte desse salto qualitativo e quantitativo deve-se ao desenvolvimento científico-tecnológico exponencial da sociedade, mas também, pela necessidade cada vez maior do aumento na confiabilidade e disponibilidade dos equipamentos e dispositivos envolvidos em um sistema produtivo industrial.

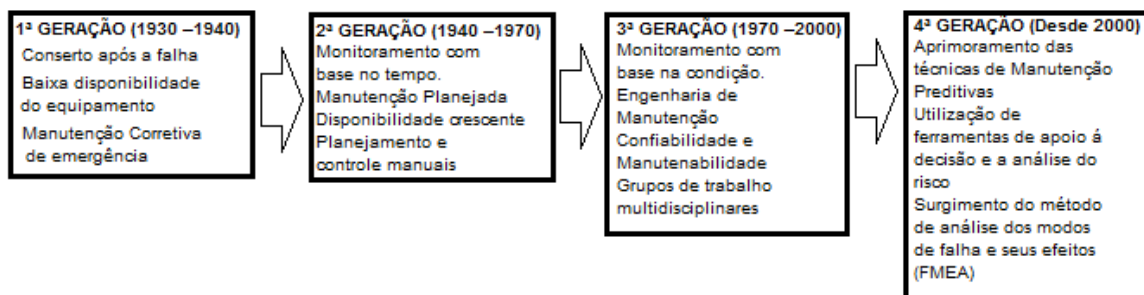
Durante muito tempo o conceito de manutenção industrial limitava-se simplesmente ao conserto ou reparo na máquina após ela apresentar a falha, já com o dano presente, o motor parado e a cadeia produtiva interrompida. A ideia de manutenção remete ao conceito do conjunto de uma série de medidas preventivas, visando manter os sistemas funcionando; de medidas de correção, visando reestabelecer o funcionamento do sistema avariado; e de medidas de predição, visando monitorar o estado de funcionamento do sistema, detectar alguma falha precocemente e fornecer subsídios para o planejamento de ações de intervenção, sendo estas preventivas ou corretivas, praticadas com a intenção de corrigir os danos provocados pela degradação e manter os sistemas funcionando (PINTO; XAVIER, 2005).

Até final da década de 1950, a manutenção em nível mundial era quase que exclusivamente de caráter corretivo, onde somente quando um equipamento apresentava uma quebra, substituía-se o componente defeituoso (BRANCO, 2008). Foi também nesse período que, no meio acadêmico, houve um aumento do estudo das máquinas elétricas rotativas. A partir daí, houve um importante crescimento

tecnológico industrial, mudando o conceito de Manutenção, com o objetivo agora de se evitar ao máximo uma manutenção corretiva não planejada, por causa dos danos e custos adicionais que ela pode ocasionar (KARDEC *et al*, 2002).

A evolução da manutenção está intimamente ligada ao desenvolvimento das unidades de produção de forma que, quanto mais sofisticado for o processo fabril, mais sofisticada será a manutenção dos equipamentos. Este conceito não se aplica apenas ao maquinário envolvido na manutenção, mas também na organização e na administração, onde não se pode esperar algo diferente, senão mudanças no tratamento de falhas, na abordagem da manutenção e sua prevenção (PINTO; XAVIER, 2005). Os sistemas produtivos evoluíram, com novas técnicas de otimização de processos, de forma que as técnicas de manutenção industrial tiveram que acompanhar esse desenvolvimento, sendo que as mudanças ocorridas podem ser caracterizadas, ou divididas, em quatro gerações, as quais são mostradas na Figura 2 (MORAES, 2004).

Figura 2 – Demonstração da evolução dos conceitos de manutenção



Fonte: Adaptado de Moraes (2004).

2.2 Classificação das atividades de manutenção industrial

Conforme Branco (2008), o Capítulo 2 da norma ABNT-TB116 (Confiabilidade e Manutenibilidade – Terminologia), define manutenção como todas as ações necessárias para que um item mantenha-se conservado de modo a permanecer de acordo com uma ou mais condições previamente especificadas, dentro de padrões previamente estabelecidos. Para o cenário industrial em particular, define-se como a ação de reparar ou executar serviços em equipamentos e sistemas, para que estes voltem a trabalhar em suas condições nominais de funcionamento. Como já mencionado no Capítulo 1, apesar dos MIT atualmente possuírem um alto padrão

tecnológico de construção que as tornam eficientes e robustas, devido as condições de estresse nas quais são submetidas (condições térmicas, ambientais, mecânicas e elétricas), elas não estão totalmente seguras de não desenvolver falhas durante sua vida útil (SUETAKE, 2012).

Existem várias classificações para a atividade dentro de um ambiente industrial, sendo que a maneira pela qual é feita a intervenção nos equipamentos, sistemas ou instalações determinam o seu tipo. Dessa forma tem-se uma variação de nomenclatura para subtipos diversos, entretanto, para o caso da manutenção em MIT na indústria, pode-se agrupá-las, basicamente, em três estratégias de manutenção: manutenção corretiva, manutenção preventiva e manutenção preditiva (KARDEC *et al*, 2002).

A Manutenção Corretiva é a mais antiga e mais utilizada, sendo a forma primária de manutenção, pois só é realizada após a ocorrência do defeito ou falha que torna o equipamento ou sistema inoperante. Não há a preocupação em se antever os prováveis defeitos e condições de não conformidade no processo, sendo que os problemas são resolvidos apenas após terem ocorrido. Obviamente que esse tipo de manutenção implica em uma série de desvantagens, como a ocorrência sistemática de paradas na produção industrial de maneira não programada; uma degradação maior do equipamento ou máquina que recebe este tipo de manutenção; maior consumo de energia, entre outros (KARDEC *et al*, 2002).

Com o avanço tecnológico e econômico dos processos industriais, principalmente com o objetivo de se diminuir as paradas da linha de produção não programadas, adotou-se a estratégia de Manutenção Preventiva, que é a manutenção executada para manter um item em condições satisfatórias de operação, através de inspeções sistemáticas (intervalo de tempo fixo), detecção e prevenção de falhas incipientes (PINTO; XAVIER, 2005). De forma oposta à característica da Manutenção Corretiva, o intuito da Manutenção Preventiva é evitar a ocorrência de condições insatisfatórias, e conseqüentemente, reduzir o número de ações corretivas nos equipamentos.

A Manutenção Preditiva é considerada uma evolução das estratégias de Manutenção Preventiva, mas com o foco na condição ou estado do equipamento, sendo que o objetivo principal é prevenir as falhas nos equipamentos ou sistemas por meio de acompanhamento de parâmetros diversos, permitindo a operação contínua do equipamento pelo maior tempo possível (RIBEIRO, 2003). Através dessa predição

de estado das máquinas e equipamentos, como os MIT, consegue-se programar uma intervenção com antecedência, efetuando-se então uma manutenção corretiva de forma programada. Além disso, a estratégia de Manutenção Preditiva traz com ela uma série de vantagens que a faz, juntamente com suas subdivisões, a mais utilizada nos processos industriais atualmente. Características essas como o apoio em técnicas não-invasivas, ou seja, não é necessário parar a operação da máquina para sua aplicação; aumento da vida útil e ciclo de trabalho dos equipamentos, eliminação de intervenções emergenciais para manutenção corretiva; possibilidade de estudos e monitoramento através de técnicas *on-line* ou *off-line*, entre outras (KARDEC *et al*, 2002).

Percebe-se, atualmente, uma crescente demanda por sistemas de manutenção preditivos automatizados, principalmente de sistemas para diagnosticar falhas em motores elétricos, com especial atenção aos MIT, devido a ser o tipo de máquina elétrica rotativa mais presente, nas linhas de produção. Indo ao encontro dessas necessidades, uma importante alternativa para a automatização de sistemas de monitoramento desses motores é a utilização de sistemas computacionais inteligentes. Esses sistemas possuem vantagens interessantes para o uso nas estratégias de manutenção preditivas, como a baixa complexidade computacional, para sua implementação sendo capaz de analisar falhas nos MIT sem a necessidade de modelos matemáticos complexos e sofisticados (SANTOS *et al*, 2012).

2.3 Motores elétricos de indução trifásicos (MIT)

Como a maior parte da energia elétrica produzida e mais abundantemente disponibilizada é a corrente elétrica alternada, a grande maioria dos motores elétricos são desenvolvidos para trabalharem com esse tipo de corrente. Nesse contexto, o MIT, mais especificamente o Motor de Indução Trifásico Rotor Gaiola de Esquilo (MITRGE), aparece como a máquina rotativa de corrente alternada mais utilizada nos sistemas e processos de acionamento eletromecânicos (BELLINI *et al*, 2008; GOEDTEL, 2007; SUETAKE, 2012). A Figura 3 ilustra alguns modelos desses motores comercializados.

Grande parte desse protagonismo deve-se as suas características de construção que lhes atribuem qualidades como robustez, durabilidade e simplicidade de manutenção, o que o torna também economicamente mais viável. Soma-se a isso

uma simplicidade e versatilidade na forma de acionamento em casos onde se requer uma velocidade estável independentemente da carga que lhe está a ser aplicada, tornando-o adequado para uma diversidade de aplicações para conversão de energia elétrica em mecânica motriz na indústria. Por suas características e por serem mais populares na indústria, o MITRGE foi escolhido como objeto de estudo desse trabalho de pesquisa.

Figura 3 – Modelos de MIT comumente encontrados no mercado




Fonte: WEG (2014a).

2.4 Aspectos construtivos e características funcionais

Os motores elétricos atuam basicamente como conversores de energia, convertendo energia elétrica em energia mecânica motriz. Os MIT, em especial, funcionam utilizando-se de um sistema de conversão eletromecânica de energia simples e eficiente. Utilizam-se dos princípios e leis do eletromagnetismo, onde a força age sobre os condutores de corrente elétrica, imersos em um campo magnético, com o circuito elétrico de uma parte ligado a um sistema de alimentação trifásico, e com o circuito elétrico da outra parte submetida à indução magnética criada pela circulação de correntes nos enrolamentos estatóricos. Normalmente o circuito elétrico indutor encontra-se no estator da máquina, enquanto o circuito induzido está no rotor da máquina (TOLIYAT *et al*, 2012).

Pela Figura 4 pode-se observar uma vista em corte de um (MITRGE), onde destaca-se suas duas partes fundamentais, que são o rotor e o estator (WEG, 2014b).

Figura 4 – Aspecto construtivo com estrutura básica de um MITRGE



Fonte: Adaptado de WEG (2014b).

Conforme descrito por Weg (2014b), as partes constituintes do MITRGE são:

- 1) Carenagem externa ou carcaça, sendo estrutura suporte do conjunto. De construção robusta pode ser fabricada em ferro fundido, aço ou alumínio injetado. Resistente à corrosão e normalmente com aletas;
- 2) Núcleo do estator, com chapas feitas ferro-silício prensadas, destinadas a fazer circular o campo magnético do estator, contém ranhuras onde são inseridas as bobinas do estator;
- 3) Núcleo de chapas do rotor, Chapas de aço, semelhantes às do estator, completa o circuito magnético criado no estator;
- 4) Tampa;
- 5) Ventilador de refrigeração forçada;
- 6) Tampa defletora;
- 7) Eixo do rotor, o qual transmite a potência mecânica desenvolvida pelo motor;
- 8) Enrolamentos trifásicos do estator, compostos por conjuntos de bobinas em condutores de cobre ou alumínio cobertos com material isolante, ligadas à rede trifásica, onde circula a corrente do motor, que

produz o campo magnético. Os enrolamentos de cada fase são iguais e distribuídos espacialmente no estator defasados em 120° elétricos;

- 9) Caixa de ligação elétrica;
- 10) Terminais para conexões de alimentação elétrica do MIT;
- 11) Rolamento;
- 12) Barras e anéis de curto-circuito do rotor, confeccionadas geralmente em alumínio ou cobre, formam o circuito elétrico do rotor. O conjunto de barras e anéis fechados em curto-circuito formam uma estrutura que lembra uma gaiola, de onde originou-se o nome gaiola de esquilo.

Uma das particularidades que caracterizam os motores de indução em geral é o fato de apenas o estator estar conectado com a rede de alimentação elétrica. Como o rotor não é alimentado eletricamente por fonte externa, as correntes que circulam por ele são induzidas eletromagneticamente pelo estator. Não há anéis coletores e comutador ou qualquer contato móvel entre o rotor e o estator (TOLIYAT *et al*, 2012).

Seja qual for o modo de fabricação, o princípio básico de funcionamento dos motores é o mesmo: alimenta-se a parte fixa do motor com energia elétrica, criando-se ali campo magnético girante. Esse campo cria uma força magnética na parte móvel do motor que se move para tentar acompanhar a variação do campo magnético. Segundo Riehl (2010), quando o estator é alimentado por uma fonte de alimentação trifásica, correntes elétricas circulam nas bobinas das fases de cada enrolamento do mesmo, resultando um campo magnético girante, de amplitude constante, que gira na velocidade síncrona no entreferro, que é função do número de pólos do motor e da frequência da fonte de alimentação.

Sabe-se que o campo magnético gerado por uma bobina depende da corrente que no momento circula por ela. Se a corrente for nula, não haverá formação de campo magnético; se ela for máxima, o campo magnético também será máximo. Como as correntes nos três enrolamentos estão com uma defasagem de 120° elétricos, os três campos magnéticos apresentam também a mesma defasagem. Os três campos magnéticos individuais combinam-se e disso resulta um campo único cuja posição varia com o tempo. Esse campo único, giratório, vai agir sobre o rotor e provocar seu movimento, girando o eixo do motor (TOLIYAT *et al*, 2012).

2.5 Tipos de falhas em motores de indução trifásicos

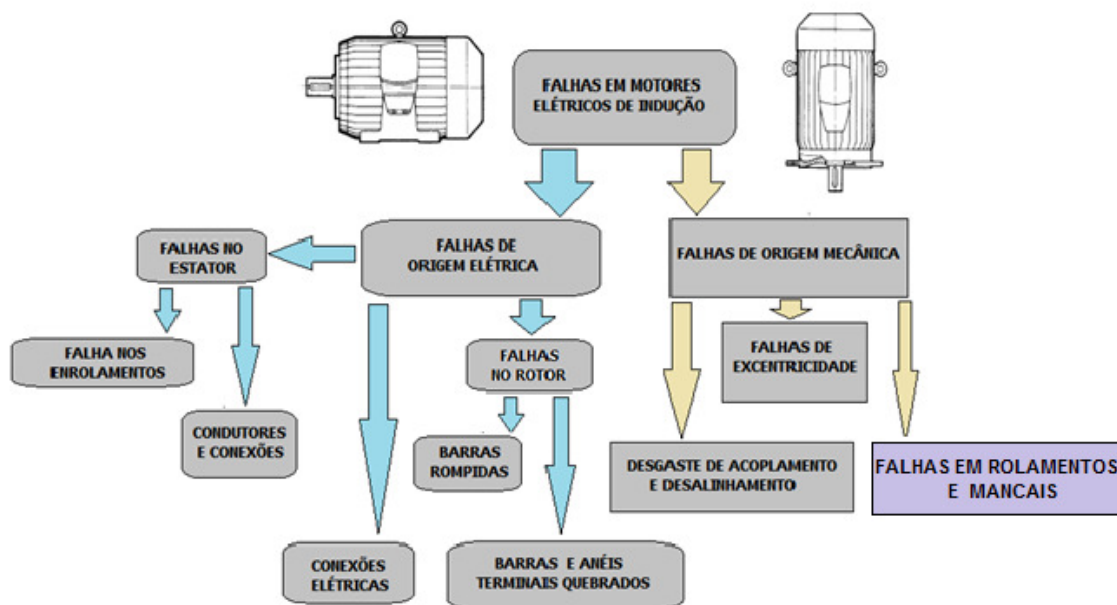
Como já mencionado anteriormente, um MIT possui qualidades como robustez e durabilidade. Todavia, como qualquer equipamento, o mesmo está sujeito a falhas que modificam suas condições de funcionamento. É importante destacar que estas falhas atuam de maneira negativa diretamente no desempenho dessas máquinas, mesmo antes que a falha atinja uma magnitude relevante e problemas significativos ocorram (SANTOS *et al*, 2012a).

Os MIT são máquinas que, quando trabalhando em condições normais, comportam-se como um sistema elétrico altamente simétrico. Sendo assim, qualquer falha, por menor que seja, altera essa característica, sendo refletida tanto em vibrações mecânicas quanto na corrente elétrica (BELLINI *et al*, 2008).

De maneira geral, as falhas apresentadas nos MIT podem ser classificadas em dois grupos distintos: falhas elétricas e falhas mecânicas (BELLINI *et al*, 2008).

A Figura 5 ilustra um diagrama esquemático indicando os componentes defeituosos com o grupo à qual pertence.

Figura 5 – Classificação das falhas presentes em MIT



Fonte: Autoria própria (2017).

Como pode ser visto, as falhas de caráter elétrico podem ocorrer devido a problemas relativos aos enrolamentos de estator e de rotor, às barras e anéis quebrados no rotor e suas conexões. As falhas de caráter mecânico, por sua vez, podem ser provenientes de problemas de rolamentos, excentricidade, desgaste de acoplamento e desalinhamento.

Das falhas que os MIT estão sujeitos destacam-se as que modificam, além do funcionamento adequado do motor, os sinais das correntes elétricas que circulam nos seus enrolamentos. Tais alterações na forma de onda das correntes se destacam, pois, estas são responsáveis pelo fluxo magnético gerado nas bobinas do estator, que provocam a indução das correntes no rotor.

As falhas elétricas, tanto no rotor quanto no estator estão associadas aos enrolamentos abertos ou em curto, barras quebradas ou anéis de curto circuito danificados. Já para as falhas de origem mecânica, tem-se a excentricidade do rotor deslocado do seu centro magnético, rolamento defeituoso, bem como eixo do rotor torto ou desalinhamento dos acoplamentos mecânicos (FITZGERALD *et al*, 2008).

A Tabela 1, no capítulo introdutório desse trabalho, ilustra a porcentagem de distribuição dessas falhas presente em um MIT, de acordo com a predominância de ocorrência.

Os resultados obtidos mostram que as falhas que mais ocorrem localizam-se nos rolamentos (origem mecânica), seguida das falhas no estator (origem elétrica), ou seja, nos enrolamentos das bobinas que o constituem. Por esse motivo, optou-se, como objeto de estudo dessa pesquisa, a análise das falhas elétricas nos estatores de MIT.

2.6 Análise de falhas em estatores de MIT

Os MIT, ao longo de sua vida útil, estão suscetíveis a operações de cargas e condições ambientais variadas, sendo expostos a esforços térmicos, elétricos e mecânicos, potencializando o desgaste natural de suas partes. (BELLINI *et al*, 2008).

Nesse contexto, as bobinas do estator estão sujeitas a diversas anomalias e estas, por sua vez, ocasionam diferentes respostas de comportamento no funcionamento do MIT.


As alterações no estator podem se manifestar de diversas maneiras, destacando-se o aquecimento excessivo do motor, a sobrecarga elétrica e a falha no isolamento da bobina como umas das mais relevantes (BRITO, 2002).

De acordo com Bonnett e Soukup (1992), os materiais orgânicos utilizados na camada de isolamento dos fios que formam as bobinas do estator sofrem uma deterioração devido à combinação de sobrecargas térmicas, transitórios elétricos, fatores mecânicos e contaminantes como poeira.

Segundo Stone e Kapler (1998), a vida útil do isolamento é reduzida em 50 % a cada 10° C acima da temperatura limite dos enrolamentos.

Nesse sentido, as sobrecargas térmicas são consideradas como o principal causador da degradação do isolamento, sendo que a vida útil dessa camada isolante pode ser drasticamente reduzida se houver um sobreaquecimento significativo do motor, levando a ruptura desse isolante do condutor, conforme ilustrado na Figura 6.

Figura 6 – Danos na camada de isolante do condutor elétrico (imagem aumentada de um fio de cobre) devido a sobreaquecimento



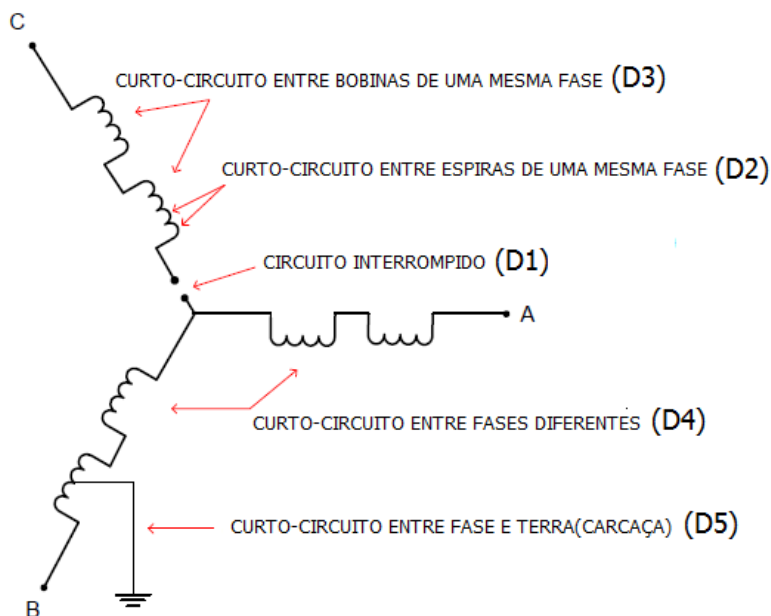
Fonte: Adaptado de Tavner (2008).

Além disso, conforme Nandi *et al* (2005), essa isolação estatórica pode ser afetada pela elevada taxa de variação da tensão de alimentação (dV/dt), folga na laminação do núcleo magnético estatórico, alta temperatura do núcleo estatórico, perda da proteção das conexões das bobinas, contaminação provocada por óleo ou umidade e sujeira e descargas elétricas.

De maneira geral, independente das causas, as falhas que ocorrem estator dos MIT podem ser divididas nas seguintes categorias: ruptura do circuito, curto-circuito entre espiras de uma mesma fase, curto-circuito entre bobinas de uma mesma

fase, curto-circuito entre fases diferentes, curto-circuito entre enrolamento e a carcaça da máquina. A Figura 7 ilustra de maneira esquemática essas possibilidades.

Figura 7 – Características das possíveis falhas elétricas em estatores de MIT



Fonte: Bonnett e Soukup (1992).

Segundo o trabalho de Bonnett e Soukup (1992), conforme ilustrado pela Figura 7, a falha de curto-circuito evolui nesse sentido: uma vez que ocorre uma falha do tipo (D2), curto-circuito entre espiras, o calor excessivo gerado resulta na deterioração da isolamento adjacente. Como já dito anteriormente, conforme o tipo de proteção utilizado no sistema, o MIT continua em operação. À medida que a isolamento se deteriora a corrente e o calor se elevam, num ciclo vicioso, até culminar numa falha do tipo (D3), (D4) ou (D5).

Normalmente, nesse nível, a proteção, se bem dimensionada, deve agir, desconectando o motor da rede elétrica e paralisando o processo. Em vista da descrição acima, fica evidente que os curtos-circuitos entre espiras podem ser qualificados como incipientes, haja vista que as demais são normalmente consequência dessa. Portanto, o curto-circuito entre espiras demanda atenção no processo de monitoramento do MIT.

Uma vez que esse tipo de curto-circuito ocasiona a retirada de uma ou mais espiras do circuito, é estabelecida uma força magnetomotriz (FMM) negativa, a qual reduz a FMM da fase em questão. Em decorrência disso, a forma de onda do fluxo magnético no entreferro é distorcida, induzindo frequências harmônicas na corrente do estator (BONNETT; SOUKUP, 1992). Os fatos mencionados, do ponto de vista da análise espectral, tornam a investigação de curtos-circuitos incipientes tarefa de maior complexidade. Como destacam Bellini *et al* (2008) e Mehala (2012), a falha do tipo (D2) é reconhecida como uma das mais difíceis de serem detectadas em estágios iniciais. Em razão disso, muitas metodologias têm sido desenvolvidas para solucionar essa dificuldade, sendo este tipo de falha o foco do presente trabalho.

De acordo com Baccarini *et al* (2005), a corrente de curto-circuito nas espiras do estator é de aproximadamente duas vezes a corrente de rotor quando bloqueado, situação que provoca aquecimento localizado que rapidamente se estende para outros setores do enrolamento. O tempo de evolução dessa falha depende das condições de operação do motor e é difícil de ser estimado.

Entretanto, no início de um curto-circuito entre espiras de uma mesma bobina ou com bobinas adjacentes, a intensidade de corrente não é demasiadamente elevada, de modo que os dispositivos de proteção termomagnéticos não atuam em tempo hábil. A partir desse momento, a falha pode gerar danos consideráveis nas bobinas dos enrolamentos do estator, conforme ilustrado na Figura 8, implicando em uma falha catastrófica para o MIT, num curto intervalo de tempo (BELLINI *et al.*, 2008).

Existem dois tipos de técnicas mais usuais e relevantes para monitoramento das condições de operação de um MIT, bem como para o diagnóstico e identificação das falhas presentes, técnicas essas classificadas como invasivas e não-invasivas. Basicamente diferem-se no fato de existir ou não a necessidade de acessar fisicamente a estrutura do motor para extração de sinais, informações ou características da máquina.

Dessa forma, com o desenvolvimento de métodos de monitoramento da condição e diagnóstico de falha, destacam-se de maneira significativa as técnicas mais recentes não invasivas e de monitorização remota automatizada. Por essas características, de monitoramento automatizado constante e em tempo real, essas técnicas também são chamadas de métodos *on-line* e *off-line*. No método *on-line*, a técnica empregada torna possível realizar o diagnóstico com o motor em regime de trabalho, sem interromper processos e desligamento das máquinas. Em contrapartida,


no método *off-line*, exige-se que a máquina seja removida do sistema de modo a que os componentes causadores de falha possam ser acessados.

Figura 8 – Características físicas de algumas avarias em enrolamentos de estatores


CURTO-CIRCUITO ENTRE ESPIRAS




CURTO-CIRCUITO ENTRE BOBINAS



CURTO- CIRCUITO ENTRE FASES



CURTO- CIRCUITO FASE A TERRA



Fonte: Adaptado de WEG (2014a).

De forma geral, a presença de qualquer tipo de falha em um MIT provoca mudanças de interação de fluxo magnético entre o estator e rotor, refletindo diretamente em mudanças na corrente do estator, nas tensões, no campo magnético e na vibração da máquina. Estes sinais são responsáveis por auxiliar o monitoramento da máquina, conseqüentemente, detectar e diagnosticar a falha.

Nesse contexto, muitos estudos sobre métodos e técnicas de manutenção preditiva para MIT foram realizados nas últimas décadas, trazendo muitos avanços tanto no âmbito industrial quanto acadêmico. Algumas das mais utilizadas são:

- a) Monitoramento por Análise da Assinatura Elétrica do motor (MCSA - *Motor Current Signature to Analysis* e EPVA - *Extended Park's Vector approach*);
- b) Monitoramento por Análise de Vibrações;

- c) Monitoramento de temperatura por Termografia;
- d) Sistemas Computacionais Inteligentes.

a) Monitoramento por Análise da Assinatura Elétrica do Motor

A técnica de monitoramento MCSA destaca-se como uma das mais utilizadas pois permite detectar vários tipos de defeitos, entre eles curtos-circuitos em estatores e problemas relacionados com a excentricidade dos componentes, sem a necessidade de desmontar as máquinas ou suas partes estruturais, facilitando o acesso a motores muitas vezes inacessíveis dentro de uma planta industrial em funcionamento. Constitui em um método que identifica anomalias nos motores, através da detecção de alterações nas correntes do MIT, pela sua análise espectral, por meio do monitoramento de uma das três fases da corrente de alimentação (PEREIRA et al., 2005). Dessa forma, o sinal de corrente de uma das fases do motor é analisado para produzir o espectro de corrente, gerando a assinatura do MIT. O objetivo é obter tal assinatura para se identificar a frequência e a magnitude de cada componente individual que constitui o sinal de corrente desse motor. Nesse sentido há a possibilidade de se identificar os padrões na assinatura da corrente para, posteriormente, diferenciar motores simétricos em boas condições de funcionamento de motores com falhas e ainda, detectar em que parte da máquina a falha deve ocorrer (NANDI *et al*, 2005).

Por meio da aquisição dos sinais de corrente elétrica nominal de alimentação do estator, adquiridos por meio de transdutores ligados direto na alimentação elétrica do motor em regime de trabalho, e na transformação deste sinal, que se encontra no domínio do tempo, para uma análise no domínio da frequência (aplicando decomposição espectral dessa corrente), é possível identificar alguns componentes específicos de frequência que indicam uma falha iminente ou uma possível degradação da máquina. Com uma falha em desenvolvimento, o espectro de frequência da corrente se torna diferente do espectro do motor quando em boas condições de operação (THOMSON, 2001). Essa técnica visa obter as componentes localizadas em $(1 \pm 2s) f$ no espectro da corrente do estator para encontrar falhas (sendo f a frequência das correntes de alimentação) (NANDI *et al*, 2005; SANTOS *et al*, 2012).

Ainda conforme Santos *et al* (2012b), estando o enrolamento de um MIT em condições assimétricas de trabalho, o mesmo apresenta produção de harmônicas espaciais em qualquer onda no campo do entreferro, porém, estas harmônicas variam unicamente na frequência da fonte de tensão senoidal da rede. Assim, as harmônicas do estator induzem correntes na gaiola do rotor e que refletem de volta ao estator, como novas harmônicas do campo do entreferro. Dessa forma, no estator, as harmônicas do entreferro, causadas pela corrente induzida do rotor, variam na frequência, descritas pela Equação 1:

$$f_r = f_1 \left[1 \pm \frac{\alpha n}{p} (1 - s) \right] \quad (1)$$

Onde:

f_r é a frequência (Hz) refletido no estator relacionada ao curto-circuito;

f_1 é a frequência fundamental (Hz) da fonte de alimentação da rede elétrica;

α é a ordem do harmônico de frequência;

n é o número de barras do rotor;

p é o número de pares de pólos;

s é o escorregamento.

É importante destacar que as harmônicas do campo do entreferro induzidas na corrente do estator possuem as mesmas frequências que uma harmônica produzida em um motor simétrico sem falhas. Dessa forma, uma falha no enrolamento do estator tem capacidade de alterar a amplitude das harmônicas da corrente do estator, entretanto, não produz nenhuma nova frequência no espectro da corrente (SANTOS, 2013).

Na literatura acadêmica encontram-se vários trabalhos que exploram essa técnica, como a pesquisa de Bouzid *et al* (2008) que implementa um sistema de detecção de falhas de estator em MIT para análise das componentes simétricas por meio dos espectros harmônicos dos sinais da corrente elétrica de alimentação. Outros artigos descrevem também a utilização das assinaturas dos sinais de corrente de estator para diagnosticar falhas de curto-circuito entre as espiras no enrolamento de estator de um MIT, ressaltando que essas falhas causam um aumento substancial na amplitude das componentes harmônicas (GENTILE *et al*, 2003; UKIL *et al*, 2010).

Outra técnica também muito empregada para diagnóstico de falhas em MIT é a Abordagem do Vetor de Park Estendido - *Extend Park's Vector Approach* (EPVA), sendo um método utilizado com êxito para detectar falhas no enrolamento do estator em motores de indução. Caracteriza-se por utilizar a amostragem das três correntes de alimentação do estator do MIT, privilegiando a detecção de defeitos provindos da rede de alimentação trifásica e também de assimetrias internas no estator do motor. Trabalhos de pesquisa como o de Cruz e Cardoso (2001) mostram que a técnica EPVA pode ser utilizada como um tratamento diferenciado para detecção de curto circuito entre espiras quando o MIT está ligado a uma fonte de tensão equilibrada.

De acordo com o que relatam Das *et al* (2008), é possível, através de uma representação em duas dimensões (2D), ou seja, em plano cartesiano, descrever os fenômenos em um MIT, nas quais as correntes trifásicas do estator são reduzidas em duas variáveis através de soma vetorial.

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 (A, B e C) do motor (i_A , i_B , i_C), conforme as Equações 2 e 3:


$$i_d = \sqrt{\frac{2}{3}} i_A - \frac{1}{\sqrt{6}} i_B - \frac{1}{\sqrt{6}} i_C \quad (2)$$

$$i_q = \sqrt{\frac{2}{3}} i_A - \frac{1}{\sqrt{6}} i_B - \frac{1}{\sqrt{6}} i_C \quad (3)$$

Assim, com o MIT trabalhando em condições de operação simétrica e balanceada, a corrente do motor pela abordagem do vetor de Park é circular e centrada na origem do eixo de coordenadas. Sob condições de falta, este padrão é desviado do centro de acordo com a falta associada. Em condições ideais de funcionamento (motor simétrico), a representação gráfica da componente dq , resultante do vetor de Park, descreve um padrão circular centrado na origem das coordenadas.

A existência de curto-circuito nas espiras dos enrolamentos provoca a transformação do padrão numa elipse, traduzindo-se assim num diagnóstico simples e bastante intuitivo. A Figura 9 ilustra esses dois casos.

Figura 9 – Representação gráfica da resultante do vetor de Park para um motor simétrico (a) e para um motor com defeito no estator (b).



Fonte: Adaptado de Mehala (2012).

b) Monitoramento por Análise de Vibrações

Pode-se definir vibração como qualquer movimento periódico, tal como uma oscilação de uma partícula, de um sistema de partículas ou de um corpo rígido, em torno de uma posição de referência em equilíbrio estático (RAO, 2009).

Além disso, a vibração é a resposta às forças dinâmicas que atuam na máquina, que por sua vez, vibra em várias frequências e níveis de energia que se propagam por toda a máquina. Estas frequências, e também a energia (amplitude) dos sinais no domínio do tempo, podem ser identificadas e, na maioria das vezes, relacionadas a um tipo de falha ocorrendo no equipamento.


Para uma análise quantitativa do valor de vibração, pode-se aplicar diversas formas de leitura das amplitudes dos sinais, onde destacam-se técnicas de medição que levam em consideração as amplitudes das oscilações, como Valor de Pico, Valor de Pico-a-Pico, e os níveis de vibração em função do tempo. Como principal deles tem-se o nível de energia de vibração, chamado Valor RMS (valor quadrático médio ou eficaz). Na próxima seção será abordado essa técnica de análise de vibrações com mais profundidade.

c) Monitoramento de Temperatura por Termografia

A análise termográfica do MIT consiste na captação da radiação infravermelha que os corpos naturalmente emitem quando aquecidos. Através da termografia é possível obter um mapeamento dos componentes do motor com o intuito de distinguir regiões de diferentes temperaturas superficiais, através da visualização artificial da luz dentro do espectro de infravermelhos.

Trata-se de uma técnica para predição de falha não invasiva, baseada no incremento da temperatura (REZENDE FILHO, 2007). Consiste em mapear um equipamento, para detecção de um diferencial de temperatura, correlacionado com uma falha, por meio de câmeras de termo visão e sensores de temperaturas. Através de uma câmara sensível à radiação infravermelha, as leituras são decodificadas numa imagem em escala de cores. As zonas onde a temperatura é mais elevada são representadas em cores quentes (mais claras), conforme visto na Figura 10, sendo que, nessas regiões, existe maior probabilidade de ocorrência de falha. Identifica sobreaquecimentos da carcaça, rolamentos e desalinhamento de eixos.

Figura 10 – Imagem termográfica de um motor em regime de trabalho



Fonte: Adaptado de Rezende Filho (2007).

Também é possível avaliar problemas relacionados com a ventilação do motor que provocam sobreaquecimentos. Outra forma possível de analisar termicamente um motor consiste na medição local de temperatura. Para isso, são utilizados sensores de temperatura embebidos no isolamento dos condutores do estator ou na parte interior da carcaça, que permitem medir a evolução da temperatura de forma precisa

em pontos desejáveis. Como alternativa mais barata, têm sido desenvolvidas soluções de estimação de temperatura, com base na resistência dos enrolamentos do estator. Existem vários tipos de sensores sendo os mais utilizados o termopar, o resistivo e o de silício.

d) Sistemas Computacionais Inteligentes

Nos últimos anos, com os avanços tecnológicos e científicos na área de eletrônica embarcada e de sistemas computacionais, houve um aumento significativo dos trabalhos de pesquisa para sistemas de diagnóstico de falhas em MIT apoiados por sistemas computacionais inteligentes. Nesse contexto destacam-se os sistemas inteligentes baseados em Redes Neurais Artificiais (RNAs), Lógica Fuzzy (LF), Algoritmos Genéticos (AG) e Sistemas Híbridos (utilização de dois ou mais sistemas inteligentes juntos). Uma das principais vantagens no uso de sistemas inteligentes está no fato de sua implementação com baixa complexidade computacional, pois é capaz de determinar o tipo de uma falha num MIT sem necessitar de modelos matemáticos complexos (SANTOS, 2012b).

A Rede Neural Artificial (RNA) apresenta-se como uma das mais versáteis abordagens de sistemas computacionais inteligentes, sendo capaz de organizar as características dos sinais, assim como identificar e diagnosticar falhas presentes nos MIT. A não dependência de modelos matemáticos complexos para sua efetiva implementação, aliada a robustez para o tratamento de incertezas no processamento de sinais, são fatores que as destacaram na resolução de problemas de falhas nesses motores elétricos. No contexto específico de diagnóstico de falhas em máquinas elétricas, o uso da RNA tem sido objeto de consideráveis trabalhos de pesquisas acadêmicas. No artigo de Chow and 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, onde os autores desenvolveram um sistema de detecção em tempo real baseado em RNA para classificação de falhas no isolamento dos condutores do estator e de desgaste nos rolamentos (SANTOS, 2012b). Já no trabalho de Godoy *et al* (2015), encontramos a aplicação de técnicas baseadas em sistemas inteligentes para o diagnóstico e classificação de falhas no enrolamento de estator de um MIT acionado por conversor eletrônico de frequência. Os autores

optaram por monitorar as amplitudes dos sinais das correntes no domínio do tempo, utilizando diretamente um semiciclo da forma de onda para a classificação das falhas.

Pode-se verificar também em pesquisas bibliográficas, como por exemplo, em Santos *et al* (2012b), onde os autores relatam em seu artigo científico a existência de alguns trabalhos acadêmicos com grande êxito no treinamento das RNA para essa proposta, apontando que as falhas de curto-circuito no enrolamento do estator podem ser detectadas e classificadas por RNA com as seguintes arquiteturas: *Perceptron Multicamadas* (PMC) (Ghate and Dudul, 2010; Tallam *et al*, 2003; Bouzid *et al*, 2008; Ghate and Dudul, 2009; Leite *et al*, 2009); *Radial Base Function* (RBF) (Wu and Chow, 2004; Ghate and Dudul, 2011); SOM (*Self-Organizing Maps*) (Ghate and Dudul, 2010); *Elman Neural Network* e *Time Lagged Feed forward Network (TLFN)* (Leite *et al*, 2009).

Por essas características das RNA, nesse trabalho de dissertação optou-se em utilizar esse sistema computacional inteligente, apoiado pela utilização de diafragmas piezelétricos de baixo custo, para desenvolvimento de um sistema preditivo de diagnóstico de falhas elétricas em estatores de MIT.

2.7 Técnicas de Análise de Vibrações em MIT

De acordo com Araújo (2015), a análise de vibração mecânica, como técnica preditiva, é baseada na ideia que as estruturas das máquinas sujeitas a esforços dinâmicos exibem sinais vibratórios, em que a frequência é idêntica àquela dos esforços que a provocam. Todas as máquinas elétricas em funcionamento, principalmente os MIT, produzem vibrações que, aos poucos, levam-nas a um processo de deterioração. Essa deterioração é caracterizada por uma modificação da distribuição de energia vibratória pelo conjunto dos elementos que constituem a máquina. Observando a evolução do nível de energia de tais vibrações, é possível obter informações sobre o estado da máquina.

Pode-se definir o fenômeno da vibração como a oscilação de um corpo em torno de uma posição de referência, sendo caracterizado como um processo destrutivo, pois ocasiona defeitos nos elementos das máquinas por fadiga dos materiais. Ela aparece como resposta às forças dinâmicas que atuam na máquina, que por sua vez, vibra em várias frequências, que se propagam por toda a máquina.

Estas frequências podem ser identificadas e, na maioria das vezes, relacionadas a um tipo de falha.

Sabe-se que toda máquina apresenta ruído e vibração devido à própria operação e a excitações externas. Contudo, uma parcela das vibrações se deve a pequenos defeitos que comprometem a performance do equipamento. O aumento do nível de vibração é reflexo do agravamento do defeito. O que faz da análise de vibrações um processo eficiente, é o fato de que cada elemento da máquina induz uma excitação própria, gerando formas específicas de vibração. É justamente por essa razão que os defeitos nesses elementos podem ser detectados.

Várias são as formas de monitoramento da condição de máquinas elétricas rotativas utilizando análise de vibração. Entretanto, de maneira geral, esses sistemas de instrumentação para a monitoramento periódico de vibração podem ser agrupados em 2 técnicas: técnicas de medição do nível global no domínio do tempo, e técnicas de medição de vibração com análise no domínio da frequência (ARAÚJO, 2015).

Na técnica de manutenção preditiva em MIT, para se medir o nível de vibração desses equipamentos de uma maneira mais abrangente, destaca-se a medida do Valor do Nível Global de Vibração (em inglês *Overall*), que consiste em expor através de um único número a quantificação das excitações em todas as faixas de frequência (RAO, 2009). Esse parâmetro emprega a medição e compilação da intensidade total de vibração presente nos sinais aquisitados, sendo que o Valor do Nível Global é obtido para quaisquer grandezas que se deseja avaliar (deslocamento, velocidade ou aceleração). De maneira prática, pode se afirmar que consiste em realizar o somatório das influências de cada frequência na energia total de vibração atuando sobre o MIT (CAVALCANTE; JESUS, 2011).

Para a análise de vibrações, o valor de amplitude indica principalmente o grau da falha detectada, podendo variar de acordo com o equipamento, devido suas dimensões, formas estruturais, acesso ao local de medição, entre outros. Pode-se dizer que, para uma mesma condição de medição, quanto maior a amplitude de um sinal captado, maior a energia de vibração sendo gerada no MIT (RAO, 2009).


O monitoramento do Valor do Nível Global é a forma mais direta e importante de monitoramento da condição de um MIT, porque leva em consideração o histórico da onda no tempo, e fornece um valor de nível o qual está diretamente relacionado a energia contida, e portanto, a capacidade destrutiva da vibração. O método sinaliza

que existe um significativo aumento de energia no sinal de vibração, que normalmente é indicativo de evolução de uma falha no equipamento.

Nesse sentido, e de acordo Araújo (2015), com o monitoramento por Valor do Nível Global de vibração tem-se informações sobre o estado geral do equipamento, pois consiste fundamentalmente na aferição da amplitude de vibração, originada pela conjugação de todos os mecanismos de excitação, cuja frequência característica se encontre dentro da banda de análise do equipamento de medição, que abrange a faixa dos 5 Hz aos 5000 Hz. A amplitude do sinal de vibração é a característica que descreve a intensidade da vibração, o que a torna uma importante grandeza a ser observado para o diagnóstico da análise da vibração em um MIT (AGUIAR *et al*, 2012).

Conforme ilustrado na Figura 11, a avaliação do estado global de vibração do equipamento pode ser feita através dos valores de pico do sinal de vibração, ou então recorrendo ao valor eficaz, também denominado por Valor RMS (do inglês *Root Mean Square*). O valor RMS é o mais utilizado pois fornece informações sobre a média de energia contida na onda vibratória, constituindo por isso, um indicador do potencial destrutivo de uma determinada vibração. Já o valor de pico é geralmente mais utilizado quando se pretendem aferir valores de vibração em fenômenos instantâneos, como sejam os mecanismos de choque (SAMPAIO, 2014).

Figura 11 – Principais níveis para medição da amplitude de vibração



Fonte: Adaptado de Sampaio (2004).

Segundo Aguiar *et al* (2012), o critério RMS pode ser expresso pela Equação 4, onde T é o tempo de integração, N o número discreto de amostras no intervalo T , E é a tensão elétrica do sinal e E_i a tensão elétrica da amostra i . Para o caso de


sinais acústicos, que são não periódicos, o sinal é janelado e o tempo de integração é definido como o valor da própria janela, se tratando, então, de uma abstração matemática do valor RMS verdadeiro.

$$V_{RMS} = \sqrt{\frac{1}{T} \int_0^T (E(t))^2 dt} = \sqrt{\frac{1}{N} \sum_{i=1}^N E_i^2} \quad (4)$$

2.8 Características da piezeletricidade

Para a propriedade de polarização que alguns materiais dielétricos desenvolvem, quando submetidos a uma tensão mecânica, dá-se o nome de Piezeletricidade. Nesses materiais, a polarização produzida pela tensão cria cargas e, portanto, um campo elétrico. Reciprocamente, a aplicação de um campo elétrico num material piezelétrico resulta numa deformação mecânica (chamado efeito piezelétrico reverso). Nos dois casos, a mudança no sentido da perturbação produz uma inversão no sentido do efeito. A Figura 12 ilustra, por meio de um modelo bidimensional, como a compressão de um cristal induz um momento de dipolo elétrico na direção da deformação.

Figura 12 – Estrutura interna durante o processo de formação da piezeletricidade



- (a) No cristal em equilíbrio o momento de dipolo elétrico é nulo; (b) o dipolo resultante da deformação mecânica não é nulo.

No cristal sem deformação, visto na Figura 12(a), os três dipolos formados pelo íon A e seus vizinhos (cada carga $\pm e$ é repartida em três) têm momento total nulo. Entretanto, quando o cristal é deformado como indicado na Figura 12(b), os ângulos entre os dipolos produzem um momento resultante na direção da deformação (REZENDE, 2004).

Esse fenômeno foi descoberto pelos irmãos Pierre Curie e Jacques Curie no final do Século XIX. Em grego a palavra *piezein* significa pressão. Uma tensão mecânica em direção ao cristal resulta numa polarização em diferente direção. As grandezas envolvidas na piezeletricidade são tensoriais, não obstante algumas direções particulares dos cristais, os vetores estão na mesma direção. As relações das grandezas escalares podem ser expressas conforme as Equações 5 e 6:

$$D = dT + \epsilon^T E \quad (5)$$

$$S = s^E T + dE \quad (6)$$

Sendo D é a densidade de fluxo elétrico, S deformação mecânica, s^E a constante elástica do material, d a constante dielétrica do material, e o coeficiente ϵ^T que representa a constante de permissividade dielétrica (BAPTISTA, 2010).

Os materiais piezelétricos são utilizados em transdutores, dispositivos que convertem energia elétrica em deformação mecânica, ou vice-versa. Dentre os materiais piezelétricos estão: os titanatos de bário e chumbo, o zirconato de chumbo ($PbZrO_3$), o di-hidrogenofosfato de amônio ($NH_4H_2PO_4$) e o quartzo.


2.9 Sensores piezelétricos de baixo custo

Atualmente, entre os tipos de materiais piezelétricos mais utilizados, destacam-se o titanato de bário ($BaTiO_3$), que é utilizado em transdutores ultrassônicos e, mais recentemente, o titanato zirconato de chumbo ($PbTiO_3 \cdot PbZrO_3$) conhecido como PZT ou diafragmas piezelétricos.

Conforme relata Marchi (2015), quando comparadas com outros materiais piezelétricos, estes diafragmas apresentam algumas vantagens como: bom acoplamento eletromecânico, boa estabilidade, alta rigidez, resposta linear para campo elétrico de baixa intensidade e baixo custo.

A Figura 13 ilustra o aspecto construtivo do diafragma piezelétrico de baixo custo utilizada neste trabalho como sensor de vibração, um modelo similar ao 7BB-35-3 do fabricante Murata (2016).

Figura 13 – Construção do diafragma piezelétrico de baixo custo




Fonte: Adaptado de Murata (2016).

Esses transdutores piezelétricos são constituídos por pequenas placas delgadas de cerâmicas de PZT revestidas, em ambas as faces, por um filme metálico que serve como eletrodo, onde o material piezelétrico é colado sobre uma fina lâmina de latão, e que estão disponíveis em diferentes tamanhos e espessuras (MARCHI, 2015).

Em um elemento piezelétrico deformado por uma fonte de tensão mecânica, a distorção irá se expandir na direção radial, conforme a Figura 14 (a). Caso o material seja comprimido, haverá uma distorção de acordo com a Figura 14 (b). Dessa forma, quando uma tensão alternada é aplicada aos eletrodos, as flexões ilustradas nas Figura 14 (a) e (b) são repetidas de forma cíclica, como mostra a Figura 14 (c), produzindo ondas sonoras (MURATA, 2016).

No desenvolvimento dessa pesquisa, estas membranas piezelétricas foram utilizadas como sensores para aquisição de sinais de vibração monitoradas na estrutura de um MIT, com o objetivo de detectar falhas de caráter elétrico nos estatores dessas máquinas. Após o condicionamento desses sinais, os mesmos são utilizados como dados de entrada para o treinamento de arquiteturas de RNA, que posteriormente classificarão esses defeitos.

Figura 14 – Sistema de oscilação da membrana piezelétrica de baixo busto



Fonte: Adaptado de Murata (2015).

2.10 Sistemas Computacionais Inteligentes

O estudo do funcionamento do cérebro humano tem progredido consideravelmente nas últimas décadas, onde muitos cientistas procuram reproduzir o funcionamento dessa máquina tão poderosa, e ao mesmo, tempo tão complexa. Inteligência Artificial (IA) são sistemas que buscam similaridade de funcionamento ao cérebro humano, principalmente no que tange as questões do armazenamento de memória, autonomia de processamento de informações, aprendizagem por experiência e tomadas de decisões. De acordo com HAYKIN (2001), o termo IA é atribuído ao conceito de um equipamento capaz de realizar um processamento que imita o raciocínio humano na tomada das decisões, sendo necessário para isto a análise dos diversos elementos componentes do processo.

Sistemas inteligentes (SI) fornecem um método padronizado para resolução de problemas importantes, e de bastante complexidade, a fim de obter resultados consistentes e confiáveis ao longo do tempo (BYRD; HAUSER, 1991).

Um sistema de inteligência artificial basicamente possui três características (SAGE,1990):

- Armazenar conhecimento;
- Aplicar o conhecimento armazenado para resolver problemas;
- Adquirir novo conhecimento através da experiência.

Dessa forma entende-se que para realizar tais tarefas citadas acima, os sistemas inteligentes devem possuir três componentes fundamentais: a aprendizagem, o raciocínio e a representação (SAGE, 1990).

Para o elemento de aprendizagem de um sistema inteligente, o ambiente ou um usuário fornecem dados ao sistema que forma a base de conhecimento para executar uma determinada tarefa (HAYKIN, 2001). Frequentemente, a informação fornecida tem imperfeições e, então, o sistema inteligente deve revisar as hipóteses segundo uma realimentação dos dados.

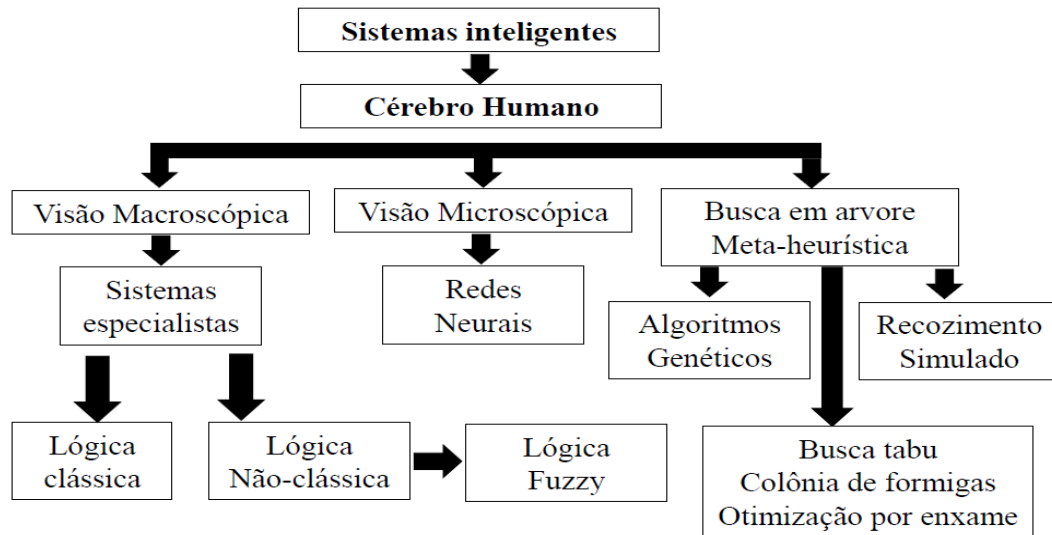
No que tange ao raciocínio, ou seja, habilidade de resolver problemas, para um sistema ser qualificado, Haykin (2001) preconiza que ele deve satisfazer algumas condições:

- O sistema deve ser capaz de resolver uma vasta gama de problemas e tipos de problemas;
- Necessita-se que seja capaz de tornar conhecidas as informações implícitas e explícitas;
- Deve necessariamente possuir um mecanismo de controle que determine quais operações devem ser aplicadas, quando uma solução for encontrada, ou quando deve ser encerrado o tratamento deste problema.

Já a representação consiste no uso difundido de uma linguagem simbólica para representar, tanto o conhecimento genérico, quanto um conhecimento específico de um problema. Em um sistema inteligente, o conhecimento significa o aparato de dados de um problema. Conforme ilustrado na Figura 15, existem diversas ferramentas de SI já consolidadas, inclusive no meio acadêmico principalmente, sendo que pode-se destacar como mais difundidas:

- a) Sistemas de produção: visa caracterizar a heurística e os conhecimentos de especialistas humanos por meio da aplicação de conceitos de lógica;
- b) Lógica nebulosa: visa considerar as incertezas inerentes à representação humana dos fenômenos da natureza, refletida nas expressões verbais empregadas corriqueiramente, na verbalização humana;
- c) Redes neurais artificiais: uma das ferramentas mais conhecidas e exploradas de IA, trabalha no sentido de mimetizar o cérebro humano por meio de elementos processadores simples, denominados neurônios artificiais (HAYKIN, 2001).

Figura 15 – Representação organizacional dos sistemas inteligentes



Fonte: Clerice (2014).

2.11 Redes Neurais Artificiais

Redes neurais artificiais (RNA) são sistemas neuro-adaptativos, tal que, para apresentarem um bom desempenho, normalmente necessitam que um treinamento seja previamente realizado, ajustando seus pesos, de forma a produzirem respostas desejadas, conforme os padrões de entradas (HAYKIN, 2001). São modelos computacionais inspirados no sistema nervoso de seres vivos, e possuem a capacidade de aquisição e manutenção do conhecimento. Nesse sentido, podem ser definidas como um conjunto de unidades de processamento, caracterizadas pelos neurônios artificiais, que são interligadas por um grande número de conexões denominadas “sinapses artificiais”, a qual, matematicamente, são representadas por vetores e matrizes de pesos sinápticos (SILVA *et al*, 2010). Possuem grande potencial para serem aplicadas em diversas áreas do conhecimento como por exemplo a avaliação de imagens captadas por satélite, classificação de padrões de escrita e fala, controle de trens de alta velocidade, identificação de anomalias em imagens médicas, etc. As características principais envolvidas nas aplicações das Redes Neurais são (HAYKIN, 2001; SILVA *et al*, 2010):

- Adaptação por experiência: os parâmetros internos de uma RNA são ajustados a partir de uma apresentação sucessiva de exemplos relacionados ao comportamento do problema em questão;
- Capacidade de aprendizado: por intermédio da aplicação de um método de treinamento, a rede consegue extrair o relacionamento entre diversas variáveis em questão;
- Habilidade de generalização: após o treinamento de uma rede, essa é capaz de generalizar o conhecimento adquirido, retornando soluções para casos ainda não conhecidos;
- Organização interna de dados: baseada nas características dos dados de aprendizado de uma rede, ela é capaz de agrupá-los em características comuns;
- Tolerância a falhas: devido ao elevado índice de interconexões, uma RNA é tolerante a falha quando sua estrutura é minimamente corrompida;
- Detém facilidade de prototipagem em hardware e software.

O desenvolvimento de computadores com maior capacidade de processamento e a criação de algoritmos de otimização eficientes e robustos facilitaram os estudos e desenvolvimentos das RNAs. Com isso, multiplicaram-se as potenciais áreas passíveis de aplicações desse sistema inteligente, principalmente nas que estão relacionadas às engenharias e ciências (SILVA *et al*, 2010). Assim, pode-se destacar as principais aplicações destes modelos computacionais e seus objetivos:

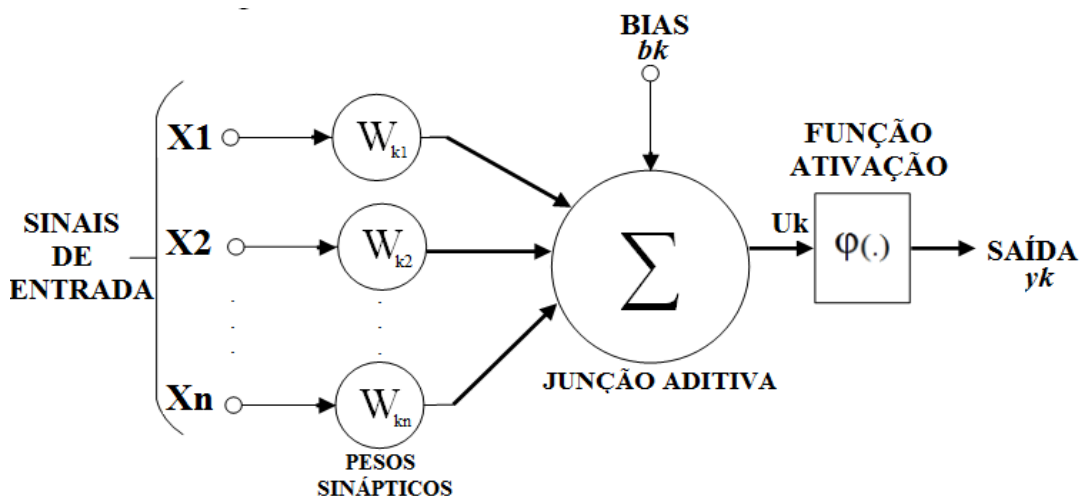
- a) Agrupamento de dados (*clusterização*): é a capacidade de identificação e detecção de similaridades entre diversos padrões para o agrupamento;
- b) Aproximador universal de funções: consiste em mapear o funcionamento entre variáveis de um sistema, cujas modelagens convencionais são de difícil obtenção;
- c) Controle de processos: consiste em identificar ações de controle que permitem a qualidade, eficiência e segurança de processo. Aplicados em robótica, aeronaves, eletrodomésticos;
- d) Classificação de padrões: consiste em associar padrões de amostras para uma das classes previamente definidas. Aplicadas em reconhecimento de

voz, imagem, etc. O problema deve possuir um conjunto discreto e conhecimento das possíveis saídas desejadas;

- e) Sistemas de previsão: têm o objetivo de estimar valores futuros de um determinado processo considerando medidas prévias observadas em seu domínio. Nas aplicações enquadram-se: a previsão de séries temporais, previsões de mercados financeiros, previsões climáticas, etc.;
- f) Otimização de sistemas: tende a minimizar ou maximizar uma função custo obedecendo as restrições impostas pelo problema, sendo tratados com otimização restrita, programação dinâmica e otimização combinatorial;
- g) Memória Associativas: a recuperação de padrões corretos mesmo se os elementos que o constituem se apresentam de forma incerta ou imprecisa. Aplicados a processamento de imagens, transmissão de dados e identificação de caracteres, etc.

A unidade básica de processamento que formam as RNA é chamada neurônio artificial (HAYKIN, 2001). De acordo com Spatti (2011), a Figura 16 ilustra o modelo proposto por McCulloch e Pitts, o qual possui n terminais de entrada (x_1, x_2, x_3, x_n), que representam os dendritos, e um terminal de saída (y), que representa um axônio.

Figura 16 – Modelo de neurônio artificial



Fonte: Adaptado de Haykin (2001).

Os terminais de entrada do neurônio são influenciados pelos pesos sinápticos (w_1, w_2, w_3, w_n), com o intuito de simular o comportamento das sinapses.

O produto de uma entrada x_i , pelo seu peso sináptico w_i , corresponde ao efeito de uma sinapse particular i no neurônio.

Segundo Spatti (2011), o modelo matemático que descreve o comportamento do neurônio artificial é dado pela Equação 7 a seguir:

$$y = \varphi \left(\sum_{i=1}^n w_i x_i + b \right) \quad (7)$$

Onde:

n é o número de entradas do neurônio;

w_i é o peso associado a i -ésima entrada;

b é o limiar associado ao neurônio;

x_i é a i -ésima entrada do neurônio;

$\varphi(.)$ é a função de ativação do neurônio;

y é a saída do neurônio;

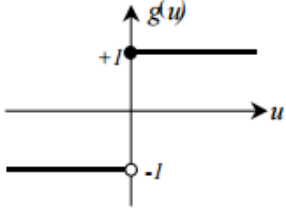
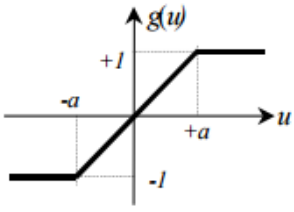
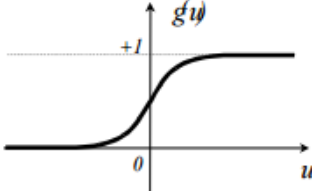
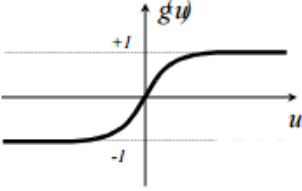
De acordo com esse modelo, o funcionamento do neurônio artificial ocorre no momento em que os sinais são aplicados à entrada e cada sinal é multiplicado por um peso correspondente à sua relevância na saída da unidade.

Em seguida, é realizada uma soma dos produtos sinais-pesos e caso esse resultado exceda um certo limite (*threshold*), a unidade produzirá uma saída. O valor da saída pode ser binário (0 ou 1), bipolar (-1 ou 1) ou real, de acordo com a função de ativação utilizada (SPATTI, 2011).

As funções de ativação mais utilizadas são mostradas na Figura 17.

A arquitetura de uma rede neural artificial determina a forma como os neurônios são dispostos e o direcionamento de suas conexões sinápticas (HAYKIN, 2001).

Figura 17 – Representação das principais funções de ativação

Função Degrau (bipolar)	Função rampa
	
$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases}$	$g(u) = \begin{cases} 1 & \text{se } u \geq a \\ u & \text{se } -a < u < a \\ -1 & \text{se } u \leq -a \end{cases}$
Função Sigmóide	Função Tangente Hiperbólica
	
$g(u) = \frac{1}{1 + e^{(-\beta u)}}$	$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}}$

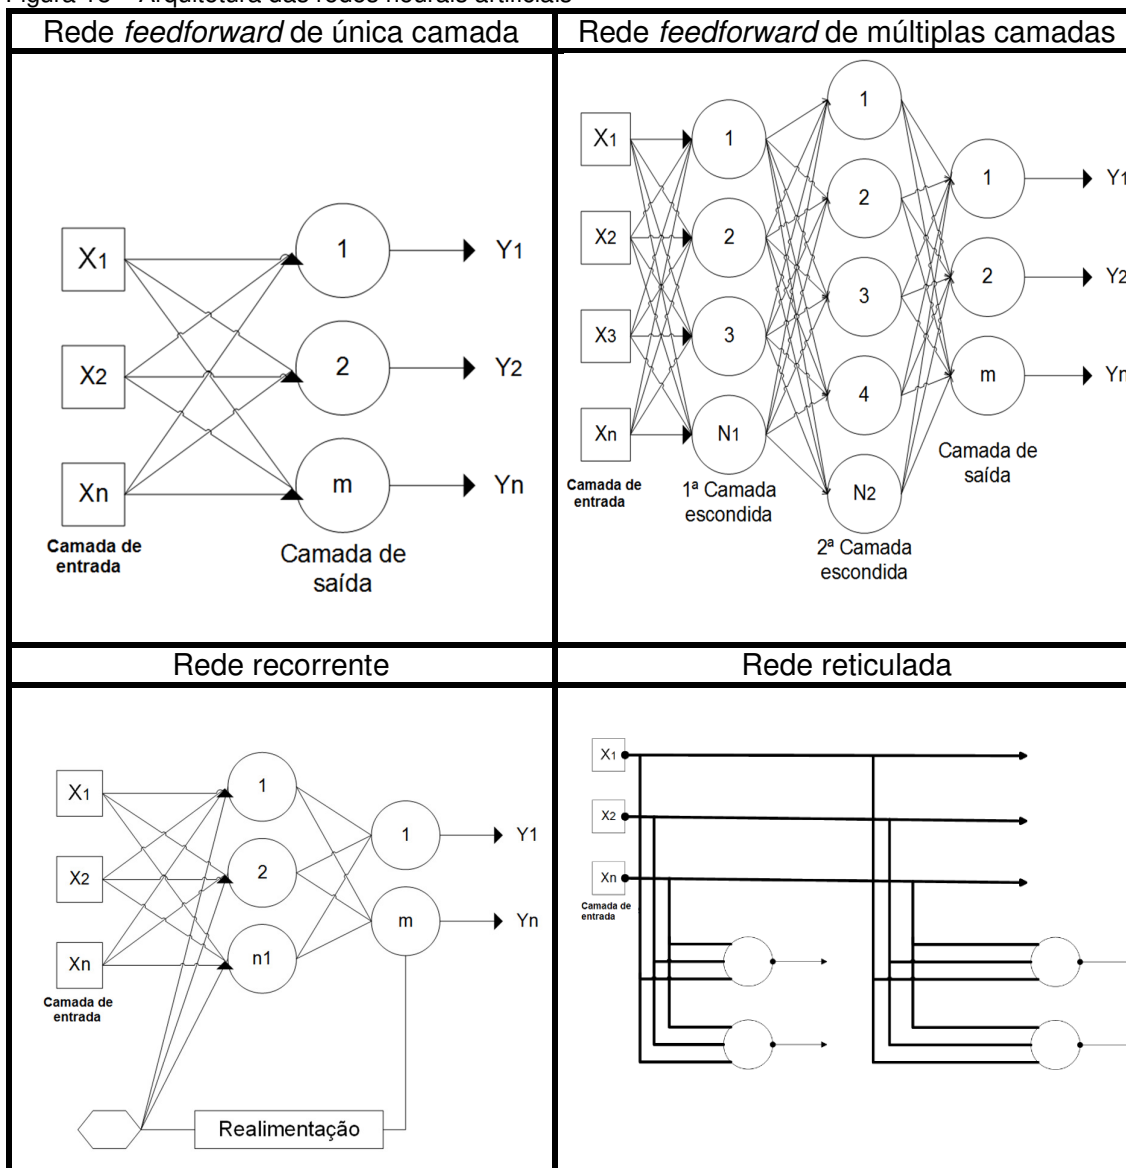
Fonte: Clerice (2014).

A topologia da RNA é caracterizada pela composição que determinada arquitetura de rede neural poderá assumir, ou seja, a quantidade de neurônios da rede, a função de ativação utilizada, entre outras (SILVA *et al*, 2010).

As redes neurais possuem várias arquiteturas, definindo a maneira em que os neurônios estão dispostos um em relação do outro, podendo ser divididas basicamente em redes *feedforward* (alimentação à frente) de camada simples, redes *feedforward* de camadas múltiplas, redes recorrentes e redes reticuladas, conforme ilustrado pela Figura 18 (SILVA *et al*, 2010).

As redes *feedforward*, de camada simples, possuem uma camada de entrada e uma única camada de neurônios, que é também a camada de saída. Dentre os principais tipos de rede com essa arquitetura estão o *Perceptron* e o *Adaline*. Essas redes são mais aplicadas em problemas de classificação de padrões e memórias associativas. Já as redes *feedforward*, de camadas múltiplas, possuem uma ou mais camadas escondidas de neurônios (SILVA *et al*, 2010; SPATTI, 2011).

Figura 18 – Arquitetura das redes neurais artificiais

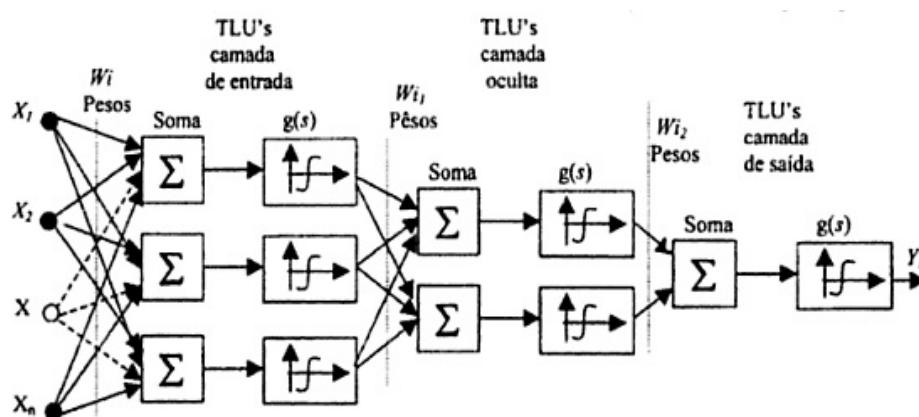


Fonte: Adaptado de Clerice (2014).

Dentre as principais redes que utilizam este tipo de arquitetura estão as redes *Perceptron* Multicamadas (PMC), e as Redes de Base Radial (em inglês *Radial Basis Function* - RBF). Nesta arquitetura, as informações são recebidas pela camada de entrada, depois são processadas pelas camadas escondidas e, por fim, são apresentadas pela camada de saída. De acordo com Spatti (2011) e Silva *et al* (2010), essas redes têm como principais aplicações a utilização para classificação de padrões, identificação de sistemas, aproximação de funções (inclusive não lineares), otimização e robótica. As redes em múltiplas camadas, ilustradas na Figura 19, inovaram porque trouxeram a possibilidade de serem treinadas através de um

algoritmo. As variáveis de entrada podem assumir qualquer valor real e a saída foi aproximada ao modelo do neurônio biológico por uma função de ativação φ (HAYKIN, 2001). A rede neural tipo PMC foi escolhida como uma das arquiteturas para aplicação nessa pesquisa em função de sua grande capacidade de reconhecimento de padrões. Ela executa seu aprendizado a partir do algoritmo *back-propagation*, no chamado aprendizado supervisionado, ou seja, para um determinado valor apresentado em suas entradas, haverá sempre um valor de saída desejado (HAYKIN, 2001).

Figura 19 – Configuração da rede Perceptron Multicamadas



Fonte: Adaptado de Clerice (2014).

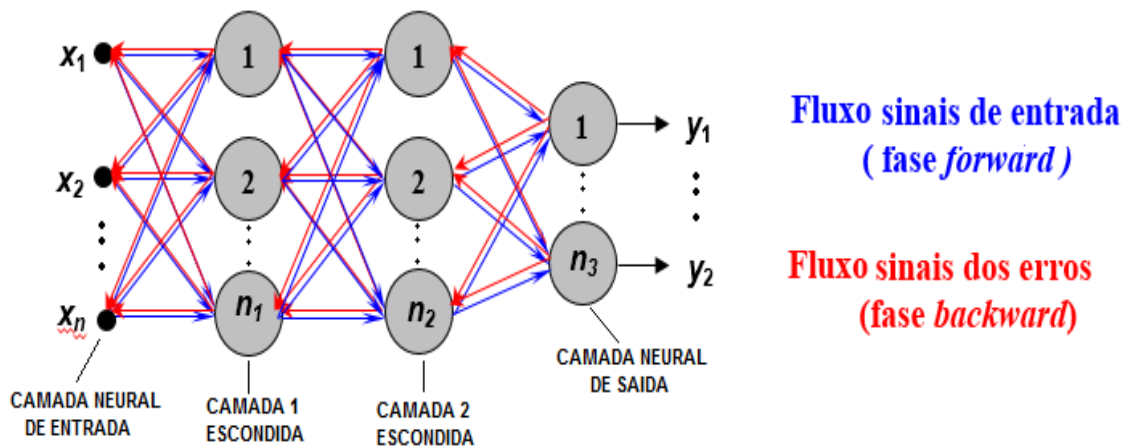
As entradas X_1, X_2, \dots, X_n e os pesos sinápticos das conexões $W_{i1}, W_{i2}, \dots, W_{in}$ são valores reais, tanto positivos como negativos. Quando as entradas trazem características de disparar um neurônio o seu respectivo peso é positivo. Se a característica for inibir o disparo, então o seu peso será negativo. O Processo de treinamento da rede para o reconhecimento de padrões é obtido pela variação dos valores dos pesos das conexões e dos limites.

O processo de treinamento de uma rede neural é dado pela execução de passos ordenados (algoritmo de aprendizagem), em um conjunto de amostras de treinamento, a fim de sintonizar os pesos sinápticos e limiares dos neurônios, cujo objetivo final é a generalização de soluções a serem produzidas pelas saídas da rede (HAYKIN, 2001; SILVA *et al*, 2010). Basicamente, as estratégias de treinamento são divididas em: treinamento não-supervisionado e treinamento supervisionado. No treinamento não supervisionado, o conjunto de amostras de treinamento não possui as saídas desejadas. Dessa forma, o algoritmo de aprendizado irá detectar

similaridades entre os sinais de entrada, agrupando-os em classes (clusters), a fim de ajustar os pesos sinápticos e limiares. Na estratégia de treinamento supervisionado, o conjunto de amostras de treinamento é composto por sinais de entrada e suas correspondentes saídas desejadas os quais representam o processo. Os pesos sinápticos e limiares são ajustados pelo algoritmo de aprendizado, através da comparação entre a resposta produzida pela rede e a saída desejada, ambos para um dado sinal de entrada, a fim de minimizar o erro entre ambas (SILVA *et al*, 2010). A rede Perceptron Multicamadas, utilizada neste trabalho de pesquisa, faz uso desta estratégia de treinamento.

Segundo Silva *et al* (2010), o processo de treinamento das redes *Perceptron* Multicamadas (PMC), utiliza um algoritmo denominado *backpropagation* ou algoritmo de retro propagação do erro. Este algoritmo de treinamento, conhecido também como regra Delta generalizada, é realizado através da aplicação de duas fases específicas: *forward* e *backward*. A Figura 20 ilustra uma rede PMC constituída por uma camada de entrada, duas camadas escondidas e uma camada de saída, cujas fases *forward* e *backward* são sinalizadas.

Figura 20 – Fases *Forward* e *Backward* em uma rede PMC



Fonte: Adaptado de Ulson (2009).

De acordo com Haykin (2001), na primeira fase do treinamento (*forward*), os sinais de uma amostra do conjunto de treinamento são aplicados à camada de entrada e propagados pelas demais camadas até a produção das respectivas saídas. Esta fase visa obter as respostas da rede e compará-las com as respostas desejadas, obtendo os respectivos erros (HAYKIN, 2001; SILVA *et al.*, 2010). Na segunda fase

(*backward*), são utilizados os erros obtidos na fase anterior, a fim de ajustar os pesos sinápticos e limiares de todos os neurônios da rede, começando pela camada de saída até a primeira camada escondida. As aplicações sucessivas das fases *forward* e *backward* (épocas de treinamentos) implicam em uma diminuição gradativa dos erros (convergência) e, conseqüentemente, no aprendizado da rede (HAYKIN, 2001; SILVA et al., 2010).

Na realidade, durante o treinamento da rede, o processo de convergência do algoritmo *backpropagation* tende a ser lento e exige um elevado esforço computacional, uma vez que ele possui uma aproximação de primeira ordem. Dessa forma, diversas variações do método *backpropagation* têm sido propostas a fim de aumentar a eficiência do processo de convergência (SILVA et al., 2010). Segundo Hagan e Menhaj (1994), uma das técnicas mais utilizadas para esse propósito é o algoritmo de Levenberg-Marquardt. Enquanto que o algoritmo *backpropagation* é um método de descida do gradiente da função erro quadrático, o algoritmo de Levenberg-Marquardt é uma aproximação do método de Newton. Através do método de Levenberg-Marquardt, o processo de treinamento das redes MLP pode ser realizado de 10 a 100 vezes mais rápido que o algoritmo *backpropagation* convencional (HAYKIN, 2001; SILVA et al., 2010; HAGAN; MENHAJ, 1994).

Na maior parte das RNA multicamadas, a função de ativação aplicada a cada neurônio utiliza como argumento o produto escalar do vetor de entrada e do vetor de pesos desse neurônio. Entretanto, encontramos redes multicamadas em que a ativação de um neurônio pode ser função da distância entre seus vetores de entrada e de peso. Destaca-se como exemplo a arquitetura da RNA de Função de Base Radial, em inglês *Radial Basis Function (RBF)*. Comumente chamada apenas rede RBF, tem esse nome devido aos neurônios da camada intermediária utilizarem funções de base radial (BRAGA et al, 2011).

A rede RBF pode ser tratada como uma arquitetura de rede neural, para um problema de ajuste de curva (aproximação) em um espaço de alta dimensionalidade, e possuem como principal característica agirem como se fossem aproximadores universais de funções, podendo ser utilizadas com êxito para identificar sistemas complexos (HAYKIN, 2001). São empregadas em quase todos os tipos de problemas tratados pela RNA PMC, sobretudo aqueles que envolvem aproximação de funções (SILVA et al, 2010). Para tarefas de classificação de padrões, as arquiteturas de RNA RBF têm sido aplicadas com grande sucesso (SUG, 2009).

De acordo com Braga *et al* (2011), estão ilustradas na Tabela 2 as funções radiais mais comumente aplicadas nas RNA RBF, onde tem-se o x sendo o vetor de entrada, μ o centro da função e σ a largura da função.

Tabela 2 - Funções de Base Radial mais comuns

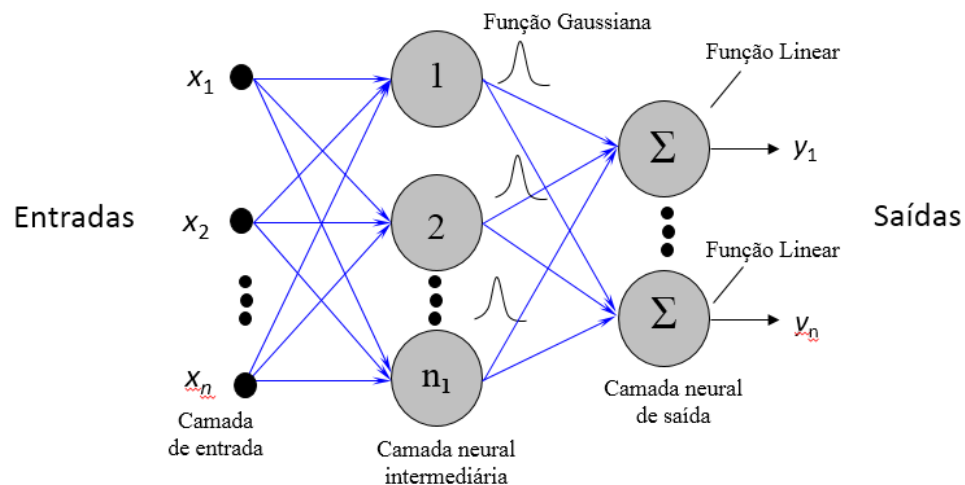
Função Gaussiana	$f(x) = e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \sigma > 0$
Função Multiquadrática	$f(x) = \sqrt{(x-\mu)^2 + \sigma^2}, \sigma > 0$
Função <i>Thin-plate-spline</i>	$f(x) = (x-\mu)^2 \ln(x-\mu)$

Fonte: Adaptado de BRAGA *et al* (2011)

De arquitetura diferente das redes PMC, que podem ser compostas de diversas camadas intermediárias, a estrutura típica de uma RNA RBF é composta por apenas uma camada escondida (HAYKIN, 2001).

Basicamente consiste de uma camada de entrada, que conecta a RNA ao seu ambiente, e apenas uma camada oculta, que aplica uma transformação não-linear do espaço de entrada para um espaço oculto de alta dimensionalidade. A Figura 21 ilustra a arquitetura característica de uma rede RBF.

Figura 21 – Configuração Típica de uma RNA RBF



Fonte: Adaptado de Silva *et al* (2009).

Na RNA RBF predomina a característica de arquitetura *feedforward* de camadas múltiplas, completamente conectadas, com treinamento sendo realizado de forma supervisionada (HAYKIN, 2001; SILVA *et al*, 2010). Nessa rede, cada camada tem uma função específica. A primeira camada, cujos neurônios utilizam funções de base radial, agrupa os dados em grupos (ou *clusters*), por meio de hiper-elipsóides no espaço de padrões de entrada, de forma diferente da RNA PMC que particiona o espaço de entrada através de hiperplanos (HAYKIN, 2001). Esta camada transforma um conjunto de padrões de entrada não-linearmente separáveis em um conjunto de saídas linearmente separáveis. A segunda camada, que é a camada de saída, procura classificar os padrões recebidos da camada anterior (BRAGA *et al* 2011). A distância euclidiana $\|x - \mu\|$ do vetor de entrada x ao vetor centro μ , serve de entrada para a função, que retorna o valor de ativação da unidade intermediária. A resposta gerada em um neurônio k de saída será pela Equação 8 (BRAGA *et al* ,2011; HAYKIN, 2001).

$$y(x) = \sum_{i=1}^k w_{ji} \phi(\|x - \mu\|) + b \quad (8)$$

As RNA do tipo RBF tem seu princípio de funcionamento muito parecido com a RNA PMC, onde cada um dos sinais da entrada são propagados pela subseqüente camada intermediária em direção a camada de saída. Porém, de forma contrária a RNA PMC, a estratégia de treinamento da RNA RBF é classificada como híbrida, uma vez que é dividido em dois estágios diferentes entre si (SILVA *et al*, 2010).

O primeiro estágio, associado com o ajuste dos pesos dos neurônios da camada intermediária, adota um método de aprendizagem auto organizado, onde o número de funções radiais e seus parâmetros são determinados por métodos não-supervisionados, sendo dependente apenas das características dos dados de entrada. Alguns algoritmos não-supervisionados conhecidos para a determinação dos centros das funções de base radial são o SOM (*Self-Organizing Maps*) de Kohonen, o ART e o *k-means* (HAYKIN, 2001). O segundo estágio, ajusta os pesos dos neurônios da camada de saída, e utiliza um critério de aprendizagem similar aquele usado na última camada da RNA PMC. Como a saída dos neurônios da camada

intermediária é um vetor linearmente separável, os pesos podem ser determinados por modelos lineares, como a regra delta, mostrada no Perceptron de camada única (BRAGA *et al*, 2011; HAYKIN, 2001; SILVA *et al*, 2010). As RNA de arquitetura RBF possuem boas características como alta capacidade de generalização, alta tolerância aos ruídos de entrada, capacidade de aprendizagem *on line*, e conseguem generalizar e responder bem a padrões de dados de entrada que não foram utilizados no treinamento (SANTOS, 2013)

3 MATERIAIS UTILIZADOS E METODOLOGIA PROPOSTA

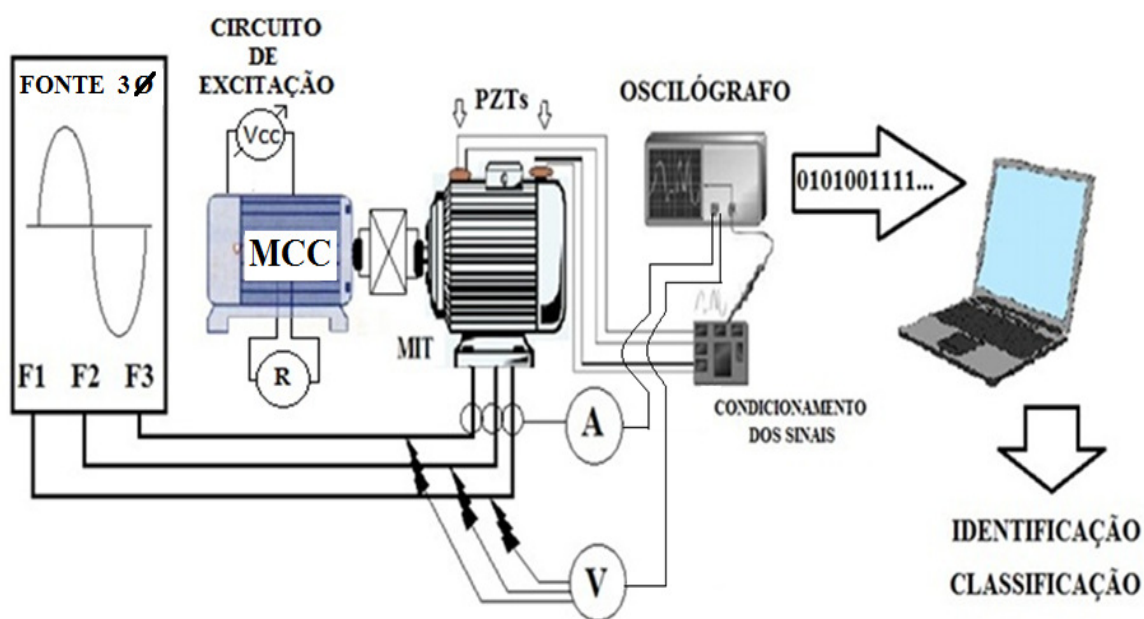
Neste capítulo são abordados questões referentes a metodologia empregada para o desenvolvimento dessa pesquisa, bem como as características dos materiais e equipamentos utilizados nos ensaios, os aspectos metodológicos para o desenvolvimento dos experimentos e aquisição de dados.

Tal metodologia tornou-se necessária para o desenvolvimento da proposta desta dissertação, que é a utilização de diafragmas piezelétricos de baixo custo e redes neurais artificiais para o diagnóstico de falhas no estator de MIT.

Uma forma de elaborar estratégias de classificação das falhas em motores elétricos é por meio do estudo de técnicas de diagnóstico, que consiste em reproduzir as principais falhas encontradas no cotidiano de uma linha industrial, em uma bancada experimental. Esta foi desenvolvida e montada nas dependências do Laboratório de Qualidade de Energia Elétrica (LAQEE), situado na Faculdade de Engenharia Elétrica da UNESP – Campus Bauru / SP.

A Figura 21, ilustra o diagrama esquemático dessa bancada implementada para as simulações de falhas e ensaios

Figura 21 – Diagrama esquemático do sistema proposto implementado para os ensaios com o MIT



Fonte: Autoria própria (2017).

3.1 Preparação do MIT para inserção de simulação de falhas

Para realização dos ensaios, foi utilizado um motor de indução trifásico tipo gaiola de esquilo, fabricado pela empresa WEG, modelo W22 - 3~90, com 2 CV de potência, tensão de acionamento 220/380 V, 60 HZ e 4 pólos, no qual foram realizadas as modificações na sua estrutura interna dando as condições necessárias para promover as futuras inserções de falhas nas bobinas de enrolamento do estator. A Figura 22 ilustra as características e especificações técnicas principais do MIT utilizado.

Figura 22 – Especificações técnicas do Motor de Indução trifásico utilizado na pesquisa


ASPECTO CONSTRUTIVO	ESPECIFICAÇÕES TÉCNICAS
	<p>Fabricante: WEG Modelo: W21 – 3 ~ 90S Rotor: Gaiola de esquilo Potência Nominal: 2CV Número de Polos: IV Tensão Nominal: 220V / 380V Corrente Nominal: 6,12A / 3,54 A Corrente de Partida: 21,7 / 12,6A Rotação Nominal: 1740 RPM Frequência: 60Hz Categoria: N Grau de proteção: IP55 Fator de Serviço: 1,15 Fator de Potência: 0,78 Rendimento: 82,5%</p>

Fonte: Autoria própria (2017).

Este motor foi inteiramente rebobinado para possibilitar a manobra de se inserir oportunamente defeitos nos enrolamentos do estator, viabilizando a simulação dos curto-circuito entre espiras. Durante o processo de rebobinamento, foram acrescentadas saídas de derivações nas bobinas do estator, chamadas aqui de TAP, afim de criar acessos externos as espiras, dando condições para simulações posteriores de situações de falhas.


A Figura 23 ilustra algumas das etapas da etapa de preparação do novo enrolamento do MIT utilizado para realização esta dissertação, e a Figura 24 o aspecto final do MIT já finalizado e montado na bancada.

Figura 23 – Etapas do processo de modificação do estator do MIT



Fonte: Autoria própria (2017).

Figura 24 – Aspecto construtivo final do MIT após rebobinamento e montagem



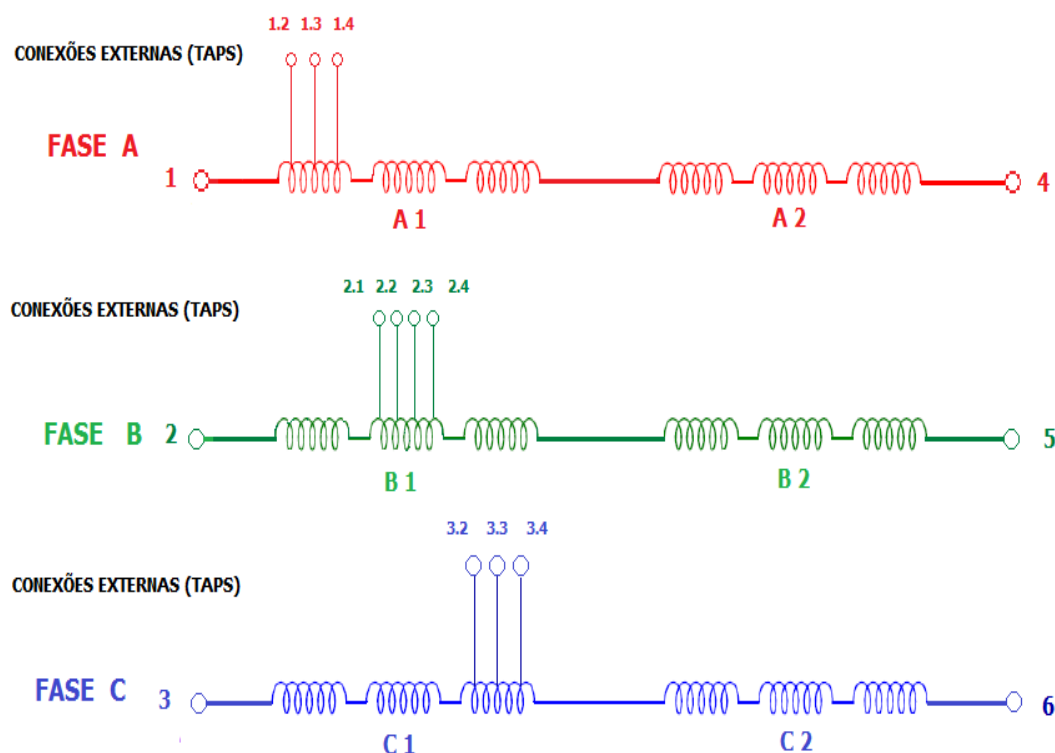
Fonte: Autoria própria (2017).

Em um primeiro momento, o MIT teve todas suas bobinas cortadas e retiradas do estator, e, após limpeza do núcleo, foram inseridas os novos jogos de bobinas nas ranhuras do estator, já com as derivações necessárias para o desenvolvimento da proposta de inserção das falhas simuladas. As falhas entre espiras de mesma fase ocorrem com maior frequência, devido ao posicionamento das mesmas dentro do estator, pois dividem a mesma área por estarem alocadas na mesma ranhura. As bobinas de fases distintas não compartilham a mesma ranhura, nesse sentido a possibilidade de ocorrência de curto-circuito nessa situação é menor. O aumento da temperatura nesse ponto, pode vir a prejudicar a camada isolante dos condutores, desencadeando a degradação do mesmo e evoluindo para um curto-circuito.

No enrolamento de cada fase do estator, com seus respectivos grupos de bobinas, disponibilizou-se opções de conexões conforme ilustrado pela na Figura 25.


Essas derivações foram posicionadas espaçadas igualmente, dividindo-se uma das bobinas de cada fase em segmentos na proporção correspondente a 1/3 do total de espiras da mesma.

Figura 25 – Representação das conexões das bobinas modificadas



Posteriormente, os novos fios das derivações (Taps) foram soldados em terminais conectores e fixados na tampa externa da caixa de ligações elétricas do MIT, e dispostos conforme o diagrama da Figura 26.

Figura 26 – Disposição final dos bornes de acesso as derivações para ligações dos taps




Fonte: Autoria própria (2017).

3.2 Montagem da bancada de ensaios proposta

Para atingir os objetivos propostos por esse trabalho, visando ensaiar as simulações de falhas no estator do MIT, a bancada de ensaios foi desenvolvida para as inserções das falhas de maneira controlada e posterior aquisição dos sinais característicos, consolidados por diversos trabalhos acadêmicos desta área de pesquisa.

A Figura 27 ilustra a montagem completa usada nos ensaios, sendo identificados cada equipamento usado.

Figura 27 – Visão geral da bancada de ensaios montada em laboratório



Fonte: Autoria própria (2017).

Os itens enumerados na Figura 27 são:

- 1 – Fonte de eletrônica de alimentação trifásica linear programável
- 2 – Máquina de corrente contínua (MCC)
- 3 – Motor de indução trifásico (MIT) do tipo rotor gaiola de esquilo, com diafragmas piezelétricos fixados em sua estrutura externa
- 4 – Sensores de efeito hall modelo garra de corrente
- 5 – Oscilógrafo
- 6 – Fonte eletrônica DC simétrica ajustável
- 7 – Multímetro digital
- 8 – Circuito eletrônico para amplificação e condicionamento dos sinais de vibração
- 9 – Circuito eletrônico divisor resistivo para medidas de tensão das fases do MIT
- 10 - Resistências para simulação de curtos-circuitos controlados entre bobinas

- 11 - Transformador variador de tensão alternada monofásico
- 12 - Ponte retificadora
- 13 - Banco de resistências operando como carga para a MCC
- 14 - Barramento de saída da fonte de alimentação trifásica

O acionamento do MIT foi realizado por meio de uma fonte eletrônica de alimentação trifásica programável, modelo AMX-360, do fabricante Pacific Powers Source. Esta fonte tem como característica um controle robusto, assim apresenta uma tensão elétrica estabilizada e se programada para gerar uma forma de tensão senoidal pura sua tensão de saída não apresenta distorção harmônica, eliminando inclusive as distorções oriundas da rede elétrica na qual a fonte é alimentada. Na Figura 28 podem ser vistas suas especificações técnicas principais.

Figura 28 – Especificações Técnicas da Fonte de Alimentação Trifásica

ASPECTO CONSTRUTIVO



ESPECIFICAÇÕES TÉCNICAS


Fabricante: Pacific Power Source
 Modelo: 360 AMX
 Potência Nominal: 6000 VA
 Modo de Acoplamento: Direto
 Tensões de Saída Vrms Max:
 1Ø → 0-338V L- N; 2Ø → 0-600V L- L;
 3Ø → 0-338V L- N / 585V L- L
 Correntes de Saída: 1Ø → 48 Arms;
 3Ø → 16 Arms por fase trifásico
 Frequência de saída: 20 a 5000 Hz
 Fases de saída: 1Ø / 2Ø / 3Ø

Fonte: Autoria própria (2017).

Em seguida, foi utilizado uma máquina de corrente contínua (MCC) de 1,8 kW funcionando como um simulador de carga mecânica para o MIT, e assim, operando como um elemento de variação de carga controlada no sistema. O MCC é o responsável por impor o torque no eixo do MIT, possibilitando assim a simulação dos regimes de trabalho do MIT.

A Figura 29 ilustra as especificações técnicas do MCC. O MIT está acoplado à máquina de corrente contínua através de um acoplamento mecânico flexível e o conjunto fixado em uma base metálica rígida.

Figura 29 – Especificações Técnicas da Máquina de Corrente Contínua

ASPECTO CONSTRUTIVO**ESPECIFICAÇÕES TÉCNICAS****MÁQUINA CORRENTE CONTÍNUA****Motor CC:**

Marca: VARIMOT

Modelo: BN 100L

Excitação Independente

Potência: 1,8 kW

Rotação: 1800RPM

Momento de Inércia: 0,0083kgm

Motor de refrigeração:

Marca: Eberle

Modelo: B63A2


Potência: 1/3 CV

Rotação: 3360 RPM

Fonte: Autoria própria (2017).

Com o intuito de garantir uma boa aproximação nas simulações das situações de regime de trabalho do MIT, por não disponibilizar de um torquímetro, optou-se por realizar inferência indireta dos valores de cargas impostas no regime de trabalho ao eixo do MIT. Através da análise das especificações técnicas e curvas características do motor utilizado, é possível inferir uma correlação entre torque e velocidade do MIT. A Figura 30 ilustra o gráfico da curva Torque x Rotação característica do MIT utilizado.

Figura 30 - Curva Torque x Velocidade característica de um MIT

Fonte: Fitzgerald *et al* (2008).

Dessa forma o conjugado de carga foi obtido a partir da região de operação nominal, ou seja, aquela entre o conjugado nominal (plena carga) e a operação em vazio ($w \sim w_s$). Através dos valores nominais de corrente elétrica, estipulados nas especificações técnicas do MIT, e seus respectivos valores de rotação monitorados utilizando um tacômetro óptico digital, traçou-se uma correlação considerando a variação do conjugado como sendo linear, onde se pode inferir os valores de regime de trabalho do MIT desejados durante os ensaios. A Figura 31 apresenta as características técnicas do tacômetro utilizado.

Figura 31 – Especificações Técnicas do Tacômetro para aferição da velocidade do MIT

ASPECTO CONSTRUTIVO



Fonte: Autoria própria (2017).

ESPECIFICAÇÕES TÉCNICAS

TACÔMETRO ÓPTICO DIGITAL

Especificações

Marca: Instrutherm

Modelo: TD-705

Display LCD 5 dígitos 10mm

Escala de teste: 5 a 100000 RPM

Resolução: 0,1 RPM (0,5 a 999,9RPM);

1RPM (acima de 1000RPM)

Precisão: $\pm (0,5 + 1 \text{ dígito})$

Para o controle da máquina CC operando como gerador, utilizou-se uma fonte de tensão CC variável (V_{cc}) para a alimentação do enrolamento de campo da máquina, através de um circuito formado por um módulo retificador e um variador de tensão (VARIAC) monofásico, com suas especificações ilustrados na Figura 32.

Figura 32 – Especificações Técnicas do Transformador Variador de Tensão

ASPECTO CONSTRUTIVO



Fonte: Autoria própria (2017).

ESPECIFICAÇÕES TÉCNICAS

TRANSFORMADOR VARIADOR DE TENSÃO - VARIAC

Marca: SP

Modelo: ATV-215-M -

Tensão de entrada: 220 VAC

Tensão de saída: 0 a 240VAC

Frequência: 60Hz

Corrente máxima: 6,3A

Potência máxima: 1,5 kVA

Dessa forma, através do ajuste da tensão no enrolamento de campo do gerador CC, consegue-se o variar a carga imposta ao MIT simulando as situações de regime de trabalho desejadas. Utilizou-se também um voltímetro digital, especificado na Figura 33 para monitoramento dessa tensão aplicada.

Figura 33 – Especificações Técnicas do Multímetro Digital

ASPECTO CONSTRUTIVO



ESPECIFICAÇÕES TÉCNICAS

MULTÍMETRO DIGITAL


Fabricante: Agilent
 Modelo: U1252A
 Medidas True RMS (CA, CA+CC)
Data Logging manual e automático
 Precisão CC: 0,025%
 Tensão máxima: 1000V
 Corrente máxima: 10A
 Frequência: 1MHz
 Resistência máxima: 500MΩ

Fonte: A autoria própria (2017).

Na armadura da máquina CC conectou-se um banco resistivo de potência, ilustrado na Figura 34, para atuar como carga dissipativa para o gerador.

Figura 34 – Especificações Técnicas do Banco Resistivo utilizado como carga para MCC

ASPECTO CONSTRUTIVO



ESPECIFICAÇÕES TÉCNICAS

BANCO RESISTIVO

Especificações

Número de resistências usadas: 04
 Potência individual: 400W
 Tensão individual: 127V
 Resistência individual: 40,32
 Fechamento: sequência de pares em série ligados em paralelo

Fonte: A autoria própria (2017).

Para simulação das falhas de curto-circuito inseridas nas espiradas das bobinas do estator do MIT, optou-se pela utilização de impedâncias resistivas, para a simulação dos graus de comprometimento da camada isolante dos condutores que compõem essas bobinas, ou seja, simular os níveis de deterioração do material isolante.

A ideia da utilização das impedâncias inseridas nas bobinas tem o intuito de evitar danos ao MIT, assim amenizando o efeito de um curto-circuito franco, ou seja, acarretando a destruição da bobina.

É importante ressaltar que essa escolha levou em conta a diferença de potencial entre os terminais de cada TAP do MIT ser relativamente alta, o que provocaria grandes avarias no momento da inserção de uma ligação direta com fios (*jumper*) no fechamento entre eles.

Essas impedâncias foram sistematicamente conectadas aos terminais das derivações disponibilizados na caixa de ligação do MIT, simulando falhas de curto-circuito entre as espiras de uma bobina de uma mesma fase.


Desta forma, com as resistências sendo inseridas no MIT de forma em série no circuito elétrico do MIT, foi possível simular a variação da degradação da camada do isolamento dos condutores, que nas condições reais de trabalho do MIT em campo, ocorre progressivamente até que o curto seja direto, ou seja, com resistência nula.

Como o intuito desta pesquisa é simular falhas elétricas no estator do MIT, mas identificá-las de forma incipiente, foram utilizadas impedâncias resistivas que representam, respectivamente: falha leve (36Ω) simulando uma degradação inicial leve do isolante dos fios condutores, ou seja, uma falha no início; falha moderada (9Ω) para simulação da avaria já progredindo e aumentando o rompimento da camada de isolamento dos fios das outras bobinas adjacentes; e a falha severa ($2,5\Omega$) representando um alto comprometimento na camada de isolamento dos fios (curto-circuito direto), ou seja, uma degradação significativa na isolamento dos condutores.

Como já comentado aqui nesse trabalho, a importância da detecção de um curto-circuito de maneira incipiente se verifica em razão da possibilidade de evitar que o dano se propague para espiras e bobinas em sua proximidade.

Nesse sentido, foram utilizadas 3 resistências elétricas de potência, com os terminais disponibilizados em conectores, conforme ilustrado na Figura 35.

Figura 35 – Impedâncias resistivas utilizadas nas simulações das falhas de curto-circuito controladas



Fonte: Autoria própria (2017).

Os valores da tensão de alimentação trifásica foram adquiridos utilizando-se as pontas de prova do próprio oscilógrafo, sendo que, para preservar a integridade desse instrumento, optou-se por uma medição atenuada através de uma placa com um divisor de tensão resistivo, para atenuação dos valores de tensão em contato com as entradas do oscilógrafo.


Entretanto, esses valores tensão não foram utilizados como entradas para o treinamento das RNAs, apenas serviram para monitoramento do sistema durante os ensaios.

Os sinais mecânicos de vibrações foram adquiridos utilizando-se diafragmas piezelétricos de resposta rápida e baixo custo, modelo similar ao 7BB-35-3 do fabricante MURATA (MURATA, 2016), conforme ilustrado na Figura 36.

Na pesquisa de Clerice (2014), tem-se informações que validam a proposta de aplicação do diafragma piezelétrico como sensor de vibração para utilização em MIT.

Foi realizado um estudo do comportamento de reposta em frequência desses diafragmas em comparação aos sensores de vibração comerciais já consolidados no mercado, e realizado ensaios de resposta à impulsos mecânicos, como por exemplo o teste do grafite, onde ficou demonstrado que o diafragma piezelétrico possui boa resposta para frequência baixas, com uma faixa de trabalho indo até 400 kHz.

Figura 36 – Aspecto construtivo do diafragma piezolétrico de baixo custo utilizado




Fonte: Adaptado de Murata (2016).

Para fixação mecânica desses diafragmas na estrutura externa do MIT foi utilizado um adesivo químico a base de Cianoacrilato.

Dessa forma, para aquisição dos sinais de vibração foram fixados na carenagem externa do MIT, conforme ilustrado na Figura 37, quatro diafragmas piezolétricos como alternativa para substituir a utilização de sensores de vibração de alto custo já consolidados no mercado.

Figura 37 – Disposição da fixação dos diafragmas piezolétricos no MIT



Fonte: Autoria própria (2017).

O critério para escolha das posições de fixação dessas cápsulas foi apoiado nas normas de análise de vibração em MIT, como a ABNT NBR 11 390 (Medição - Avaliação e limites da severidade de vibração mecânica de máquinas de altura de eixo igual ou superior a 56 mm – Especificação).


Essa norma preconiza que, conforme ilustrado na Figura 38, os pontos de fixação 1, 2 e 3 devem estar próximos ao apoio dianteiro e os pontos 4,5 e 6 próximos ao apoio traseiro. A seta ao lado do ponto indica a direção, assim, os pontos 1 e 4 estão na direção radial horizontal, os pontos 2 e 5 na direção radial vertical e os pontos 3 e 6 na direção axial.

Caso não seja possível fixar o sensor de vibração diretamente sobre o apoio indicado, deverá ser colocado o mais próximo possível. Além disso, deve-se colocar o sensor de medição sobre superfícies que oferecem rigidez adequada,

Entretanto, o aspecto construtivo e as características geométricas de fabricação dessas diafragmas piezelétricos implicam em uma limitação técnica na forma e local de fixação das mesmas. Isto implica na necessidade de uma superfície plana o suficiente tanto quanto do seu diâmetro para uma correta fixação dos mesmos na carcaça do MIT.

Neste trabalho, optou-se pela fixação de maneira análoga as indicadas pela Figura 38, nas regiões das posições 1 e 4 da referida figura, espelhadas no eixo horizontal, sendo dois diafragmas dianteiros e dois traseiros.

Figura 38 – Pontos normalizados para medição de vibração em MIT



Fonte: WEG (2012).


3.3 Sistema de aquisição, amplificação e condicionamento dos sinais

Devido os sinais aqisitados pelos diafragmas piezelétricos possuírem amplitude de tensão relativamente pequena em suas formas de onda (na faixa de 20 mV), se fez necessário a amplificação dos sinais, para uma melhor resolução, antes de suas aquisições e registros pelo oscilógrafo.

Para isso fez-se uso do circuito integrado amplificador de instrumentação INA128P, do fabricante TEXAS INSTRUMENTS, com ganho de 20 dB. Além da amplificação, o circuito comportou-se como um filtro *anti-aliasing*.

O esquema básico do circuito eletrônico desenvolvido para o amplificador está ilustrado na Figura 39.

Figura 39 – Diagrama eletrônico do circuito amplificador para sinais dos diafragmas piezelétricos




Fonte: Clerice (2014).

Esse circuito foi montado em uma placa de circuito impresso implementada por Clerice (2014), contendo oito amplificadores operacionais de instrumentação, conforme ilustrado na Figura 40.

As interligações entre os diafragmas piezelétricos e a placa foram realizadas por meio de cabos flexíveis blindados, todos de mesmo tamanho, para que as possíveis impedâncias e capacitâncias não influenciassem nos resultados.

Figura 40 – Reprodução gráfica da placa de circuito impresso com oito amplificadores INA128P



Fonte: Clerice (2014).

O registro dos dados de corrente elétrica foi realizado utilizando-se sensores de efeito *Hall* tipo garra de corrente, de fabricante TEKTRONIX, conforme mostrado na Figura 41.

Figura 41 – Especificações Técnicas do Sensor de Corrente

ASPECTO CONSTRUTIVO



ESPECIFICAÇÕES TÉCNICAS

Fabricante: TEKTRONIX
 Modelo: A622 AC/DC CURRENT
 Entrada: 0 – 70 A RMS 100 A pico em AC ou DC
 Saída: 10 mV/A, 100mV/A
 Faixa de Frequência: DC a 100kHz
 Conexão: BNC

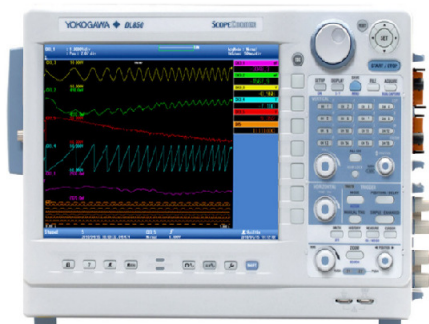
Fonte: Autoria própria (2017).

Foram utilizados três sensores tipo garra de corrente, um para cada fase da alimentação elétrica do MIT, e todos ligados diretamente através de seus conectores nos canais de entrada do oscilógrafo.

Após aquisição dos sinais pelos sensores, os dados foram registrados utilizando um oscilógrafo digital da marca YOKOGAWA, modelo DL - 850, cujas características estão ilustradas na Figura 42.

Figura 42 – Especificações do Oscilógrafo Digital

ASPECTO CONSTRUTIVO



ESPECIFICAÇÕES TÉCNICAS

Fabricante : YOKOGAWA

Modelo: DL 850

Canais isolados (14 canais disponíveis), 10 MS/s por canal, 12 bits, memória interna de 10 MWord/canal
Faixa de ajuste do eixo de tempo: de 100ns/div a 3 dias/div;

Triggers auto, auto level, normal, single, single N e avançados com recurso de pré-trigger e pós-trigger configuráveis;


Drives para dispositivos de armazenamento: slot para SD Card (até 16GB) e porta USB para pen drive.

Fonte: Autoria própria (2017).

A aquisição ocorreu a uma taxa de amostragem de 2 MS/s, sendo que os canais de entrada do instrumento são isolados galvanicamente, com resolução de 12 bits.

Após os sinais serem adquiridos e armazenados na memória interna do oscilógrafo, foi utilizada uma ferramenta computacional para conversão desses dados arquivados no disco rígido do oscilógrafo de extensão wdf para o formato compatível com o *software* MATLAB®. A Figura 43 ilustra uma visão geral do sistema de instrumentação utilizado nas aquisições dos dados durante os ensaios.

Figura 43 – Instrumentação utilizada para aquisição dos sinais de corrente elétrica, vibração e tensão

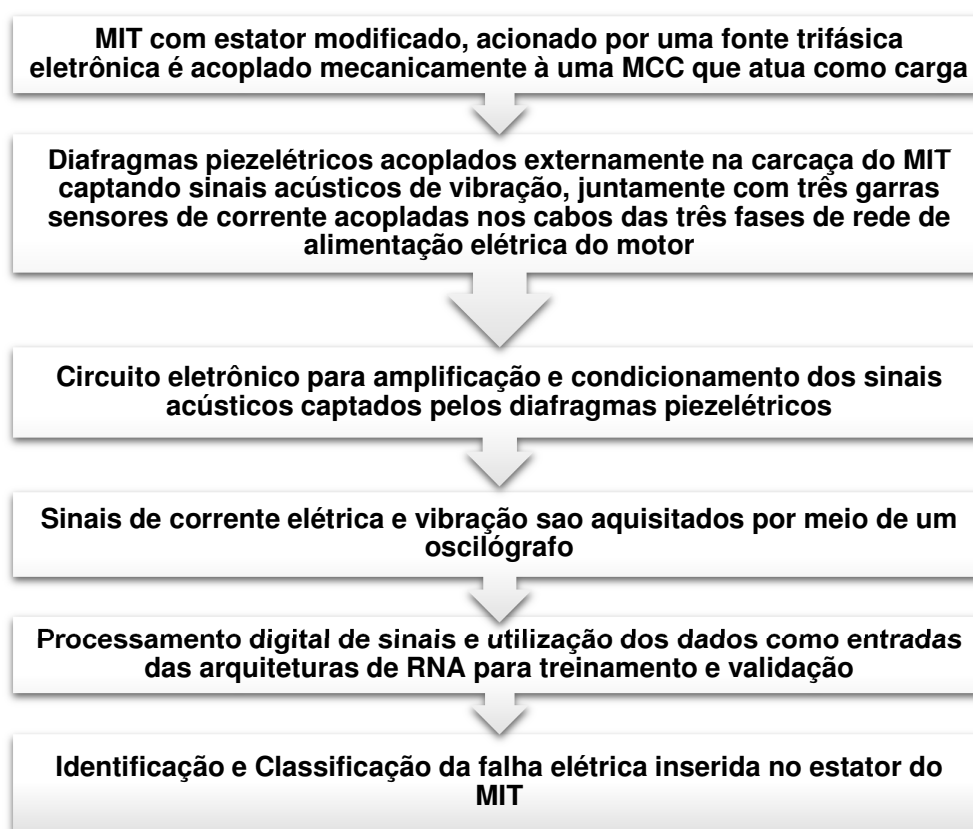


Fonte: Autoria própria (2017).

Em seguida, no MATLAB®, foi desenvolvido uma rotina de programação foi implementado o filtro *Butterworth* de segunda ordem, do tipo passa-banda (10 Hz a 1 kHz), necessário para a eliminação de ruídos de ordens superiores e inferiores, que não caracterizam o fenômeno de interesse.

Após a montagem da bancada de ensaios, visando atingir os objetivos propostos pela pesquisa, deu-se seguimento as ações metodológicas conforme o fluxograma na Figura 44.

Figura 44 – Etapas metodológicas adotadas para o desenvolvimento da pesquisa



Fonte: Autoria própria (2017).


Reproduzir, com precisão, as condições reais de regime de trabalho as quais um motor instalado num processo industrial é submetido, efetivamente, torna-se uma tarefa muito difícil.

A evolução da falha muitas vezes acontece de forma relativamente lenta, muitas vezes somam-se efeitos diversos em uma mesma circunstância, podendo o MIT estar funcionando sob condições de diversas falhas ao mesmo tempo.

Dessa forma, no que diz respeito aos aspectos metodológicos, este trabalho utiliza as leituras das correntes elétricas de estator e os sinais de vibração do MIT, ambos no domínio do tempo, com o MIT em regime de trabalho.

Para a aquisição dos sinais e registro dos dados utilizou-se 7 canais de entrada do oscilógrafo, que faz a amostragem dos sinais simultâneos e não de forma multiplexada, conforme ilustrado na pela Figura 45.

Figura 45 – Aquisição simultânea dos sinais de corrente elétrica e vibração do motor.



Fonte: Autoria própria (2017).

As aquisições dos sinais seguiram uma rotina de ensaios conforme sequência ilustrada na Tabela 3, com as simulações das condições de funcionamento do MIT, denominado por este trabalho como motor simétrico (sem falhas) e inserção de falhas no estator do tipo curto-circuito entre espiras (leve, moderada, severa).

As condições de regime de trabalho do MIT, com a situações de carga de trabalho nominal do MIT também foram ensaiadas, variando-se o carregamento de acordo com a carga imposta ao seu eixo pela máquina CC.

Tabela 3 – Metodologia para realização das simulações de falhas de curto-circuito durante os ensaios

ENSAIOS	FASE MIT	CARGA DE TRABALHO	IMPEDÂNCIA INSERIDA (curto-circuito)	FALHAS
000	-	Vazio	SIMÉTRICO	1
001	-	25% carga	SIMÉTRICO	2
002	-	50% carga	SIMÉTRICO	3
003	-	75% carga	SIMÉTRICO	4
004	-	100% carga	SIMÉTRICO	5
MOTOR SEM CARGA DE TRABALHO IMPOSTA				
ENSAIOS	FASE MIT	FECHAMENTO TAPS DO MIT	IMPEDÂNCIA INSERIDA (curto-circuito)	FALHAS
005	A	TAP 1.2 →1.3	36 Ω (leve)	6
006	A	TAP 1.2 →1.3	09 Ω (moderada)	7
007	A	TAP 1.3 →1.4	36 Ω (leve)	8
008	A	TAP 1.3 →1.4	09 Ω (moderada)	9
009	B	TAP 2.1 →2.2	36 Ω (leve)	10
010	B	TAP 2.1 → 2.2	09 Ω (moderada)	11
011	B	TAP 2.2 → 2.3	36 Ω (leve)	12
012	B	TAP 2.2 → 2.3	09 Ω (moderada)	13
013	B	TAP 2. 3→2.4	36 Ω (leve)	14
014	B	TAP 2. 3→2.4	09 Ω (moderada)	15
015	C	TAP 3.2 →3.3	36 Ω (leve)	16
016	C	TAP 3.2 →3.3	09 Ω (moderada)	17
017	C	TAP 3.3 →3.4	36 Ω (leve)	18
018	C	TAP 3.3 →3.4	09 Ω (moderada)	19
019	C	TAP 3.4 →3.6	36 Ω (leve)	20
020	C	TAP 3.4 →3.6	09 Ω (moderada)	21
021	A	TAP 1.2 →1.3	2,5 Ω (severa)	22
022	A	TAP 1.3 →1.4	2,5 Ω (severa)	23
023	B	TAP 2.1 →2.2	2,5 Ω (severa)	24
024	B	TAP 2.2 → 2.3	2,5 Ω (severa)	25
025	B	TAP 2.3 →2.4	2,5 Ω (severa)	26
026	C	TAP 3.2 →3.3	2,5 Ω (severa)	27
027	C	TAP 3.3 →3.4	2,5 Ω (severa)	28
028	C	TAP 3.4 →3.6	2,5 Ω (severa)	29
MOTOR A 50% DE CARGA DE TRABALHO NOMINAL				
029	A	TAP 1.2 →1.3	36 Ω (leve)	30
030	A	TAP 1.2 →1.3	09 Ω (moderada)	31
031	A	TAP 1.3 →1.4	36 Ω (leve)	32
032	A	TAP 1.3 →1.4	09 Ω (moderada)	33
033	B	TAP 2.1 →2.2	36 Ω (leve)	34
034	B	TAP 2.1 →2.2	09 Ω (moderada)	35
035	B	TAP 2.2 →2.3	36 Ω (leve)	36
036	B	TAP 2.2 →2.3	09 Ω (moderada)	37
037	B	TAP 2.3 →2.4	36 Ω (leve)	38
038	B	TAP 2.3 →2.4	09 Ω (moderada)	39

Continuação Tabela 3

039	C	TAP 3.2 →3.3	36 Ω (leve)	40
040	C	TAP 3.2 →3.3	09 Ω (moderada)	41
041	C	TAP 3.3 →3.4	36 Ω (leve)	42
042	C	TAP 3.3 →3.4	09 Ω (moderada)	43
043	C	TAP 3.4 →3.6	36 Ω (leve)	44
044	C	TAP 3.4 →3.6	09 Ω (moderada)	45
045	A	TAP 1.2 →1.3	2,5 Ω (severa)	46
046	A	TAP 1.3 →1.4	2,5 Ω (severa)	47
047	B	TAP 2.1 → 2.2	2,5 Ω (severa)	48
048	B	TAP 2.2 → 2.3	2,5 Ω (severa)	49
049	B	TAP 2.3 → 2.4	2,5 Ω (severa)	50
050	C	TAP 3.2 → 3.3	2,5 Ω (severa)	51
051	C	TAP 3.3 →3.4	2,5 Ω (severa)	52
052	C	TAP 3.4 →3.6	2,5 Ω (severa)	53
▼ MOTOR A 100% DE CARGA DE TRABALHO NOMINAL ▼				
053	A	TAP 1.2 →1.3	36 Ω (leve)	54
054	A	TAP 1.2 → 1.3	09 Ω(moderada)	55
055	A	TAP 1.3 → 1.4	36 Ω (leve)	56
056	A	TAP 1.3 →1.4	09 Ω (moderada)	57
057	B	TAP 2.1 → 2.2	36 Ω (leve)	58
058	B	TAP 2.1 →2.2	09 Ω(moderada)	59
059	B	TAP 2.2 →2.3	36 Ω (leve)	60
060	B	TAP 2.2 →2.3	09 Ω(moderada)	61
061	B	TAP 2.3 →2.4	36 Ω (leve)	62
062	B	TAP 2.3 →2.4	09 Ω(moderada)	63
063	C	TAP 3.2 →3.3	36 Ω (leve)	64
064	C	TAP 3.2 →3.3	09 Ω(moderada)	65
065	C	TAP 3.3 →3.4	36 Ω (leve)	66
066	C	TAP 3.3 →3.4	09 Ω (moderada)	67
067	C	TAP 3.4 → 3.6	36 Ω (leve)	68
068	C	TAP 3.4 → 3.6	2,5 Ω (severa)	69
069	A	TAP 1.2 →1.3	2,5 Ω (severa)	70
070	A	TAP 1.3 →1.4	2,5 Ω (severa)	71
071	B	TAP 2.1 →2.2	2,5 Ω (severa)	72
072	B	TAP 2.2 →2.3	2,5 Ω (severa)	73
073	B	TAP 2.3 →2.4	2,5 Ω (severa)	74
074	C	TAP 3.2 →3.3	2,5 Ω (severa)	75
075	C	TAP 3.3 →3.4	2,5 Ω (severa)	76
076	C	TAP 3.4 →3.6	2,5 Ω (severa)	77

Fonte: Autoria própria (2017).


3.4 Processamento dos sinais

O processo de extração de características dos sinais é de grande importância para um diagnóstico da falha do MIT. A partir do conjunto de dados de treinamento, as RNAs são capazes de aprender a identificar se há ou não falhas de acordo com o padrão apresentado, e se houver uma falha, classificá-la. Por isso, a extração de características é fundamental para um correto aprendizado das mesmas e, conseqüentemente, um correto diagnóstico.

Como os sinais aqüisitados pelos sensores, tanto de corrente quanto de vibração, são sinais periódicos, optou-se por trabalhar com a análise no domínio do tempo, afim de evitar mais uma etapa de processamento e tratamento matemático, como por exemplo uma Transformada Rápida de Fourier (sigla em inglês - *FFT*) (SAMPAIO, 2014).


As Figuras 46, 47 e 48 ilustram as formas de onda originais no domínio do tempo, para o motor simétrico (sem falhas inseridas) e trabalhando em vazio.

Figura 46 – Formas de onda dos sinais de corrente elétrica do MIT



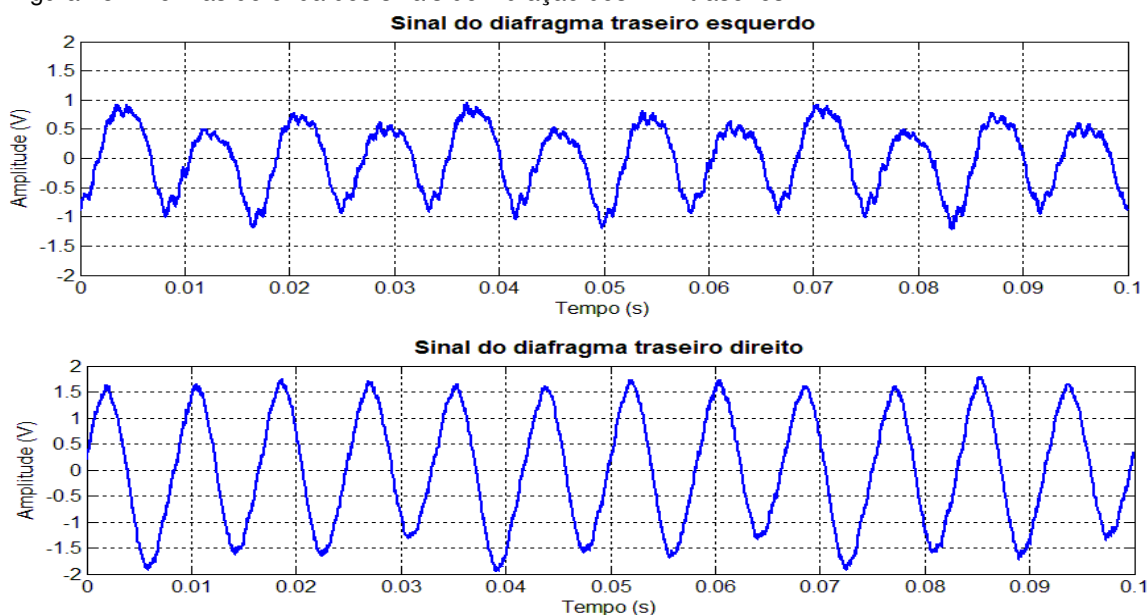
Fonte: Autoria própria (2017).

Figura 47 – Formas de onda dos sinais de vibração dos PZT dianteiros



Fonte: Autoria própria (2017).

Figura 48 – Formas de onda dos sinais de vibração dos PZT traseiros



Fonte: Autoria própria (2017).

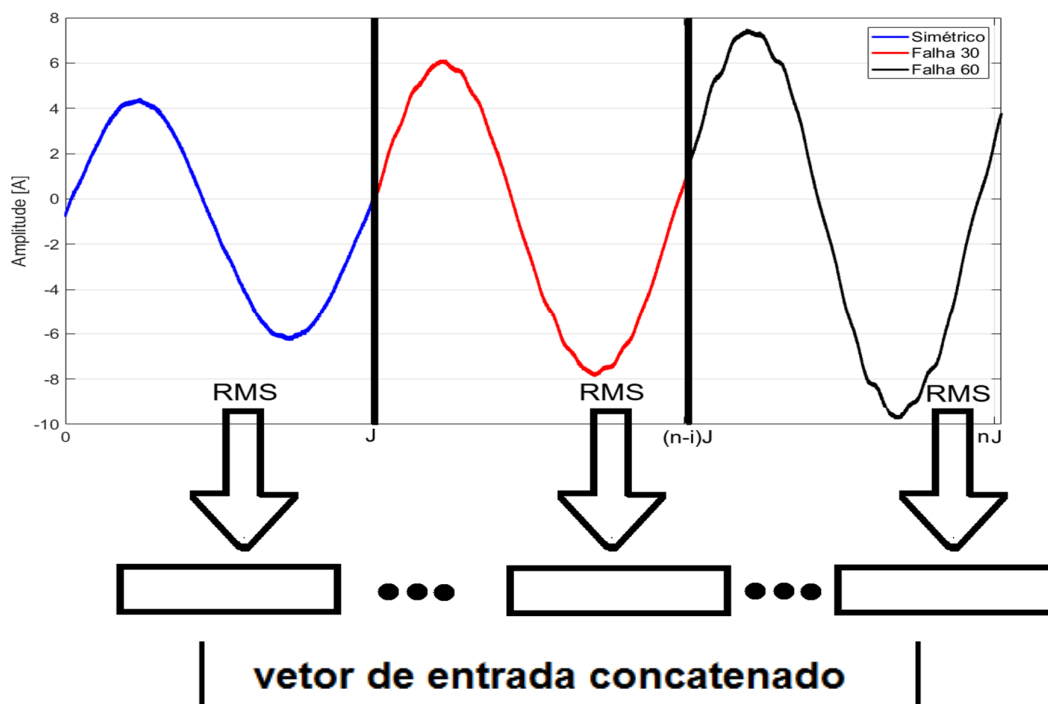
Nesse contexto, observou-se que as formas de onda dos sinais adquiridos apresentavam características inerentes a cada falha. Assim, como o objetivo dessa pesquisa foi o monitoramento das falhas do motor em regime de trabalho, dessa forma, não foram aplicados métodos para análises de transitórios. Esse tipo de análise necessita de diversas técnicas de processamento de sinais e uso de RNAs dinâmicas,

tais como a Rede de Elman e *Time Delay Neural Networking - TDNN* (SANTOS *et al*, 2012b).

Visando a geração do banco de dados de treinamento e validação cruzada para as RNA, procedeu-se com um análise dos sinais no domínio do tempo.

Sendo assim, o critério do valor RMS foi utilizado para gerar os vetores de entradas nas RNAs. Conforme citado no Capítulo 2, o valor RMS é a medida do nível global mais importante nesse tipo de análise, porque leva em consideração o histórico da onda no tempo e dá um valor de nível da amplitude do sinal diretamente relacionado à energia contida nele. Para gerar o conjunto de dados de entrada da RNA, utilizou-se uma rotina implementada em ambiente MATLAB® para tratamento dos dados, onde optou-se por “janelar” um ciclo de onda completo e, em seguida, sub amostrá-lo. Foram registrados pelo oscilógrafo 5 segundos de operação do MIT, em regime de trabalho contínuo, para cada uma das 77 condições de falhas simuladas durante os ensaios. Estudando a forma de onda dos sinais de corrente elétrica, optou-se por dividi-la em janelas, de forma a contemplar um ciclo completo da senóide da corrente, segmento esse denominado como “J”, conforme ilustrado na Figura 49.

Figura 49 – Exemplo de seleção do janelamento sobre o sinal periódico para aplicação do critério RMS



Dessa massa de dados, foram utilizadas 738 (30%) amostras para o treinamento das RNA, e 1725 (70%) das amostras para a validação cruzada.

A Tabela 4 ilustra um fragmento parcial conjunto de dados dos vetores de entradas utilizados para o treinamento das redes neurais artificiais de arquitetura PMC e RBF.

Tabela 4 – Tabela com parcial do conjunto de dados dos Vetores de Entrada de treinamento da rede

Número falha	Ia_RMS	Ib_RMS	Ic_RMS	PZT_1_RMS	PZT_2_RMS	PZT_3_RMS	PZT_4_RMS
61	0,05885	0,06119	0,05845	0,49626	0,03681	0,55275	0,83092
24	0,03646	0,03627	0,03839	0,33429	0,03126	0,56411	1,23478
11	0,03669	0,03669	0,03671	0,35202	0,03089	0,60243	1,10701
8	0,03683	0,03700	0,03626	0,35284	0,02941	0,58349	1,12583
43	0,04525	0,04811	0,04504	0,44771	0,03391	0,58310	0,93344
77	0,05752	0,05841	0,05622	0,56208	0,03466	0,54775	0,71891
33	0,04613	0,04697	0,04518	0,37402	0,03430	0,61459	0,96052
53	0,04526	0,04564	0,04429	0,51200	0,03340	0,55683	1,01084
66	0,05959	0,05979	0,05746	0,55251	0,03628	0,46878	0,81052
54	0,06020	0,06140	0,05865	0,53547	0,03800	0,49893	0,85481
47	0,04725	0,04696	0,04506	0,44761	0,03323	0,58198	0,90206
2	0,04142	0,04030	0,03940	0,42084	0,03325	0,52557	1,14486
57	0,06180	0,06226	0,05939	0,51212	0,03670	0,45097	0,85952
42	0,04752	0,04810	0,04593	0,45735	0,03371	0,52050	0,94777
43	0,04525	0,04811	0,04504	0,44771	0,03391	0,58310	0,93344
51	0,04546	0,04561	0,04435	0,54257	0,03333	0,55949	0,97503
2	0,04142	0,04030	0,03940	0,42084	0,03325	0,52557	1,14486
28	0,03657	0,03842	0,03651	0,31378	0,03275	0,54343	1,07215
43	0,04525	0,04811	0,04504	0,44771	0,03391	0,58310	0,93344
24	0,03646	0,03627	0,03839	0,33429	0,03126	0,56411	1,23478
44	0,04753	0,04763	0,04583	0,46800	0,03503	0,51943	0,95505
60	0,05868	0,06063	0,05767	0,48037	0,03654	0,48849	0,77598
17	0,03683	0,03731	0,03618	0,36308	0,03119	0,58356	1,00434
19	0,03607	0,03751	0,03621	0,41040	0,02990	0,62929	1,06172
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

Fonte: Autoria própria (2017).

3.5 Critérios para treinamento das Redes Neurais Artificiais

Para classificar o estado de funcionamento do MIT, foram implementadas duas arquiteturas diferentes de redes neurais artificiais, com o intuito de se verificar o desempenho de cada uma delas frente a proposta desse trabalho.

Nesse sentido, visando atingir o objetivo proposto, a abordagem desta pesquisa utiliza as redes neurais como classificadoras de padrões. Conforme Silva *et al* (2010), as arquiteturas de rede *Perceptron* Multicamadas (PMC) e Funções de Base Radial (RBF) podem ser empregadas para resoluções de problemas com essas características. Para os treinamento e as operações de testes e validação das redes neurais foram utilizados o toolbox de Redes Neurais Artificiais do *software* MATLAB® (DEMUTH *et al*, 2010).

Como dados de entrada de treinamento das RNA foram utilizados os sinais dos sensores de corrente elétrica e dos diafragmas piezelétricos atuando como sensores de vibração. Esses dados foram obtidos através dos ensaios aos quais o MIT foi submetido na bancada implementada pra simulação das condições de falhas, processados e condicionados no domínio do tempo, e tratados com a métrica Valor RMS. Em seguida, esses dados foram apresentados para as redes como vetores de entrada para treinamento das mesmas, e receberam as nomenclaturas conforme ilustrado pela Tabela 5.

Tabela 5 – Nomenclatura dos sinais de entrada utilizados para alimentação das RNA

ENTRADAS	Nomenclatura
1	Corrente elétrica da fase A (I _A)
2	Corrente elétrica da fase B (I _B)
3	Corrente elétrica da fase C (I _C)
4	Sinal diafragma pzt dianteiro esquerdo (PZT 1)
5	Sinal diafragma pzt dianteiro direito (PZT 2)
6	Sinal diafragma pzt traseiro esquerdo (PZT 3)
7	Sinal diafragma pzt traseiro esquerdo (PZT 4)

Fonte: Autoria própria (2017).

Com o intuito de se verificar, além do comportamento das RNA para classificação das falhas, também a viabilidade de aplicação dos diafragmas piezelétricos como sensores de vibração, adotou-se, como critério metodológico, duas formas distintas de apresentação dos dados para cada uma das arquiteturas de RNA escolhidas. Estas formas foram denominados neste trabalho de “Roteiros”. Importante

ressaltar que as arquiteturas das RNA propostas foram submetidas, dentro das divisões respectivas a cada ROTEIRO, aos treinamentos com o mesmos tipos de dados de entrada.

Em um primeiro momento, no Roteiro I, foram utilizados os sinais aqusitados de corrente elétrica (I_A , I_B , I_C) e vibração (PZT1, PZT2, PZT3, PZT4) como entrada para treinamento e teste de cada topologia da rede PMC, totalizando 7 entradas.

Em seguida, no Roteiro II, para mesma rede, foram utilizados apenas os 4 sinais de vibração dos diafragmas piezelétricos (PZT1, PZT2, PZT3, PZT4).

De forma análoga, para o treinamento da rede RBF, em um primeiro momento, intitulado Roteiro III, foram utilizados os sinais de corrente elétrica (I_A , I_B , I_C) e vibração (PZT1, PZT2, PZT3, PZT4) como entradas para treinamento e teste de cada topologia da rede, totalizando 7 entradas. No Roteiro IV, foram utilizados apenas os 4 sinais de vibração aqusitados pelos diafragmas piezelétricos (PZT1, PZT2, PZT3, PZT4).

Como verificado no Capítulo 2 dessa dissertação, cada tipo de RNA têm suas particularidades, ou seja, as suas arquiteturas e seus modos de treinamento específicos. Nesse sentido, não possuem os mesmo atributos de configuração de topologias e métodos de treinamento e validação.

É importante destacar que, para se iniciar um treinamento, não existe um maneira formal para determinar o tamanho de uma rede. Não há um método determinístico específico para estipular o número inicial de camadas, de neurônios por camadas, de índices e critérios de parada, que definam e indiquem, *a priori*, uma melhor configuração de topologia de uma RNA para mapear determinado problema. Tal dimensionamento depende de fatores como a forma como as matrizes de pesos foram iniciadas, da disposição espacial das amostras, do algoritmo de aprendizagem utilizado, entre outros (HAYKIN 2001; SILVA *et al*, 2010).

Dessa forma, a determinação do tamanho da rede é usualmente feita de forma empírica, e sendo assim, a princípio, esses valores foram inseridos aleatoriamente. Visando encontrar uma arquitetura neural adequada e que exigisse o mínimo esforço computacional, foram realizados vários treinamentos com diversas configurações de topologias para as redes, alterando-se as topologias específicas de cada tipo de RNA trabalhada, a título de experimentação.

Nesse sentido, inicialmente, foram realizadas diversos treinamentos e testes para a RNA PMC, onde foram variados o número das camadas da rede e a quantidade de neurônios por camada, apenas limitando-se a testar um arranjo com até três

camadas neurais. Essas rotinas tiveram o objetivo de selecionar as melhores topologias das RNA para posterior realização dos testes finais e apresentação final dos resultados.

Dessa forma, após os treinamentos aleatórios preliminares, foram elencadas 6 arranjos de topologias de rede, com até 3 camadas neurais, para serem avaliadas e seus dados apresentados.

Para a arquitetura da RNA PMC, o treinamento da rede foi do tipo supervisionado, e um treinamento mais otimizado foi obtido utilizando-se o algoritmo de *Levenberg-Marquardt*. Como função de ativação utilizou-se a função logística Sigmóide, por apresentar uma variação entre 0 a 1 de forma suave, ou seja, um crescimento exponencial em forma de 'S'.

Como critérios de parada de treinamento da RNA PMC, foram utilizados o valor de erro quadrático médio (EQM) por ciclo de treinamento, conforme Equação 9, e o número máximo de épocas ou iterações permitidas.

$$EQM = \frac{\sum_{i=1}^n (r_n - e_n)^2}{n} \quad (9)$$

Sendo que r_n refere-se ao valor real ou desejado para uma determinada falha, e_n refere-se à falha estimada para a mesma amostra, e n é o número de amostras.

O erro quadrático médio desejado foi estipulado em de 10^{-7} , e o valor estabelecido para o número de épocas máximas foi de 1000.

As Tabelas 6 e 7 ilustram as características dos arranjos finais das topologias utilizadas para RNA PMC.

Tabela 6 – Roteiro de treinamento para topologias de rede PMC utilizando todas as entradas de sinais

RNA PMC - ROTEIRO I – TODAS AS ENTRADAS UTILIZADAS					
Número de entradas	Número de neurônios por camada			Critérios de parada	Algoritmo de treinamento
1; 2; 3; 4; 5; 6; 7	1ª	2ª	3ª	EQM ou n ^o de Épocas	<i>Levenberg-Marquardt</i> Função de ativação do tipo Sigmóide
	5	5	5		
	15	15	15		
	5	5			
	15	15			
	10				
	40				

Fonte: Autoria própria (2017).

Tabela 7 – Roteiro de treinamento para topologias de rede PMC utilizando entradas de sinais dos PZT

RNA PMC - ROTEIRO II – ENTRADAS APENAS DOS PZTS					
Número de entradas	Número de neurônios por camada			Critérios de parada	Algoritmo de treinamento
4; 5; 6; 7	1^a	2^a	3^a	EQM ou nº de Épocas	<i>Levenberg-Marquardt</i> Função de ativação do tipo Sigmóide
	5	5	5		
	15	15	15		
	5	5			
	15	15			
	10				
	40				

Fonte: Autoria própria (2017).

Para obter os arranjos de topologias para a RNA RBF, também foram realizados, inicialmente, diversas simulações de treinamentos e testes para a RNA RBF, onde foram variados o valor do parâmetro *spread*, que determina a largura para a função de base radial, na tentativa de se atingir uma taxa de acerto com precisão maior. Assim, após os treinamentos aleatórios preliminares, foram elencadas 6 arranjos de topologias de rede para serem avaliadas e seus resultados posteriormente apresentados e analisados.

Para o criar o projeto da RNA RBF foi utilizado o comando *newrb* do *toolbox* de Redes Neurais Artificiais do *software* MATLAB® (DEMUTH *et al*, 2010). Para a camada oculta dessa rede optou-se por um treinamento otimizado utilizando o algoritmo de agrupamento *k-means*, onde a quantidade de grupos *k* é igual ao número de neurônios da camada escondida. Nessa camada os eletrodos são incrementados um a um até que o critério de parada seja alcançado. Neste caso, o critério utilizado foi à soma do erro quadrático médio. Como critérios de parada de treinamento da rede, foram utilizados o valor de erro quadrático médio (EQM) e o número máximo de épocas ou iterações.

Como função de ativação foi utilizado a função do tipo Gaussiana. No caso da arquitetura da RNA RBF utilizada, basicamente tem-se que encontrar o parâmetro *spread* que traz a melhor generalização da rede. Esse parâmetro representa a largura para função de base radial. Para tanto, optou-se por variar o fator *spread*, que afim de buscar um melhor ajuste da taxa de acerto da rede.

O erro quadrático médio desejado foi estipulado em 10^{-5} . Para a arquitetura de RNA RBF escolhida, o número máximo de iterações ou épocas corresponde ao número de dados de entrada no treinamento da rede.

É importante destacar que a sintonia fina entre precisão e generalização deve ser obtida através da aprendizagem. Assim, de forma a testar a capacidade de generalização e real aprendizado das RNA, foram utilizados 30% do conjunto de dados para treinamento, e 70% para teste e validação.

As Tabelas 8 e 9 ilustram as características dos arranjos finais das topologias utilizadas para RNA PMC.

Tabela 8 – Roteiro de treinamento para topologia de rede RBF utilizando todas as entradas de sinais

RNA RBF - ROTEIRO III – TODAS AS ENTRADAS UTILIZADAS			
Número de entradas	SPREAD	Critério de parada	Algoritmo de treinamento
1; 2; 3; 4; 5; 6; 7	0.2	EQM ou nº de épocas	Algoritmo <i>k-means</i> Função de ativação do tipo Gaussiana
	0.4		
	0.6		
	0.8		
	1		
	2		

Fonte: Autoria própria (2017).

Tabela 9 – Roteiro de treinamento para topologias de rede RBF utilizando entradas de sinais dos PZT

RNA RBF - ROTEIRO IV – ENTRADAS APENAS DOS PZTS			
Número de entradas	SPREAD	Critério de parada	Algoritmo de treinamento
4; 5; 6; 7	0.2	EQM ou nº de épocas	Algoritmo <i>k-means</i> Função de ativação do tipo Gaussiana
	0.4		
	0.6		
	0.8		
	1		
	2		

Fonte: Autoria própria (2017).

3.6 Critérios para validação das RNAS

As RNA foram validadas por meio do critério de validação cruzada descrito por Haykin (2001), onde é avaliada a capacidade de generalização do modelo a partir de um conjunto de dados, buscando verificar se o conjunto de dados de treinamento é representativo o suficiente em relação à base de dados na qual se deseja prever.

Para validação das abordagens propostas, as redes utilizaram durante os processamentos das cinco índices de desempenho. Índices de desempenho são ferramentas que utilizam índices estatísticos e são aplicados na validação do resultado de um experimento. São eles:

- a) Raiz do erro quadrático médio (REQM):** Este índice mostra, em unidades da variável que está sob análise, a dispersão média dos valores das amostras reais e estimadas ao redor da linha de regressão. Quanto menor o valor da REQM, melhor é a qualidade da previsão feita pelo sistema inteligente. A REQM é obtida pela Equação 10:

$$REQM = \sqrt{\frac{\sum_{i=1}^n (r_n - e_n)^2}{n}} \quad (10)$$

Sendo que r_n refere-se ao valor real ou observado para uma determinada amostra, e_n refere-se ao valor estimado para a mesma amostra e n é o número de amostras. A RNA utiliza este índice em seu processamento interno também para gerar o gráfico de evolução de desempenho de treinamento e teste.

- b) Erro absoluto médio (EAM):** Corresponde à diferença algébrica entre o valor medido (falha) e o valor estimado pela rede, divididas pelo número de amostras. A Equação 11 demonstra seu cálculo:

$$EAM = \frac{\sum_{i=1}^n |r_n - e_n|}{n} \quad (11)$$

c) Erro relativo médio (ERM %): Quando se exprimem erros de medições. O modo mais usual é em percentagem, sendo obtido pela divisão do erro absoluto pelo valor real, calculado pela Equação 12:

$$ERM = 100 \frac{\sum_{i=1}^n |r_n - e_n|}{|e_n|} \quad (12)$$

d) Desvio padrão (Dp%): Este índice mostra o quanto de variação ou dispersão existe em relação à média (ou valor esperado). Um baixo desvio padrão indica que os dados tendem a estar próximos da média; um desvio padrão alto indica que os dados estão espalhados por uma gama de valores. O desvio padrão é calculado pela Equação 13:

$$Dp = \sqrt{\frac{\sum_{i=1}^n (r_n - \bar{r})^2}{n - 1}} \quad (13)$$

Sendo que r_n refere-se ao valor real para uma determinada amostra, \bar{r} refere-se à média dos valores reais das amostras e n é o número de amostras.

e) Coeficiente de Correlação Linear (R): é utilizado para verificar o grau de linearidade entre os valores estimados pelo sistema inteligente e os valores reais medidos em laboratório, sendo calculado pela Equação 14:

$$R = \frac{\sum_{i=1}^n (r_n - \bar{r})(e_n - \bar{e})}{\sqrt{(\sum_{i=1}^n (r_n - \bar{r})^2 \sum_{i=1}^n (e_n - \bar{e})^2)}} \quad (14)$$

Sendo que r_n refere-se ao valor real para uma determinada amostra, \bar{r} refere-se à média dos valores reais das amostras, e_n refere-se ao valor estimado para uma determinada amostra, \bar{e} refere-se à média dos valores estimados e n é o número de amostras. Os resultados dos coeficientes de determinação próximos de 1 indicam uma qualidade melhor do grau de ajuste da reta estimada pelo conjunto de dados.

4 RESULTADOS E DISCUSSÕES

Após a abordagem, no Capítulo 3, da metodologia para o desenvolvimento dessa pesquisa, neste capítulo são apresentados os resultados obtidos com os treinamentos das redes neurais, bem como uma avaliação da viabilidade do emprego dos diafragmas piezelétricos de baixo custo como sensores de vibração, no contexto da manutenção preditiva em MIT.

Visando o objetivo da aplicação de sistemas inteligentes do tipo RNA para diagnosticar defeitos em MIT, e com o intuito de se investigar o desempenho e a robustez do sistema proposto, foram realizadas análises dos melhores desempenhos, através de comparações estatísticas entre os dados fornecidos pelas diferentes topologias de redes e de seus gráficos.

Primeiramente são demonstrados os resultados dos treinamentos das redes para cada um dos roteiros propostos, com apresentação das tabelas com os dados e dos gráficos de análise de desempenho das melhores topologias das redes. Nesse momento, optou-se por demonstrar apenas os gráficos das topologias que obtiveram destaque dentro de cada Roteiro.

Por fim, foi realizada uma análise comparativa entre os melhores resultados obtidos em cada roteiro, indicando qual configuração das combinações “RNA-Sensores” testadas, que obteve o melhor resultado frente ao objetivo proposto por essa dissertação.

4.1 Resultados das RNA PMC para classificação das falhas utilizando sinais de corrente elétrica e vibração – ROTEIRO I

Nessa seção são apresentados os resultados obtidos com as RNA PMC após os testes realizados com as combinações de topologias de redes e conjunto de entradas de dados do Roteiro I. Conforme demonstrado pela Tabela 6, esse roteiro utiliza como dados de entrada para as redes os sinais corrente elétrica (I_A , I_B , I_C) e vibração fornecidos pelos diafragmas piezelétricos de baixo custo, denominados aqui nesse trabalho como PZT1, PZT2, PZT3, PZT4.

A Tabela 10 ilustra os resultados para as topologias das redes que obtiveram o melhor desempenho. São demonstrados os valores de taxa de acerto com respectivo

desvio padrão, em valores percentuais, para cada topologia de rede trabalhada, bem como o coeficiente de correlação linear (R) estimado no teste e o erro de classificação.

Tabela 10 – Resultados obtidos para treinamento e validação do ROTEIRO I

RNA PMC – RESULTADOS ROTEIRO I					
Taxa de Acerto (%)					
PMC (10)	PMC (40)	PMC (5 5)	PMC (15 15)	PMC (5 5 5)	PMC (15 15 15)
77,39	90,55	62,26	85,10	90,43	89,62
Desvio-Padrão da Taxa de Acerto (%)					
27,029	13,771	31,894	21,066	14,209	15,419
Erro Relativo Médio (ERM%)					
22,61	9,55	37,74	14,90	9,57	10,38
Coefficiente de Correlação Linear (R) Estimado no Teste					
0,99968	0,99989	0,9995	0,9998	0,99986	0,99987
Erro de Classificação					
17 / 77	7 / 77	29 / 77	12 / 77	7 / 77	8 / 77

Fonte: Autoria própria (2017).

Conforme demonstrado pelos dados da Tabela 10, observa-se que a topologia para arquitetura RNA – PMC(40), trabalhando com os 7 sinais de dados de entrada (3 sinais de corrente elétrica e 4 sinais de vibração), foi a que obteve melhor desempenho, uma topologia de camada escondida única formada por 40 neurônios.


Essa rede externou valores para taxa de acerto de 90,55%, com um erro relativo médio de 9,55%. A rede também apresentou um valor para desvio padrão de 13,77%.

A Figura 50 ilustra o gráfico que representa a evolução do desempenho do erro de treinamento e teste para RNA-PMC (40), a topologia que apresentou os melhores resultados dentro do Roteiro I.

Pela análise do gráfico, verificou-se que a topologia RNA - PMC (40) conseguiu desenvolver seu processamento, para o treinamento e teste, com pouco esforço computacional, pois atingiu a meta do critério de parada do treinamento pelo valor do EQM pré-determinado (10^{-7}), e também o melhor desempenho na etapa de teste com poucas iterações, ou seja, baixo número de épocas. Como já mencionado no capítulo anterior, os dados de teste não são utilizados em nenhuma das etapas do algoritmo

de treinamento, embora seus erros quadráticos médios sejam ilustrados juntos no gráfico. Nesse sentido tem-se que os erros do conjunto teste e do conjunto validação possuem característica similares, e o erro de teste decai juntamente com o erro de treinamento até atingir 98 épocas.

Figura 50 – Evolução do desempenho do erro de treinamento e teste para RNA-PMC (40)



Fonte: Autoria própria (2017).

Ainda conforme ilustrado na Figura 50, observa-se que o desempenho da RNA em relação ao conjunto de treinamento e teste se aprimora a cada época, visto que o comportamento do EQM apresenta um decaimento progressivo ao longo do número de épocas, indicando que a rede está convergindo e caminha para o mínimo global.

No processo de treinamento de uma RNA, tem-se como objetivo conseguir uma configuração de topologia para que a rede consiga a melhor capacidade de generalização possível, ou seja, a maior capacidade de responder corretamente aos dados que não foram utilizados no processo de treinamento. As RNA PMC, com características de redes totalmente interconectadas, estão comumente sujeitas a sofrerem o fenômeno de sobre-treinamento (*overtraining*) ou treinamento excessivo (*overfitting*), que é quando a rede parece estar representando o problema cada vez melhor, ou seja, o EQM do conjunto de treinamento continua diminuindo, porém, em algum ponto do processamento a capacidade de responder a um novo conjunto de


dados piora fazendo com que a rede perca a capacidade de generalização em virtude de sua especialização no conjunto de dados do treinamento.

O ideal é que o treinamento seja interrompido quando a rede apresentar uma boa capacidade de generalização, ou seja, encontrar um ponto ideal de parada com erro mínimo estipulado e capacidade de generalização máxima. (PRECHELT, 1997).

Desta forma, nota-se, portanto, pela análise das curvas do gráfico da Figura 50, um decaimento progressivo ao longo do número de épocas, tanto para curva de treinamento quanto a de teste, comportamento esse que não indica a ocorrência do fenômeno de *overfitting*.

Em seguida, com o objetivo de analisar os resultados visualmente, através da representação da distribuição dos erros dos dados de treinamento e de teste de forma gráfica, foi gerado o histograma de erros para a topologia RNA-PMC (40), conforme ilustrado pela Figura 51. São apresentados os histogramas de distribuição dos erros dos valores utilizados para o treinamento bem como os utilizados para o teste (valores gerados pela RNA).

Figura 51 – Histograma de Erros médios para RNA-PMC (40)



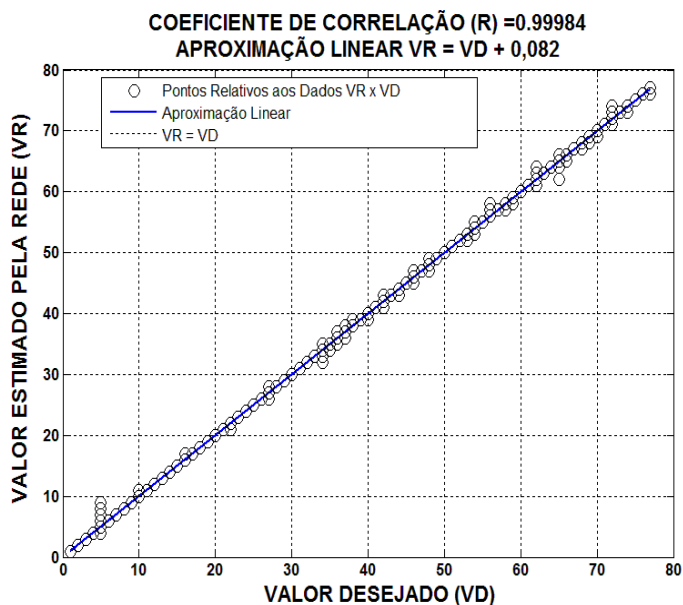
Fonte: Autoria própria (2017).

O gráfico da Figura 51 demonstra a dispersão dos erros de treinamento e teste para a topologia RNA PMC (40). Nota-se que a maioria dos erros, tanto para os dados de treinamento quanto para os dados de teste estão concentrados próximos do erro

zero, mostrando que rede generalizou de forma adequada (dados de teste), denotando confiança estatística ao método.

De maneira a destacar a capacidade de generalização da RNA PMC (40), observa-se, ilustrado na Figura 52, o gráfico de aproximação linear e correlação entre os valores desejados e os estimados pela rede. Ele demonstra a correlação dos dados externados pelo sistema inteligente e os valores reais conhecidos.

Figura 52 – Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para a RNA-PMC (40) – ROTEIRO I




Fonte: Autoria própria (2017).

Neste caso foram mostrados os 77 pares efetivamente medidos e que não participaram do treinamento. Nota-se que a dispersão dos pares se localizam em torno da curva ideal da aproximação linear, mostrando a boa capacidade de generalização da rede em questão. A análise da Figura 52 confirma o elevado grau de similaridade previsto pelos dados estatísticos da Tabela 10. O coeficiente de correlação (R) igual a 0,999 indica uma forte correlação linear entre as duas variáveis, uma vez que a correlação perfeita possui valor de (R) igual a 1. Nota-se essa similaridade também ao se observar a reta de aproximação linear entre as duas variáveis, em azul, que está praticamente sobreposta a reta ideal em preto tracejado.

Com o intuito de proporcionar uma análise visual global do comportamento do conjunto de validação, mostrando uma representação da dispersão entre os dados

simulados e os estimados pela RNA, foi gerado o gráfico ilustrado pela Figura 53. Nessa figura observa-se, de maneira global o comportamento dos valores externados pela RNA PMC (40) para as condições de falhas ensaiadas (desejadas) e as estimadas pela rede em questão.

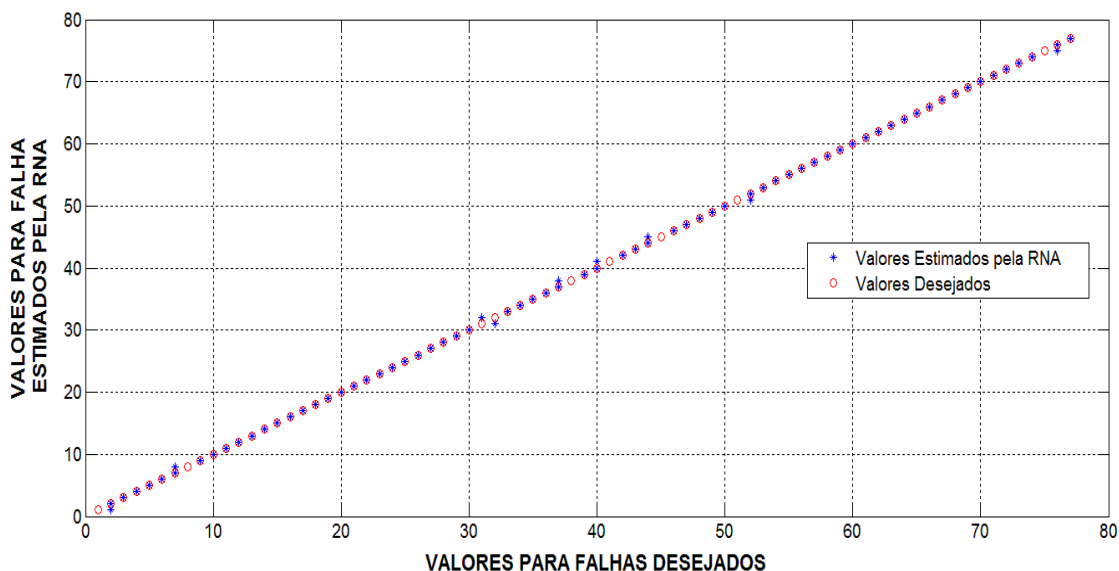
Figura 53 – Orientação global dos dados de teste para a RNA-PMC (40) – ROTEIRO I



Fonte: Autoria própria (2017).

Da mesma forma, na Figura 54, tem-se representado a média dessa dispersão dos dados para valores estimados x desejados para a mesma rede.

Figura 54 – Média da Dispersão dos dados para valores estimados x desejados para RNA PMC (40) ROTEIRO I.



Fonte: Autoria própria (2017).

4.2 Resultados das RNA PMC para classificação das falhas utilizando sinais de vibração – ROTEIRO II

Nessa seção são apresentados os resultados obtidos com RNA PMC após os testes realizados com as combinações de topologias de redes e conjunto de entradas de dados do Roteiro II.

No subcapítulo 4.1 foram mostrados e discutidos os dados e gráficos de desempenho de treinamento e teste das RNA PMC para o Roteiro I, ou seja, utilizando como dados de entrada para rede os sinais de corrente elétrica e vibração. Nesta seção as mesmas topologias de RNA PMC foram treinadas agora utilizando como dados de entrada apenas os 4 sinais de vibração (PZT1, PZT2, PZT3, PZT4), conforme determina o Roteiro II indicado na Tabela 7.

São demonstrados, conforme ilustrado pela Tabela 11, os valores de taxa de acerto com respectivo desvio padrão, em valores percentuais, para cada topologia de rede trabalhada, bem como o coeficiente de correlação linear (R) estimado no teste e o erro de classificação.

Tabela 11 – Resultados obtidos para treinamento e validação do ROTEIRO II

RNA PMC – RESULTADOS ROTEIRO II					
Taxa de Acerto (%)					
PMC (10)	PMC (40)	PMC (5 5)	PMC (15 15)	PMC (5 5 5)	PMC (15 15 15)
34,49	88,17	25,50	88,05	72,11	91,30
Desvio-Padrão da Taxa de Acerto (%)					
65,4013	16,537	57,0094	12,6208	14,4835	9,7407
Erro Relativo Médio (ERM%)					
65,51	11,83	74,50	11,95	27,89	8,70
Coefficiente de Correlação Linear (R) Estimado no Teste					
0,99577	0,99986	0,99413	0,99987	0,9995	0,99985
Erro de Classificação					
49 / 77	9 / 77	57 / 77	9 / 77	21 / 77	6 / 77

Fonte: Autoria própria (2017).


Dessa forma, a partir da análise dos dados da Tabela 11, observa-se que a topologia para arquitetura RNA PMC (15 15 15), trabalhando apenas com os 4 sinais de vibração como dados de entrada para a rede, foi a que obteve melhor desempenho.

Essa rede externou valores para taxa de acerto de 91,30%, com um erro relativo médio de 8,70%. A rede também apresentou um valor para desvio padrão de 9,74%.

A Figura 55 ilustra o gráfico que representa a evolução do desempenho do erro de treinamento e teste para RNA PMC (15 15 15), a topologia que apresentou os melhores resultados dentro dos arranjos das topologias contidas no Roteiro II.

Pela análise do gráfico, verificou-se que a topologia RNA PMC (15 15 15) conseguiu desenvolver seu processamento, para o treinamento e teste, com pouco esforço computacional, menor ainda que a RNA PMC(40) do Roteiro I. Ela atingiu a meta do critério de parada do treinamento pelo valor do EQM pré-determinado (10^{-7}), e também o melhor desempenho na etapa de teste com poucas iterações, ou seja, baixo número de épocas. Observa-se que os erros do conjunto teste e do conjunto validação possuem característica similares, e o erro de teste decai juntamente com o erro de treinamento até atingir 42 épocas.

Figura 55 – Evolução do desempenho do erro de treinamento e teste para RNA-PMC (15 15 15) ROTEIRO II




Fonte: Autoria própria (2017).

De maneira similar ao que ocorreu com a RNA-PMC (40), analisando as curvas do gráfico da Figura 55, observa-se que o desempenho da RNA em relação ao conjunto de treinamento e teste se aprimora a cada época, visto que o comportamento do EQM apresenta um decaimento progressivo ao longo do número de épocas, indicando que a rede está convergindo e caminha para o mínimo global. Nesse sentido, esse decaimento progressivo ao longo do número de épocas, tanto para curva de treinamento quanto a de teste, indica que não houve a ocorrência do fenômeno de *overfitting*.

Em seguida, novamente com o objetivo de analisar os resultados visualmente, através da representação da distribuição dos erros dos dados de treinamento e de teste de forma gráfica, foi gerado o histograma de erros para a topologia RNA PMC (15 15 15), conforme ilustrado pela Figura 56. São apresentados os histogramas de distribuição dos erros dos valores utilizados para o treinamento bem como os utilizados para o teste (valores gerados pela RNA).

Figura 56 – Histograma de Erros médios para RNA-PMC (15 15 15) ROTEIRO II




Fonte: Autoria própria (2017).

O gráfico da Figura 56 demonstra a dispersão dos erros de treinamento e teste para a topologia RNA PMC (15 15 15). Nota-se que, a maioria dos erros, tanto para os dados de treinamento quanto para os dados de teste estão concentrados próximos

do erro zero, mostrando que rede generalizou de forma adequada (dados de teste), denotando confiança estatística ao método.

A fim de se destacar a capacidade de generalização da RNA PMC (15 15 15), observa-se ilustrado na Figura 57, o gráfico de aproximação linear e correlação entre os valores desejados e os estimados pela rede. Ele demonstra a correlação dos dados externados pelo sistema inteligente e os valores reais conhecidos.

Figura 57 – Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para a RNA-PMC (15 15 15) – ROTEIRO II



Fonte: Autoria própria (2017).


Novamente, foram mostrados os 77 pares efetivamente medidos e que não participaram do treinamento. Nota-se que a dispersão dos pares se localizam em torno da curva ideal da aproximação linear, mostrando a boa capacidade de generalização da rede em questão. A análise da Figura 57 confirma o elevado grau de similaridade previsto pelos dados estatísticos da Tabela 11. O coeficiente de correlação (R) igual a 0,999 indica uma forte correlação linear entre as duas variáveis, uma vez que a correlação perfeita possui valor de (R) igual a 1.

Com o intuito de proporcionar uma análise visual global do comportamento do conjunto de validação, mostrando uma representação da dispersão entre os dados simulados e os estimados pela RNA, foi gerado o gráfico ilustrado pela Figura 58.

Nessa figura observa-se, de maneira global o comportamento dos valores

externados pela RNA PMC (15 15 15) para as condições de falhas ensaiadas (desejadas) e as estimadas pela rede em questão.


Figura 58 – Orientação global dos dados de teste para a RNA-PMC (15 15 15) – ROTEIRO II



Fonte: Autoria própria (2017).

Da mesma forma, na Figura 59, tem-se representado a média dessa dispersão dos dados para valores estimados x desejados para a mesma rede.

Figura 59 – Média da Dispersão dos dados para valores estimados x desejados para RNA PMC (15 15 15) ROTEIRO II



Fonte: Autoria própria (2017).

4.3 Resultados das RNA RBF para classificação das falhas utilizando sinais de corrente elétrica e vibração – ROTEIRO III

Após as abordagens utilizando as RNA PMC nos subcapítulos 4,1 e 4.2, são apresentados e discutidos nessa seção os resultados obtidos com as arquiteturas de RNA RBF, utilizando as combinações de topologias de redes e conjunto de entradas de dados do Roteiro III. Nesse roteiro, conforme informado pela Tabela 8, são utilizados como dados de entrada para as redes os sinais corrente elétrica (I_A , I_B , I_C) e vibração fornecidos pelos diafragmas piezelétricos de baixo custo, que denominados aqui nesse trabalho como PZT1, PZT2, PZT3, PZT4. Para o treinamento e teste de cada configuração de topologia das RNA - RBF, o parâmetro *spread* variou, admitindo valores de (0.2), (0.4), (0.6), (0.8), (1) e (2).

Dessa forma, tem-se ilustrado na Tabela 12 os dados das redes que obtiveram o melhor desempenho. São demonstrados os valores de taxa de acerto com respectivo desvio padrão, em valores percentuais, para cada topologia de rede trabalhada, bem como o coeficiente de correlação linear (R) estimado no teste e o erro de classificação.

Tabela 12 – Resultados obtidos para treinamento e validação do ROTEIRO III

RNA RBF – ROTEIRO III					
Taxa de Acerto (%)					
RBF (0.2)	RBF (0.4)	RBF (0.6)	RBF (0.8)	RBF (1)	RBF (2)
98,14	97,73	98,26	97,56	96,41	97,27
Desvio-Padrão da Taxa de Acerto (%)					
8,0065	6,8167	7,6750	8,3749	8,5722	7,7225
Erro Relativo Médio (ERM%)					
1,86	2,27	1,74	2,44	3,59	2,73
Coefficiente de Correlação Linear (R) Estimado no Teste					
0,99997	0,99971	0,99970	0,99977	0,99963	0,99996
Erro de Classificação					
2 / 77	2 / 77	2 / 77	2 / 77	3 / 77	2 / 77

Fonte: Autoria própria (2017).


Nesse sentido, conforme demonstrado pelos dados da Tabela 12, observa-se que a topologia para arquitetura RNA RBF(0.6), trabalhando com os 7 sinais de dados

de entrada (3 sinais de corrente elétrica e 4 sinais de vibração), foi a que obteve melhor desempenho.

Essa rede externou valores para taxa de acerto de 98,26%, com um erro relativo médio de 1,74%. A rede também apresentou um valor para desvio padrão de 7,67%.

A Figura 60 ilustra o gráfico que representa a evolução do desempenho do erro de treinamento e teste para RNA RBF (0.6), a topologia que apresentou os melhores resultados dentro do Roteiro III.

Figura 60 – Evolução do desempenho do erro de treinamento e teste para RNA RBF (0.6) ROTEIRO III




Fonte: Autoria própria (2017).

Pela análise do gráfico, verificou-se que a topologia RNA RBF(0.6) conseguiu desenvolver seu processamento, para o treinamento e teste, com pouco esforço computacional, pois atingiu a meta do critério de parada do treinamento pelo valor do EQM pré-determinado (10^{-5}), e também o chegou ao melhor desempenho na etapa de teste com poucas iterações, ou seja, baixo número de épocas. Como já mencionado no capítulo anterior, os dados de teste não são utilizados em nenhuma das etapas do algoritmo de treinamento, embora seus erros quadráticos médios sejam ilustrados juntos no gráfico. Nesse sentido tem-se que os erros do conjunto teste e do conjunto validação possuem característica similares, e o erro de teste decai juntamente com o erro de treinamento até atingir 117 épocas.

De maneira similar ao que ocorreu com o treinamento das RNA PMC, analisando as curvas do gráfico da Figura 60, observa-se que o desempenho da RNA em relação ao conjunto de treinamento e teste se aprimora a cada época, visto que o comportamento do EQM apresenta um decaimento progressivo ao longo do número de épocas, indicando que a rede está convergindo e caminha para o mínimo global. Nesse sentido, também, indicando que não houve a ocorrência do fenômeno de *overfitting*.

Em seguida, novamente com o objetivo de analisar os resultados visualmente, através da representação da distribuição dos erros dos dados de treinamento e de teste de forma gráfica, foi gerado o histograma de erros para a topologia RNA RBF (0.6), conforme ilustrado pela Figura 61. São apresentados os histogramas de distribuição dos erros dos valores utilizados para o treinamento bem como os utilizados para o teste (valores gerados pela RNA).

Figura 61 – Histograma de Erros médios para RNA-RBF (0.6) ROTEIRO III




Fonte: Autoria própria (2017).

O gráfico da Figura 61 demonstra a dispersão dos erros de treinamento e teste para a topologia RNA RBF (0.6). Nota-se que a maioria dos erros, tanto para os dados de treinamento quanto para os dados de teste estão concentrados em uma distribuição gaussiana próximos do erro zero, mostrando que a rede generalizou de forma adequada (dados de teste), denotando confiança estatística ao método.

De forma também a destacar a capacidade de generalização da RNA RBF (0.6), observa-se ilustrado na Figura 62 o gráfico de aproximação linear e correlação entre os valores desejados e os estimados pela rede. Ele demonstra a correlação dos dados externados pelo sistema inteligente e os valores reais conhecidos.

Figura 62 – Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para a RNA-RBF(0.6) – ROTEIRO III




Fonte: Autoria própria (2017).

Novamente, foram mostrados os 77 pares efetivamente medidos e que não participaram do treinamento. Nota-se que a dispersão dos pares se localizam em torno da curva ideal da aproximação linear, mostrando a boa capacidade de generalização da rede em questão. A análise da Figura 62 confirma o elevado grau de similaridade previsto pelos dados estatísticos da Tabela 12. O coeficiente de correlação (R) igual a 0,999 indica uma forte correlação linear entre as duas variáveis, uma vez que a correlação perfeita possui valor de (R) igual a 1.

Com o intuito de proporcionar uma análise visual global do comportamento do conjunto de validação, mostrando uma representação da dispersão entre os dados simulados e os estimados pela RNA, foi gerado o gráfico ilustrado pela Figura 63.

Nessa figura observa-se, de maneira global, o comportamento dos valores externados pela RNA RBF (0.6) para as condições de falhas ensaiadas (desejadas) e as estimadas pela rede em questão.


Figura 63 – Orientação global dos dados de teste para a RNA-RBF(0.6) – ROTEIRO III



Fonte: Autoria própria (2017).

Da mesma forma, na Figura 64, tem-se representado a média dessa dispersão dos dados para valores estimados x desejados para a mesma rede.

Figura 64 – Média da dispersão dos dados para valores das falhas estimados x desejados para RNA RBF (0.6) ROTEIRO III



Fonte: Autoria própria (2017).

4.4 Resultados das RNA RBF para classificação das falhas utilizando sinais de vibração – ROTEIRO IV

No subcapítulo anterior foram discutidos os dados e gráficos de desempenho de treinamento e teste das RNA RBF para o Roteiro III, ou seja, utilizando como dados de entrada os sinais de corrente elétrica e vibração.

Por fim, nesta seção as mesmas topologias de RNA RBF foram treinadas agora utilizando os arranjos segundo o Roteiro IV. Nesse roteiro, conforme indicado pela Tabela 9, foram utilizados como dados de entrada apenas os 4 sinais de vibração (PZT1, PZT2, PZT3, PZT4). As topologias das RNA RBF também foram estruturadas e treinadas variando-se o parâmetro *spread*, sendo admitido valores de (0.2), (0.4), (0.6), (0.8), (1) e (2).

Nesse sentido, tem-se ilustrado na Tabela 13 os dados das redes que obtiveram o melhor desempenho. São demonstrados os valores de taxa de acerto com respectivo desvio padrão, em valores percentuais, para cada topologia de rede trabalhada, bem como o coeficiente de correlação linear (R) estimado no teste e o erro de classificação

Tabela 13 – Resultados obtidos para treinamento e validação do ROTEIRO IV

RNA RBF – RESULTADOS ROTEIRO IV					
Taxa de Acerto (%)					
RBF (0.2)	RBF (0.4)	RBF (0.6)	RBF 0.8)	RBF (1)	RBF (2)
99,18	95,76	98,31	96,92	96,46	93,21
Desvio-Padrão da Taxa de Acerto (%)					
5,9587	7,0378	8,9491	7,6664	7,3450	17,4336
Erro Relativo Médio (ERM%)					
0,82	4,24	1,69	3,08	3,54	6,79
Coeficiente de Correlação Linear (R) Estimado no Teste					
0,99999	0,99998	0,99995	0,99997	0,99997	0,99971
Erro de Classificação					
1 / 77	3 / 77	2 / 77	3 / 77	3 / 77	5 / 77


Fonte: Autoria própria (2017).

Nesse sentido, conforme demonstrado pelos dados da Tabela 13, observa-se que a topologia para arquitetura RNA RBF(0.2), com configurações de arranjos das topologias conforme o Roteiro IV, ou seja, utilizando apenas os 4 sinais de vibração como dados de entrada para a rede, foi a que obteve melhor desempenho.

Essa rede externou valores para taxa de acerto de 99,18%, com um erro relativo médio de 0,82%. A rede também apresentou um valor para desvio padrão de 5,95%.

A Figura 65 ilustra o gráfico que representa a evolução do desempenho do erro de treinamento e teste para RNA RBF (0.2), a topologia que apresentou os melhores resultados dentro do Roteiro IV.

Figura 65 – Evolução do desempenho do erro de treinamento e teste para RNA RBF (0.2) - ROTEIRO IV



Fonte: Autoria própria (2017).


Pela análise do gráfico, verificou-se que a topologia RNA RBF (0.2) conseguiu desenvolver seu processamento, para o treinamento e teste, com pouco esforço computacional, pois atingiu a meta do critério de parada do treinamento pelo valor do EQM pré-determinado (10^{-5}), e também o chegou ao melhor desempenho na etapa de teste com poucas iterações, ou seja, baixo número de épocas. Como já mencionado no capítulo anterior, os dados de teste não foram utilizados em nenhuma das etapas do algoritmo de treinamento, embora seus erros quadráticos médios sejam ilustrados juntos no gráfico. Nesse sentido tem-se que os erros do conjunto teste e do conjunto

validação possuem característica similares, e o erro de teste decai juntamente com o erro de treinamento até atingir 94 épocas.

De maneira similar ao que ocorreu com o treinamento das RNA PMC, analisando as curvas do gráfico da Figura 65, observa-se que o desempenho da RNA em relação ao conjunto de treinamento e teste se aprimora a cada época, visto que o comportamento do EQM apresenta um decaimento progressivo ao longo do número de épocas, indicando que a rede está convergindo e caminha para o mínimo global. Nesse sentido, também indicando que não houve a ocorrência do fenômeno de *overfitting*.

Em seguida, novamente com o objetivo de analisar os resultados visualmente, através da representação da distribuição dos erros dos dados de treinamento e de teste de forma gráfica, foi gerado o histograma de erros para a topologia RNA RBF (0.2), conforme ilustrado pela Figura 66. São apresentados os histogramas de distribuição dos erros dos valores utilizados para o treinamento bem como os utilizados para o teste (valores gerados pela RNA).

Figura 66 – Histograma de Erros médios para RNA-RBF (0.2) ROTEIRO IV




Fonte: Autoria própria (2017).

O gráfico da Figura 66 demonstra a dispersão dos erros de treinamento e teste para a topologia RNA RBF (0.2). Nota-se que a maioria dos erros, tanto para os dados de treinamento quanto para os dados de teste estão concentrados em uma

distribuição gaussiana próximos do erro zero, mostrando que rede generalizou de forma adequada (dados de teste), denotando confiança estatística ao método.

De forma também a destacar a capacidade de generalização da RNA RBF(0.2), observa-se pela ilustração da Figura 67, o gráfico de aproximação linear e correlação entre os valores desejados e os estimados pela rede. Ele demonstra a correlação dos dados externados pelo sistema inteligente e os valores reais conhecidos.

Figura 67 – Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para RNA RBF (0.2)




Fonte: Autoria própria (2017).

Novamente, foram mostrados os 77 pares efetivamente medidos e que não participaram do treinamento. Nota-se que a dispersão dos pares se localizam em torno da curva ideal da aproximação linear, mostrando a boa capacidade de generalização da rede em questão. A análise da Figura 67 confirma o elevado grau de similaridade previsto pelos dados estatísticos da Tabela 13. O coeficiente de correlação (R) igual a 0,999 indica uma forte correlação linear entre as duas variáveis, uma vez que a correlação perfeita possui valor de (R) igual a 1.

Com o intuito de proporcionar uma análise visual global do comportamento do conjunto de validação, mostrando uma representação da dispersão entre os dados simulados e os estimados pela RNA, foi gerado o gráfico ilustrado pela Figura 68.

Nessa figura observa-se, de maneira global, o comportamento dos valores externados pela RNA RBF (0.2) para as condições de falhas ensaiadas (desejadas) e as estimadas pela rede em questão.


Figura 68 – Orientação global dos dados de teste para a RNA-RBF (0.2) – ROTEIRO IV



Fonte: Autoria própria (2017).

Da mesma forma, na Figura 69, tem-se representado a média dessa dispersão dos dados para valores estimados x desejados para a mesma rede.

Figura 69 – Média da dispersão para a rede RBF (0.2) ROTEIRO IV




Fonte: Autoria própria (2017).

4.5 Análise comparativa entre os resultados fornecidos pelas RNA

Após a apresentação, nos subcapítulos anteriores, dos resultados e gráficos para cada Roteiro de treinamento, nessa seção é apresentada uma avaliação com o intuito de se comparar o desempenho de cada rede treinada, de maneira a justificar a abordagem proposta. Foram utilizados os valores máximos da taxa de acerto como critério da escolha da melhor topologia de RNA.

Dessa forma, de maneira a tecer-se uma análise comparativa entre os roteiros das redes estudados, foi gerado o gráfico ilustrado pela Figura 70, onde estão demonstrados comparativamente os valores de taxa de acerto para as topologias de RNA treinadas.

Figura 70 – Gráfico comparativo de desempenho entre as RNA com melhores taxas de acerto (%)



Fonte: Autoria própria (2017).

Nota-se que a rede que obteve melhor resposta para o método proposto pela pesquisa foi a RNA RBF com parâmetro de *spread* (0.2), do ROTEIRO IV, que se utilizou dos sinais de entrada, para o treinamento, apenas os sensores de vibração, ou seja, apenas os 4 diafragmas piezelétricos de baixo custo.

A RNA RBF (0.2) mostrou-se a topologia mais eficiente no reconhecimento de curto-circuitos no estator do MIT. Essa rede externou ótimos resultados, com valores de taxa de acerto acima dos 99%. Pela análise recorrente a Tabela 13, verifica-se também que essa topologia de rede foi a que obteve menor erro relativo médio (0,82%) e também apresentou o menor valor para desvio padrão (5,95%).

Pela análise do gráfico da Figura 70, percebe-se também que a arquitetura de RNA do tipo RBF foi a que demonstrou melhores desempenhos no geral entre os arranjos propostos pelos Roteiros, seja trabalhando com todas as entradas ou apenas com os sinais dos sensores de vibração de baixo custo.

Outra relação de semelhança que pode-se destacar é o fato de, ambas arquiteturas de RNA, terem obtido melhores resultados nos roteiros que utilizaram como dados de entrada, para treinamento das redes, apenas os sinais dos diafragmas piezelétricos de baixo custo atuando como sensores de vibração.

Dessa forma, verifica-se que a abordagem proposta apresenta potencial para a diagnóstico de falhas em MIT, sem a necessidade de se monitorar grandezas elétricas.

5 CONCLUSÕES

Os MIT ocupam posição de destaque dentro das linhas de produção industriais e, sendo assim, essas máquinas merecem preocupações adicionais no que tange as questões de confiabilidade e a disponibilidade. Dessa forma, muitas técnicas têm sido desenvolvidas com o propósito de se monitorar o comportamento e o desempenho do MIT, com o propósito de mitigar os defeitos inerentes ao funcionamento dessas máquinas.

Nesse sentido, este trabalho apresentou uma metodologia para diagnosticar falhas elétricas em MIT de maneira incipiente, de forma a prevenir o avanço da falha para uma avaria grave da máquina. Mais especificamente, foi proposto uma técnica com foco nas falhas nos estatores, manifestadas na forma de curto-circuito entre espiras de uma mesma bobina dos enrolamentos da máquina, para monitoramento em tempo real, com uma análise dos sinais no domínio do tempo. Para isso, utilizou-se sistemas inteligentes do tipo Redes neurais artificiais (RNA), onde optou-se pelas arquiteturas *Perceptron* Multicamadas (PMC), e *Radial Basis Function* (RBF), sendo tipos de redes que receberam destaque quando utilizadas como classificadoras de padrões, de acordo com vários trabalhos na literatura acadêmica. Também foi proposto utilizar os sinais adquiridos por meio de diafragmas piezelétricos de baixo custo do tipo PZT, sendo o uso destes uma proposta alternativa à utilização dos sensores comerciais existentes no mercado, já consolidados para essa aplicação e com alto valor financeiro.

Fundamentando-se nos resultados obtidos nos treinamentos e testes dos sistemas inteligentes, pode-se dizer que a abordagem proposta mostrou-se promissora no que diz respeito à diagnóstico de falhas elétricas em MIT. Os valores da taxa de acerto percentual na validação cruzada mostraram que as topologias de RNA treinadas RBF(0.6) e RBF (0.2) obtiveram os melhores desempenhos, com esta última atingindo valores de taxa de acerto nos testes de validação de 99,18%.

Destaca-se também que esta rede obteve níveis de desvio padrão e erro relativo médio mais baixos entre todas topologias testadas. Com relação aos tempos de treinamento, observou-se que ambas arquiteturas necessitaram de números de interações parecidos para realizar seus treinamentos e testes, ou seja, convergiram e atingiram seus objetivos com números de épocas bem similares, demonstrando que

o fator tempo não se configura relevante como avaliação comparativa entre as RNA para o método proposto. Essas condições denotam também que o processamento, durante o treinamento e teste, envolveu baixa demanda computacional e baixa complexidade matemática. Na comparação entre os valores das falhas estimadas e as desejadas (simulados), o coeficiente de correlação (R) médio do teste foi de 99%, demonstrando uma correlação muito forte entre os dados, o que comprova a eficácia do arranjo de redes neurais proposto para atingir o objetivo dessa pesquisa.

Dessa forma, a abordagem utilizando os sinais no domínio do tempo, e aplicando-se um processamento dos sinais apenas com a métrica Valor RMS, mostrou-se suficiente e eficaz para atingir os objetivos propostos desse trabalho com significativo grau de exatidão, de acordo com os valores da taxa de acerto.

Faz-se necessário destacar o fato de, ambas arquiteturas de RNA, terem obtido melhores resultados nos roteiros que utilizaram como dados de entrada para treinamento das redes apenas os sinais dos diafragmas piezelétricos de baixo custo atuando como sensores de vibração. Sendo assim, verifica-se que a abordagem proposta apresenta potencial para a diagnóstico de falhas em MIT, sem a necessidade de se monitorar grandezas elétricas.

O emprego de diafragmas piezelétricos de baixo custo como sensores de vibração não inviabiliza o desempenho do sistema proposto, visto os mesmos que apresentam boas respostas de funcionamento a baixas frequências, característica do MIT em regime de trabalho. É importante também destacar que estes diafragmas piezelétricos não foram desenvolvidos especificamente para esta finalidade, e apresentam um baixo custo financeiro para aquisição comparados aos sensores de vibração comerciais já consolidados no mercado. Este fato torna-se um ponto chave para pesquisas futuras em áreas correlatas, que se utilizem das técnicas de processamento de sinais de vibração ou sistemas inteligentes como suporte as técnicas de manutenção preditiva industriais.

Tendo em vista que os ensaios foram realizados em apenas um MIT de pequeno porte, é prematuro generalizar a aplicação do método proposto para máquinas de maiores potências e maiores tensões de acionamento.

De maneira geral, conclui-se que o emprego das metodologias abordadas, com a utilização dos sistemas inteligentes do tipo RNA, destacam-se por várias particularidades, dentre as quais: a possibilidade de treinamento a partir dos sinais do motor no domínio do tempo; a predição de falhas incipientes monitorando as

anomalias no MIT durante sua operação (método não invasivo e equipamento em regime de trabalho) com uma resposta em tempo real; ser um sistema de fácil implementação pois demanda baixa complexidade e esforço computacional (sem necessitar de modelos matemáticos complexos) pois apresenta reconhecimento de padrões e mapeamento não-linear no monitoramento das condições do motor e capacidade de aprendizagem e organizar os dados.

5.1 Sugestões para trabalhos futuros

Nesse contexto, durante a realização desse trabalho, levantou-se algumas questões que podem ficar aqui registradas como sugestões propostas para trabalhos futuros como explorar outras ferramentas computacionais inteligentes (como sistemas neuro-fuzzy), e também aplicação de outras métricas no tratamento dos sinais (como critérios de energia, kurtosis, skewness, critério de informação de Akaike, e outros métodos estatísticos de ordem superior).

Também pode-se desenvolver trabalhos para explorar outros arranjos na disposição na fixação dos sensores na estrutura do MIT, fornecer a alimentação elétrica trifásica contendo anomalias e distorções harmônicas, bem como cargas que impõem um regime de trabalho com vibrações excessivas ao MIT, e análise observando os sinais das falhas com a presença transitórios de mudança de estado.

REFERÊNCIAS

AGUIAR, P. R.; BIANCHI, E.C.; CANARIM, R. C. **Monitoring of Grinding Burn by Acoustic Emission**. In: Wojciech Sikorski. (Org.). *Acoustic Emission*. 1ed. Rijeka, Croatia: Intech, v. 1, pp. 341-364, 2012.

ALBRECHT, P. F., J. C. APPIARIUS, R. M. MCCOY, E. L. OWEN, AND D. K. SHARMA, "Assessment of the reliability of motors in utility applications—Updated," *IEEE Trans. Energy Convers.*, vol. EC-1, no. 1, pp. 39–46, Mar. 1986.

ALMEIDA, M. T. **Manutenção Preditiva: Confiabilidade e Qualidade**. 2000. Escola Federal de Engenharia de Itajubá. Disponível em: <http://www.mtaev.com.br/download/mnt1.pdf>. Acesso em 24 jan. 2016.

ARAÚJO, R. G. C. **Desenvolvimento de um Sistema de Diagnóstico de Falhas em Motores Elétricos de Indução**. Dissertação (Mestrado) – Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa, 2015.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 11 390**: Máquinas Elétricas Girantes –Medição- Avaliação e limites da severidade de vibração mecânica de máquinas de altura de eixo igual ou superior a 56 mm – Especificação. Rio de Janeiro, 1990.

AVELAR, V. S.; BACCARINI, L. M. R.; AMARAL, G. F. V. Desenvolvimento de um sistema inteligente para diagnóstico de falhas nos enrolamentos do estator de motores de indução. **X SBAI – Simpósio Brasileiro de Automação Inteligente**, 2011.

BACCARINI, L. M. R. **Detecção e Diagnóstico de Falhas em Motores de Indução**. 207 p. Tese (Doutorado)–Universidade Federal de Minas Gerais, Belo Horizonte - MG, 2005.

BAPTISTA, F. G. **Uma contribuição aos sistemas de monitoramento de integridade estrutural baseados na impedância eletromecânica**. 2010. 91 f. Tese (Doutorado em Engenharia Elétrica). Faculdade de Engenharia, Universidade Estadual Paulista. Ilha Solteira, Brasil. 2010.

BELLINI, A.; FILIPPETT, F.; TASSONI, C. Advances in Diagnostic Techniques for Induction Machines. *IEEE Transactions on Industrial Electronics* 55(12), pp 4109-4126. 2008.

BENBOUZID, M. E. H. A Review of Induction Motors Signature Analysis as a Medium for Faults Detection, *IEEE Transactions on Industrial Electronics*, v. 47, October, n. 5, pp. 984-993. 2000.

BYRD, T. A.; HAUSER, R. D. **Expert systems in production and operations management: research directions in assessing overall impact**. *Int. J. Prod. Res.*, Vol. 29, pp. 2471-2482, 1991.

BONNETT; A. H.; SOUKUP; G. C. Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors. **IEEE Ind. Appl. Mag.**, v. 28, n. 4, pp. 921–937, 1992.

BOUZID, M. B. K.; CHAMPENOIS, G.; BELLAJ, N. M.; SIGNAC, L.; JELASSI, K. (2008). An effective neural approach for the automatic location of stator interturn faults in induction motor, **IEEE Transactions on Industrial Electronics** **55(12)**: 4277-4289.

BRAGA, Antônio de P.; CARVALHO, André P. de L. F.; LUDERMIR, Teresa B. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2011. 226p.

BRANCO, G. F. **A Organização, o Planejamento e o Controle da Manutenção**. Rio de Janeiro: Ciência Moderna, 2008.

BRITO, J. N. **Desenvolvimento de um Sistema Inteligente híbrido para diagnóstico de Falhas em Motores de indução Trifásicos**. Universidade Estadual de Campinas-PDGEM/UNICAMP, 2002, Campinas, SP.

CAVALCANTE, P. F.; JESUS, S. S. Utilização de bancadas de ensaio para estudo do comportamento dinâmico de máquinas rotativas-vibrações mecânicas. **Holos**, Natal, v. 3, p. 18-40, maio 2011.

CASTRO, B. A. **Localização de Descargas Parciais em Transformadores de Potência por Meio de Sensores Piezelétricos de Baixo Custo e Sistemas Inteligentes**. 2016. 147 f. Dissertação (Mestrado)–Faculdade de Engenharia, Universidade Estadual Paulista, Bauru, 2016.

CHAPMAN, STEPHEN J. **Fundamentos de Máquinas Elétricas**. Porto Alegre: McGraw Hill, 2013.

CHOW, M. and 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 **6(3)**: 536–545, (1991).

CLERICE, G. A. M. **Localização de Descargas Parciais por Meio de Cápsulas Piezelétricas de Baixo Custo e Sistemas Inteligentes**. 2014. 120 f. Dissertação (Mestrado). Faculdade de Engenharia, Universidade Estadual Paulista, Bauru, 2014.

CORNELL, E. P.; OWEN, E. L., APPIARIUS, J. C., **Improved motors for utility applications**, v. 1, EPRI, 1982.

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** **37(5)**: 1227–1233. 2001.

DAS, S.; PURKAIT, P.; CHAKRAVORTI, S. **Space-Vector Characterization of Induction Motor Operating Conditions**. Fifteenth National Power Systems Conference, 2008.

DEMUTH, H.; BEALE, M.; HAGAN, M. **Neural Network Toolbox – User’s Guide**. Version 6.0.4. The Mathworks Inc., 901p, 2010. Disponível em: <<http://www.world-exchanges.org/statistics/monthly-reports>>. Acesso em: 17 nov. 2016

ELETROBRAS. **Demanda Energética Brasileira**. 2015. Disponível em: <<http://www.elektrobras.com>>. Acesso em: 25 ago. 2016.

EPE. Balanço Energético Nacional 2016 – ano base 2015 – Relatório Final. **Empresa de Pesquisa Energética – Ministério de Minas e Energia**. Disponível em: <<http://www.ben.epe.gov.br>>. Acesso em: 09 set. 2016

FITZGERALD, A.; KINGSLEY, C.; UMANS, S. **Máquinas Elétricas**. 6. ed. Porto Alegre: Bookman, 2008.

GENTILE, G.; MEO, S.; OMETTO, A. Induction motor current signature analysis to diagnostics of stator short circuits. In: **4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives**, Atlanta, n. 4, p. 47-51, Agosto 2003.

GHATE, V. N. AND DUDUL, S. V. **Fault diagnosis of three phase induction motor using neural network techniques**, Proc. Second International Conference on Emerging Trends in Engineering & Technology (ICETET), number 1, pp. 922–928, 2009

GHATE, V., N.; DUDUL, S. V. **Optimal MLP neural network classifier for fault detection of three phase induction motor**. Expert Systems Whit Applications 37(4), pp 3468-3481, 2010.

GHATE, V. N. AND DUDUL, S. V. **Cascade neural network based fault classifier for three phase induction motor**, IEEE Transactions on Industrial Electronics 58(5): 1555–1563, 2011.

GOEDEL, A. **Estimador Neural de Velocidade para Motores de Indução Trifásico**. 159 p. Tese (Doutorado)–Escola de Engenharia de São Carlos - Universidade de São Paulo, São Carlos-SP, 2007.

GOEDEL, A. **Estimativa de Conjugado em Eixos de Motores De Indução Trifásicos Através de Redes Neurais Artificiais**. Universidade Estadual Paulista, Bauru, SP, 2010.

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

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt Algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, 1994.

HAYKIN, S. S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

IEEE Std. 493-1997 **.IEEE Recommended Practice for The Design of Reliable Industrial and Commercial Power Systems**, [IEEE Gold Book], Appendix H, 1997.

LEE, S. B.; YANG, J.; HONG, J.; YOO, J.; KIM, B.; LEE, K.; YU, J.; KIM, M.; WIEDENBRUG, E. J.; NANDI, S. A new strategy for condition monitoring of adjustable speed induction machine drive systems, **IEEE Transactions on Power Electronics** **26(2)**: 389–398, 2011.

LEITE, D. F. **Sistema de Diagnóstico de Falhas em Máquinas Elétricas de Corrente Alternada**. Dissertação (Mestrado)–PUC-MG, 2007.

LEITE, D. F., HELL, M. B., COSTA JR., P. AND GOMIDE, F. **Real-time fault diagnosis of nonlinear systems**, **Nonlinear Analysis: Theory, Methods & Applications** **71(12)**: e2665–e2673. (2009).

MARCHI, M. **Uma aplicação do método de impedância eletromecânica na detecção da queima no processo de retificação plana**. 2015. 80 f. Tese (Doutorado em Engenharia Elétrica). Faculdade de Engenharia, Universidade Estadual Paulista. Bauru, Brasil. 2015.

MARTINS, P. V. **Utilização de microfones comuns para detecção de defeitos em máquinas de pequeno porte**. Salvador: Universidade Salvador, 2010.

MEHALA, Neelam. Short Winding Fault Detection using Park's Vector [Online]. **IJECBS. - International Journal of Enterprise Computing and Business Systems (Online)**, IJECBS India, 2 julho 2012. Disponível em: <<http://www.ijecbs.com/July2012/4.pdf>>. Acesso em: 24 jan. 2016.

MORAES, P. H. A. **Manutenção Produtiva Total: Estudo de caso em uma empresa automobilística**. Dissertação (Mestrado). Universidade de Taubaté, São Paulo, 2004.

MURATA. Murata manufacturing Co. Ltda. **Catálogo de produtos**. Disponível em: <<http://www.murata.com/>>. Acesso em: 24 jan. 2016.

NANDI, S.; TOLIYAT, H. A.; XIADONG, L. Condition Monitoring and Fault Diagnosis of Electrical machines - A Review. **IEEE Transactions on Energy Conversion**, v. 20, n. 4, December, pp. 719-729, 2005.

NASCIMENTO, C. F.; JR., A. A. O.; GOEDEL, A.; SERNI, P. J. A. Harmonic identification using parallel neural networks in single-phase systems. **Applied Soft Computing**, v. 11, n. 2, p. 2178–2185, 2011.

PEREIRA, L. A.; SILVA GAZZANA, D.; PEREIRA, L. F. A. Motor current signature analysis and fuzzy logic applied to the diagnosis of short -circuit faults in induction motors. In: **32nd Annual Conference of IEEE Industrial Electronics Society**, North Carolina, n. 32, p. 275-280, nov. 2005.

PINTO, A. K.; XAVIER, J. N. **Manutenção: função estratégica**. Rio de Janeiro: Qualitymark, 2005.

PRECHELT, L. **Early Stopping - but when?** Technical Report, 1997. Disponível em: <http://www.ipd.ira.uka.de/~prechelt/Biblio/stop_tricks1997.ps.gz>: Acesso em: 28 maio. 2016.

RAO, S. SINGIRESU. **Vibrações Mecânicas**, Pearson Prentice Hall, Quarta Edição, São Paulo (2009).

REIS, A. J. S. **Reconhecimento de Padrões de Falhas em Motores Trifásicos Utilizando Redes Neurais**. Dissertação (Mestrado)–Centro de Tecnologia. Programa de Pós-graduação em Engenharia Elétrica e Computação - Universidade Federal do Rio Grande do Norte, Natal-RN, 2009.

REZENDE FILHO, O. **Aplicações termográficas na Manutenção Onde normalmente erramos!** Revista Manutenção y Qualidade, 28 p. 2007.

REZENDE, S. M. **Materiais e dispositivos eletrônicos**. 2. ed. São Paulo: Editora Livraria da Física, 2004. 547 p.

RIBEIRO, H. **Total Productive Maintenance (TPM) Manutenção Produtiva Total**. São Paulo: Elipse, 2003.

RIEHL, Rudolf Ribeiro. **Uma metodologia para determinação das capacitâncias parasitas de motores de indução trifásicos de rotor em gaiola**. Tese (Doutorado) Universidade de Campinas, Campinas-SP, 2010.

RISTIC, L.; JEFTENIC, B. Implementation of fuzzy control to improve energy efficiency of variable speed bulk material transportation. **IEEE Transactions on Industrial Electronics**, v. 59, n. 7, p. 2959–2969, jul. 2012.

SAGE, A.P. **Concise Encyclopedia of Information Processing in Systems and Organizations**, New York, Pergamon, 1990.

SAMPAIO, C. **Conceitos Básicos de Vibração**. Escola Náutica I. D. Henrique. Lisboa, Portugal. (2004).

SANTOS, F. M. C.; SILVA, I. N.; SUETAKE, M. Abordagem neural para detecção de falhas em rotores de motores de indução usando parâmetros estatísticos. **XIX Congresso Brasileiro de Automática (CBA)**, v. 1, p. 200–206, set. 2012a.

SANTOS, F. M. C.; SILVA, I. N.; SUETAKE, M. Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução - uma visão geral. **SBA – Sociedade Brasileira de Automática - Controle & Automação**, Scielo, v. 23, p. 553–569, outubro 2012b.

SANTOS, F. M. C. **Identificação de Falhas em motores de Indução Trifásicos usando Sistemas Inteligentes**. 110p. Tese (Doutorado) – Escola de Engenharia de São Carlos, USP, 2013.

- SEINSCH, H. O. Monitoring und Diagnose Elektrischer Maschinen und Antriebe. **Allianz Schadensstatistik an HS Motoren**, 1996–1999, In: VDE Workshop, 2001.
- SHARIFI, RASOOL; EBRAHIMI, MOHAMMAD. Detection of stator winding faults in induction motors using three-phase current monitoring. **ISA Transactions**, v. 50, pp. 14-20, 2011.
- SIDDIQUI, K. M.; SAHAY, K.; GIRI, V. K. Health monitoring and fault diagnosis in induction motor, a review. **International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering**, v. 3, n. 1, p.6549–6565, 2014.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 399 p.
- STONE, G.; KAPLER, J., Stator winding monitoring. **Industry Applications Magazine, IEEE**, v. 4, n. 5, pp. 15–20, 1998.
- SPATTI, D. H. **Automatização de Processos de Detecção de Falhas em Linhas de Distribuição Utilizando Sistemas Especialistas Híbridos**. 2011. 208 f. Tese (Doutorado em Engenharia Elétrica). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, Brasil. 2011.
- SPECHT, D. F. Probabilistic Neural Networks and the Polynomial Adaline as Complementary Techniques for Classification. **IEEE Transactions on Neural Networks**, v. 1, pp. 111-121, 1990.
- SUG, H. **Performance comparison of RBF networks and MLPs for classification**. In Proceedings of the 9th WSEAS international Conference on Applied informatics and Communications. Stevens Point, Wisconsin, p. 450-454, Agosto, 2009.
- SUETAKE, M. **Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos**. Tese (Doutorado)–Escola de Engenharia de São Carlos - Universidade de São Paulo, São Carlos-SP, 2012.
- TALLAM, R. M., HABETLER, T. G. AND HARLEY, R. G. **Stator winding turn-fault detection for closed-loop induction motor drives**, IEEE Transactions on Industry Applications 39(3): 720–724. (2003).
- TAVNER, P. **Condition Monitoring of Rotating Electrical Machines**. IET, 2008.
- THOMSON, W. T.; FENGER, M. Current Signature Analysis to Detect Induction Motor Faults, **IEEE Transactions on Industry Applications**, v. 7, july / august, pp. 26-34, 2001.
- TOLIYAT, H. A.; NANDI, S.; CHOI, S.; MESHGIN-KELK, H. **Electric Machines, Modeling, Condition Monitoring and Fault Diagnosis**. Boca Raton, FL: CRC, 2012.
- TOLIYAT, H. A.; NANDI, S.; CHOI, S.; MESHGIN-KELK, H. **Electric Machines**. CRC Press: USA, 2013.

TRUTT, F. C.; SOTTILE, J.; KOHLER, J. L. Detection of AC Machine Winding Deterioration Using Electrically Excited Vibrations. **IEEE Transactions on Industry Applications**, v. 37, n. 1, pp. 10-14, january / february 2001.

TRZYNADLOWSKI, A. M. **Control of Induction Motors**. Academic Press Series in Engineering, Academic Press, Incorporated (2001).

UKIL, Abhisek; SHUO, Chen; ANDREA, Andenna. Detection of stator short circuit faults in three-phase induction motors using motor current zero crossing instants. **Electric Power Systems Research**, pp 1036-1044, 2010.

ULSON, J. A. C. **Redes Neurais Artificiais – Capítulo 04**. Programa de Pós-Graduação em Engenharia Elétrica, Faculdade de Engenharia de Bauru – UNESP, pp. 2, 2009. Notas de Aula.

WEG, E. E. M. **Diagnóstico de problemas em máquinas elétricas girantes através da medição e da análise do espectro de vibração mecânica**. Departamento de P&D do Produto. Jaraguá do Sul: Eletromotores WEG, 2012.

WEG. **Guia de especificação de motores elétricos**. s.i.: Jaraguá do Sul: Eletromotores WEG, 2014a.

WEG. **Manual de instalações e manutenção de motores elétricos**. Jaraguá do Sul: Eletromotores WEG, 2014b, 37 p.

WU, S. AND CHOW, T. **Induction machine fault detection using SOM-based RBF neural networks**, IEEE Transactions on Industrial Electronics 51(1): 183–194 (2004).