

Detecção de Falha do Estator de um Motor de Indução Trifásico Utilizando uma Bobina Exploratória Externa

João Paulo Vicente

Orientadores:

Prof. Dr. Ângela Paula Barbosa de Silva Ferreira

Prof. Dr. Marcelo Favoretto Castoldi

Prof. Dr. João Paulo Teixeira

Bragança

2020

Detecção de Falha do Estator de um Motor de Indução Trifásico Utilizando uma Bobina Exploratória Externa

João Paulo Vicente

Dissertação apresentada à Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Bragança para a obtenção do grau de Mestre em Engenharia Industrial - ramo Engenharia Eletrotécnica, no âmbito do Programa de Dupla Diplomação com a Universidade Tecnológica Federal do Paraná

Orientadores:

Prof. Dr. Ângela Paula Barbosa de Silva Ferreira

Prof. Dr. Marcelo Favoretto Castoldi

Prof. Dr. João Paulo Teixeira

Bragança

2020

Resumo

Este trabalho apresenta uma metodologia para a detecção de falhas de curtos-circuitos entre as espiras de motores de indução trifásicos, utilizando uma bobina exploratória externa, que é uma técnica não invasiva e pode ser utilizada durante a operação do motor. O fluxo magnético de dispersão do motor, operando em condições de curto-circuito, induz uma tensão na bobina exploratória que difere de um padrão de referência, que é correspondente ao motor operando de forma saudável.

Os dados experimentais foram obtidos numa bancada de teste, composta por um motor de indução trifásico com rotor gaiola de esquilo de 0,75kW. O enrolamento do estator desse motor é modificado para permitir a introdução de curto-circuitos. Este trabalho considerou os curto-circuitos em uma fase, com 1%, 3%, 5% e 10% das espiras, com o motor operando com carga variável.

O diagnóstico de curto-circuitos são obtidos através da análise de diferentes topologias de redes neurais artificiais *perceptron* multicamadas, com os dados experimentais utilizados em três abordagens diferentes. A primeira abordagem consiste em utilizar os dados no domínio do tempo, na segunda abordagem é realizado a transformada de Fourier dos dados e é coletado a energia numa banda de frequências e na terceira abordagem, também é realizado a transformada de Fourier dos dados, sendo utilizadas as amplitudes dos harmônicos.

Os resultados obtidos demonstram que a metodologia proposta apresenta dificuldades em identificar falhas em estágios incipientes, mais precisamente os curto-circuitos de 1%, entretanto para os de curto-circuito de 10%, a taxa de exatidão das redes neurais foi de 100%. Dentre as 3 abordagens testadas na utilização dos dados, a abordagem que utiliza as amplitudes dos harmônicas foi a que apresentou a melhor eficácia no diagnóstico de curto-circuito no enrolamento do estator. Concretamente, com a melhor topologia obtiveram-se exatidões de 87% e 95% para os casos da utilização e sem utilização, respetivamente, das amostras com curto-circuito de 1%.

Palavras chaves: Motor de indução trifásico, Bobina exploratória externa, Redes neurais artificiais, Identificação de falhas, Curtos-Circuitos

Abstract

This work presents a methodology for detecting inter-turns short-circuit fault of three-phase induction motors, using an external search coil, which is a non-invasive technique and can be used during the operation of the motor. The dispersion magnetic flux of the motor operating in short-circuit conditions induces a voltage in the search coil that differs from a reference pattern, which corresponds to the motor operating healthily.

The experimental data were obtained in a test bench, using a 0.75 kW three-phase squirrel-cage induction motor with the stator winding modified to allow the introduction of short circuits. This work considered the short-circuits in one phase, with 1%, 3%, 5% and 10% of the turns, with the motor operating with variable load

The diagnosis of short circuits is obtained through the analysis of different topologies of multilayer perceptron artificial neuronal networks, with the experimental data used in three different approaches. The first approach consists of using the data in the time domain, in the second approach the Fourier transform of the data is performed and energy is collected in a frequency band and in the third approach, the Fourier transform of the data is also performed, being used the amplitudes of the harmonics.

The results obtained demonstrate that the proposed methodology presents difficulties in identifying flaws in incipient stages, more precisely short circuits of 1%, however for short circuits of 10%, the accuracy rate of neural networks was 100%. Among the three approaches tested in the use of data, the approach that uses the amplitudes of the harmonics was the one that showed the best efficiency in the diagnosis of a short circuit in the stator winding. Specifically, with the best topology, accuracy of 87% and 95% was obtained for the cases of use and without use, respectively, of the samples with a short circuit of 1%.

Keywords: Three-Phase Induction Motor, External Search Coil, Artificial Neuronal Network, Fault Identification, Short-Circuits

Agradecimentos

Agradeço a Deus, pela dádiva da vida e por estar sempre ao meu lado, me guiando e iluminando os meus passos.

Agradeço a toda minha família, sou eternamente grato por todo apoio, incentivo, esforço, carinho e amor, sem vocês eu não teria consigo chegar até esse momento. Em especial gostaria de agradecer aos meus pais, José Vicente e Rosangela Vicente, por sempre estarem ao meu lado, me auxiliando nos momentos mais difíceis, por serem o meu porto seguro e por muitas vezes abdicaram de sonhos e desejos para que eu conseguisse atingir os meus. Aos meus tios, Neiton Arantes e Lúcia Arantes, meus pais de coração, por todo o apoio, incentivo, auxílio financeiro e acima de tudo, por sempre acreditarem no meu potencial.

Aos meus orientadores, Prof. Dr^a Ângela Paula Ferreira e Prof. Dr. Marcelo Favoretto Castoldi, exemplos de profissionais e orientadores. Agradeço pelas valiosas orientações, disponibilidade, e inúmeros e inestimáveis conselhos no desenvolvimento deste trabalho. Por sempre acreditarem em mim, incentivando e apoiando nos momentos que mais precisei.

Aos meus Coorientadores Prof. Dr. João Paulo Teixeira e Prof. Dr. Alessandro Goedel, por todo auxílio prestado no desenvolvimento deste trabalho, conselhos e ensinamentos.

A todos os meus amigos, em especial a Anderson Nunes, Dyudson Vicente, Enrique Santos, Felipe Ehara, Gabriel Mendes, Gustavo Soares, Henrique Gaudeoso, Heloísa Oliveira, Iolanda Ortiz, Kathleen Carvalho, Matheus Santos, Pedro Borghi, Victor Polidório e Yuri Bornea, por todo apoio, auxílio, e principalmente, a amizade e companheirismo.

A todos os membros do Laboratório de Sistemas Inteligentes (LSI), pelo acolhimento, incentivos e auxílios. Em especial a Prof. Dr^a. Jacqueline Jordan, Prof. Me. Murillo Gentil, Prof. Me. Gustavo Bazan e Prof. Me. Igor Elias pelos conselhos e por sempre se colocarem a disposição para auxiliar.

Ao Programa de Dupla Diplomação entre a Universidade Tecnológica Federal do Paraná, Cornélio Procópio, com o Instituto Politécnico de Bragança, pela oportunidade a mim concebida.

Conteúdo

Lista de Figuras	xiii
Lista de Tabelas	xv
Lista de Abreviações	xvii
Lista de Símbolos.....	xix
1 Introdução.....	3
1.1 Motivação	3
1.2 Falhas em Motores de Indução	4
1.2.1 Falhas no enrolamento do estator	5
1.3 Objetivos.....	5
1.4 Estrutura do Trabalho	6
1.5 Artigo Publicado.....	6
2 Estado da Arte.....	9
2.1 Introdução	9
2.2 Diagnósticos Baseados na Análise de Sinais.....	9
2.3 Diagnósticos a partir da modelagem do motor	11
2.4 Diagnosticos de falhas baseados em Sistemas Inteligentes.....	12
3 Redes Neurais Artificiais.....	17
3.1 Introdução	17
3.2 Principais Aplicações	17
3.3 Neurónio Artificial	18
3.4 Funções de Ativações	19
3.5 Arquiteturas de RNA	21
3.5.1 Redes feedforward Perceptron Multicamadas	22
3.6 Validação Cruzada <i>k-fold</i>	23
4 Transformada de Fourier e Janelamento.....	27
4.1 Introdução	27
4.2 Transformada de Fourier	27
4.3 Transformada Discreta de Fourier	27
4.4 Transformada Rápida de Fourier	27
4.5 Janelamento	28
5 Materiais e Métodos.....	31

5.1	Introdução	31
5.2	Reprodução de Falhas no Estator	31
5.3	Bancada Experimental	33
5.4	Bobina Exploratória Externa.....	36
5.4.1	Determinação do Ponto de Alocação da Bobina.....	37
5.4.1.1	Motor operando em vazio	37
5.4.1.2	Motor operando com carga nominal.....	39
5.5	Metodologia para a Detecção de Falhas	41
5.5.1	Domínio do tempo	43
5.5.2	Domínio da Frequência - Banda de Frequência.....	43
5.5.3	Domínio da Frequência - Amplitude Harmônicos.....	43
6	Resultados e Discussões	47
6.1	Introdução	47
6.2	Organização dos dados e cálculo de exatidão	47
6.3	Análise no Domínio do Tempo	49
6.4	Análise no Domínio da Frequência - Banda de Frequências	54
6.5	Análise no Domínio da Frequência Amplitudes Harmônicas.....	62
6.6	Discussão dos Resultados	69
7	Conclusão	73
7.1	Trabalhos Futuros	74
	Referências	76

Lista de Figuras

Figura 1.1 - Classificação das falhas em motores de indução, adaptado de (Yeh <i>et al.</i> , 2008) .4	4
Figura 1.2 - Percentuais de falhas em motores de indução, (Bonnett; Yung, 2008 e Yeh <i>et al.</i> , 2008).....4	4
Figura 1.3 - Tipos de falhas no enrolamento do estator, adaptado de (Siddiqui <i>et al.</i> , 2014)... 5	5
Figura 3.1 - Neurónio artificial, adaptada de (Silva <i>et al.</i> , 2017)..... 19	19
Figura 3.2 - Função de ativação logística 20	20
Figura 3.3 - Função de ativação tangente hiperbólica 20	20
Figura 3.4 - Função de ativação Elliot..... 21	21
Figura 3.5 - Função de ativação linear 21	21
Figura 3.6 - Redes <i>Perceptron</i> Multicamadas, adaptado de (Silva <i>et al.</i> , 2017) 22	22
Figura 3.7 - Ilustração das fases do algoritmo <i>backpropagation</i> , adaptado de (Silva <i>et al.</i> , 2017)..... 23	23
Figura 3.8 - Validação cruzada <i>k-fold</i> , adaptado de (Silva <i>et al.</i> , 2017) 24	24
Figura 4.1 - Janela de Hamming..... 28	28
Figura 5.1 - Disposição das bobinas ao longo das ranhuras do estator (Suetake, 2012). 31	31
Figura 5.2 - Derivações do enrolamento do estator para realização de ensaios de curto-circuito (Suetake, 2012)..... 32	32
Figura 5.3 - Imagem ilustrativa das tomadas de derivação, adaptado de (Guedes, 2016) 32	32
Figura 5.4 - Disposição das tomadas na caixa de ligação 33	33
Figura 5.5 - Esquema da bancada de ensaios 34	34
Figura 5.6 - Bancada de ensaios 34	34
Figura 5.7 - Configurações de núcleos, adaptado de (Ertan; Keysan, 2009) 36	36
Figura 5.8 - Bobina exploratória..... 36	36
Figura 5.9 - Posições da bobina no MIT 37	37
Figura 5.10 - Bobina na posição 1, MIT em vazio 37	37
Figura 5.11 - Bobina na posição 2, MIT em vazio 38	38
Figura 5.12 - Bobina na posição 3, MIT em vazio 38	38
Figura 5.13 - Bobina na posição 4, MIT em vazio 38	38
Figura 5.14 - Bobina na posição 5, MIT em vazio 38	38
Figura 5.15 - Bobina na posição 6, MIT em vazio 39	39
Figura 5.16 - Bobina na posição 1, MIT com carga nominal 39	39
Figura 5.17 - Bobina na posição 2, MIT com carga nominal 40	40
Figura 5.18 - Bobina na posição 3, MIT com carga nominal 40	40
Figura 5.19 - Bobina na posição 4, MIT com carga nominal 40	40
Figura 5.20 - Bobina na posição 5, MIT com carga nominal 40	40
Figura 5.21 - Bobina na posição 6, MIT com carga nominal 41	41
Figura 5.22 - Esquema metodológico..... 42	42
Figura 5.23 - Processamento dos dados para o domínio do tempo 43	43
Figura 5.24 - Processamento dos dados para a abordagem no domínio da frequência 43	43
Figura 5.25 - Processamento dos dados para a abordagem no domínio da frequência 43	43
Figura 6.1 - Sinal da tensão induzida com o motor saudável e com curto-circuito de 1%, binário de 0,5 Nm 48	48
Figura 6.2 - Exatidão da topologia 5 e topologia 8 com e sem as amostras de C.C. 1% 53	53
Figura 6.3 - Exatidão das classes com e sem as amostras de C.C. 1% 54	54

Figura 6.4 - Exemplo da abordagem adotada	54
Figura 6.5 - Exemplo da abordagem adotada para frequência de 180Hz a 2100Hz.....	55
Figura 6.6 - Comparativo das exatidões das diferentes topologias testadas com e sem as amostras de C. C. 1%	61
Figura 6.7 - Comparativo na exatidão das classes das duas topologias que utilizam R. Bayesian com e sem a utilização das amostras de C. C. 1%.....	61
Figura 6.8 - Comparativo da exatidão das classes das duas topologias que utilizam L. Marquardt com e sem a utilização das amostras de C. C. 1%	62
Figura 6.9 - Exemplo da coletado dos dados	63
Figura 6.10 - Exatidão das diferentes topologias analisadas, com e sem as amostras de curto-circuito de 1%	68
Figura 6.11 - Comparativo da exatidão das classes das duas topologias que utilizam R. Bayesian com e sem a utilização das amostras de C. C. 1%.....	68
Figura 6.12 - Comparativo da exatidão das classes das duas topologias que utilizam L. Marquardt com e sem as amostras de C. C. 1%.....	69

Lista de Tabelas

Tabela 5.1 - Parâmetros e características dos MIT utilizado.....	35
Tabela 5.2 - Parâmetros e características do gerador CC	35
Tabela 5.3 - Status de funcionamento do motor e variação do binário na coleta dos dados exmpeimentais	42
Tabela 6.1 - Padrão de saída das redes neuronais.....	48
Tabela 6.2 - Padrão de saída das redes neuronais sem as amostras de curto-circuito de 1% ...	49
Tabela 6.3 - Resultados preliminares no domínio do tempo	50
Tabela 6.4 - Matriz de confusão para a topologia 5	51
Tabela 6.5 - Matriz de confusão para a topologia 8	51
Tabela 6.6 - Matriz de confusão topologia 5 sem as amostras de curto-circuito de 1%	52
Tabela 6.7 - Matriz de confusão topologia 8 sem as amostras de curto-circuito de 1%	52
Tabela 6.8 - Resultados no domínio da frequência banda de frequência	56
Tabela 6.9 - Matriz de confusão para a topologia 6	57
Tabela 6.10 - Matriz de confusão para a topologia 18	57
Tabela 6.11 - Matriz de confusão para a topologia 24	58
Tabela 6.12 - Matriz de confusão para a topologia 41	58
Tabela 6.13 - Matriz de confusão para a topologia 6 sem as amostras de curto-circuito de 1%	59
Tabela 6.14 - Matriz de confusão para a topologia 18 sem as amostras de curto-circuito de 1%	59
Tabela 6.15 - Matriz de confusão para a topologia 24 sem as amostras de curto-circuito de 1%	60
Tabela 6.16 - Matriz de confusão para a topologia 41 sem as amostras de curto-circuito de 1%	60
Tabela 6.17 - Resultados no domínio da frequência: ordem harmônicas.....	64
Tabela 6.18 - Matriz de confusão dos resultados da topologia 2	65
Tabela 6.19 - Matriz de confusão dos resultados da topologia 5	65
Tabela 6.20 - Matriz de confusão dos resultados da topologia 30	65
Tabela 6.21 - Matriz de confusão dos resultados da topologia 33	66
Tabela 6.22 - Matriz de confusão para a topologia 2, sem as amostras de curto-circuito de 1%	66
Tabela 6.23 - Matriz de confusão para a topologia 5, sem as amostras de curto-circuito de 1%	67
Tabela 6.24 - Matriz de confusão para a topologia 30, sem as amostras de curto-circuito de 1%	67
Tabela 6.25 - Matriz de confusão para a topologia 33, sem as amostras de curto-circuito de 1%	67
Tabela 6.26 - Comparativo entre os resultados desse trabalho e trabalhos recentes no diagnostico de curtos circuitos no enrolamento do estator.....	70

Lista de Abreviações

AD	Árvore de Decisão
AG	Algoritmo Genético
ANFIS	<i>Adaptive Neuro Fuzzy Inference System</i>
C.C.	Curto-Circuito
CE	Camada Escondida
CS	Camada Saída
DC	Corrente Contínua
DFT	<i>Discrete Fourier Transform</i>
EPRI	<i>Electric Power Research Institute</i>
EXA	Exatidão
IEEE	<i>Institution of Electrical and Electronics Engineers</i>
FBG	<i>Fiber Bragg Grating</i>
FFT	<i>Fast Fourier Transform</i>
LF	Lógica Fuzzy
MIT	Motor de Indução Trifásicos
MLP	<i>Multilayer Perceptron</i>
Occ	Ocorrencia
RBF	<i>Radial Basis Function</i>
RNA	Redes Neurais Artificiais
SI	Sistemas Inteligentes
SVM	<i>Support Vector Machines</i>

Lista de Símbolos

f_a	Frequência de amostragem
$g(\cdot)$	Função de ativação
k	Número inteiro
n	Número inteiro positivo
N	Quantidade de amostras
NA	Número de acerto
NT	Número de amostra conjunto de teste
R	Resolução da FFT em Hz
u	Potencial de ativação
w_{ham}	Janela de Hamming
w_n	n-ésimo peso sináptico do <i>perceptron</i> simples
x_n	n-ésima entrada da <i>perceptron</i> simples
$x(n)$	Sequência discreta de um sinal $x(t)$
$x(t)$	Sinal no domínio do tempo
$X(k)$	Sequência discreta $x(n)$ no domínio da frequência
$X(\omega)$	Sinal $x(t)$ no domínio da frequência
y	Sinal de saída
θ	Limiar de ativação

Capítulo 1

Introdução

1 Introdução

1.1 Motivação

Os Motores de Indução Trifásicos (MIT) são amplamente utilizados no setor industrial, na conversão de energia elétrica em energia mecânica. A vasta aplicação destes motores deve-se à sua robustez, baixo custo na aquisição, fácil manutenção e a adaptação a diversas cargas (Palácios *et al.*, 2015; Guedes, 2016; Bazan *et al.*, 2019).

No setor industrial, são empregados em aplicações gerais, como em sistemas de bombeamento, sistemas transportadores, compressores e entre outras (Filho; Pederiva; Brito, 2014). É ainda comum a sua utilização em situações críticas, que requerem alta fiabilidade, como em aplicações nucleares, aeroespaciais, entre outras (Ayhan *et al.*, 2005). Os motores de indução são empregados em cerca de 80% das aplicações (Ayhan *et al.*; 2005), consumindo aproximadamente 85% da energia em plantas/fábricas industriais (Hassan *et al.*, 2018)

Apesar da robustez e fiabilidade que caracterizam os MIT, estes dispositivos são suscetíveis a falhas, que podem ocorrer devido a longos tempos de operação, condições severas de funcionamento, como sobrecargas e sobretensões, desequilíbrios de tensões e correntes, entre outros fatores (Bazan *et al.*, 2017). Avarias nos motores de indução reduzem a eficiência dos sistemas, podendo aumentar o consumo de energia. (Singh; Kumar; Naikan, 2016). No setor industrial, paragens não programadas ocasionam gastos com manutenção e prejuízos na produção (Guedes, 2016).

No decorrer dos últimos anos, os estudos em âmbitos acadêmicos e industriais para a elaboração de sistemas de monitoramento de condição de motores de indução, com o objetivo de monitorar e/ou observar continuamente a integridade do sistema, vêm recebendo grande interesse de pesquisas, visando melhorar a produtividade dos sistemas, eficiência, redução nos custos e aumentar a disponibilidade das máquinas (Bellini *et al.*, 2008; Choudhary *et al.*, 2018).

As grandezas do motor, tais como tensão, corrente, fluxo magnético, vibração, entre outras, indicam características do funcionamento e, por isso, podem ser utilizadas para a identificação de possíveis falhas. Quando aliadas a Sistemas Inteligentes (SI) é possível realizar a identificação de falhas do MIT de forma expedita e eficiente. Durante o ajuste desses sistemas, são apresentados as grandezas do motor em condições sem falha e com falhas, uma vez que esses sistemas possuem a capacidade de realizar a extração de características do MIT e, quando implementados, podem indicar se o motor está operando sob falhas ou não. A implementação de um SI para a identificação de falhas em MIT requer uma complexidade computacional baixa,

devido ao fato de não necessitar do modelo matemático do MIT. Os principais SI são: Redes Neurais Artificiais (RNA), Logica *Fuzzy* (LF) e Algoritmos genéticos (AG).

1.2 Falhas em Motores de Indução

As falhas em motores de indução, podem ser classificadas como apresentado no esquema da Figura 1.1 (Yeh *et al.*, 2008).

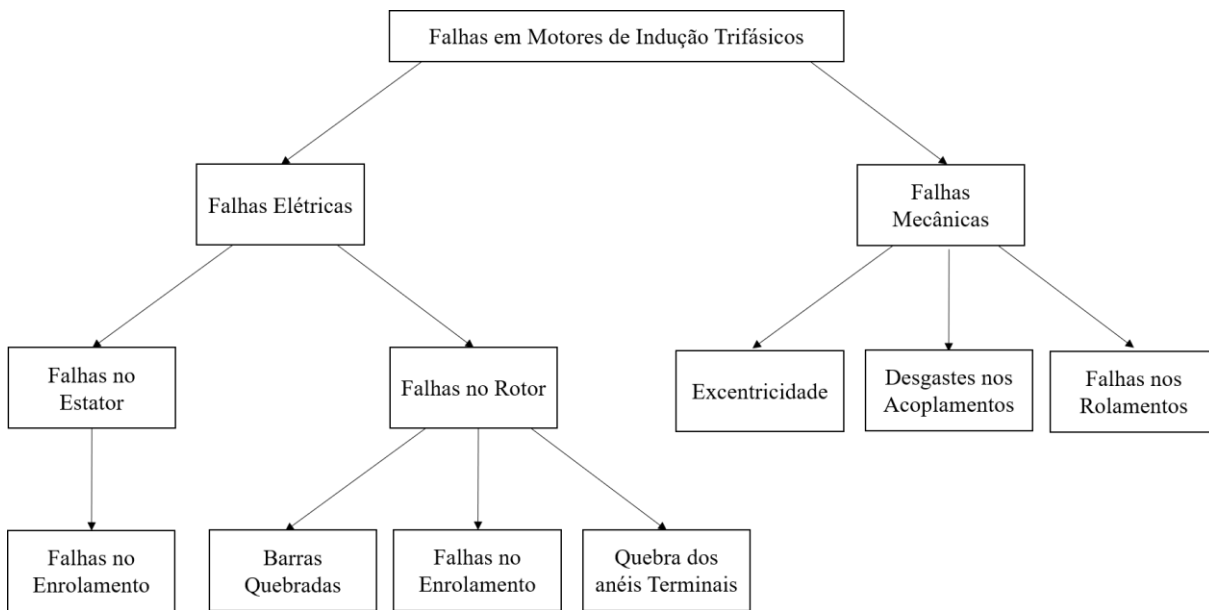


Figura 1.1 - Classificação das falhas em motores de indução, adaptado de (Yeh *et al.*, 2008)

Na Figura 1.2 são apresentados os estudos estatísticos das principais falhas em motores de indução, realizados pelo *Institution of Electrical and Electronics Engineers* (IEEE), *Electric Power Research Institute* (EPRI) e Bonnett; Yung (2007).

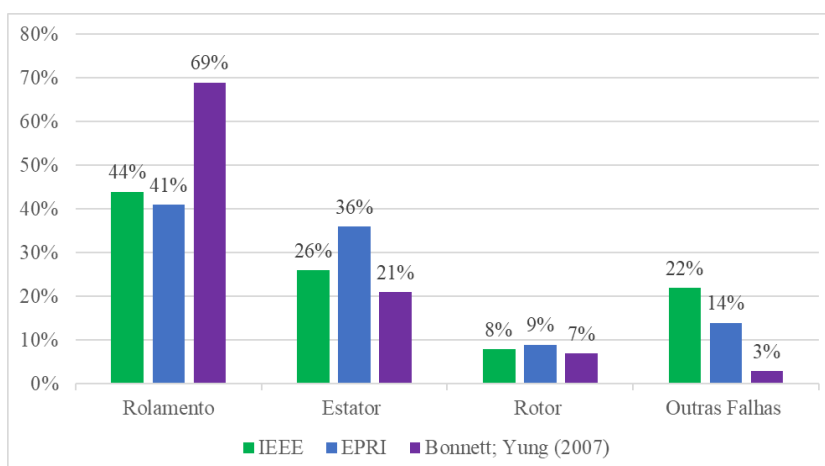


Figura 1.2 - Percentuais de falhas em motores de indução, (Bonnett; Yung, 2008 e Yeh *et al.*, 2008)

Pela Figura 1.2, nota-se que as falhas no enrolamento do estator é a segunda falha com maior incidência, sendo o objeto de estudo deste trabalho.

1.2.1 Falhas no enrolamento do estator

As falhas no enrolamento do estator, na maioria das vezes estão relacionadas com o desgaste do material isolante do condutor, que é devido ao envelhecimento do mesmo ou devido a algum estresse, como sobreaquecimento, vibração e/ou sobretensão transitória (Riera-Guasp *et al.*; 2015). Uma falha local no material isolante, gera uma falha de curto-circuito entre espiras, desse modo, uma corrente de defeito começa a circular pelo enrolamento. O efeito térmico devido à corrente de defeito, degrada o material isolante das espiras adjacentes e por fim afeta o isolamento das outras fases, podendo provocar curtos-circuitos extensos, entre fases ou entre fase-terra. A evolução das falhas de curto circuito no enrolamento do estator desenvolve-se rapidamente, assim se não forem tomadas medidas rápidas, a falha pode-se tornar catastrófica e irreparável (Guedes, 2016; Riera-Guasp *et al.*; 2015).

As falhas no enrolamento do estator mais comuns são: curto-circuito entre espiras, curto-circuito entre bobinas, curto-circuito entre bobinas de diferentes fases, curto-circuito entre fase-terra e circuito aberto (Siddiqui *et al.*, 2014). Na Figura 1.3 são apresentados os tipos de falhas supracitadas.

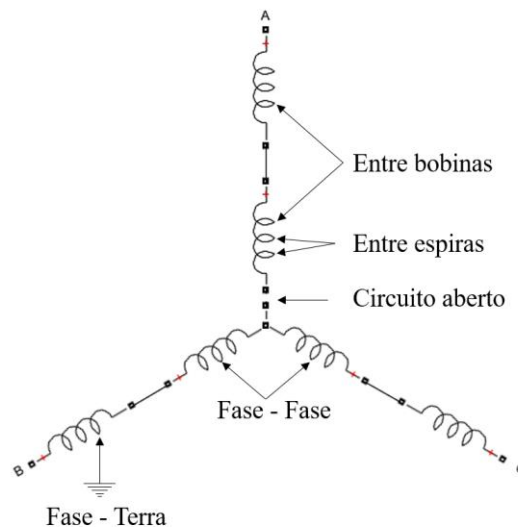


Figura 1.3 - Tipos de falhas no enrolamento do estator, adaptado de (Siddiqui *et al.*, 2014)

1.3 Objetivos

O objetivo dessa dissertação consiste em desenvolver um método de diagnóstico e de classificação do grau de severidade de falhas de curto-circuito entre as espiras do enrolamento do estator, a partir da análise do sinal de tensão induzida numa bobina exploratória externa, utilizando para o efeito Redes Neurais Artificiais (RNA). Os objetivos específicos desta pesquisa são:

- Realizar a construção da bobina;

- Determinar por meio de testes laboratoriais os melhores pontos de alocação da bobina exploratória na carcaça do MIT;
- Implementar Redes Neurais Artificiais para o diagnóstico e a classificação do grau de severidade de curto-circuitos no enrolamento do estator.

1.4 Estrutura do Trabalho

No Capítulo 1 foi apresentado a introdução do trabalho, motivação, objetivos e a estruturação do trabalho.

No Capítulo 2 é realizado o estado da arte na identificação de falhas em motores de indução, nomeadamente em falhas nos enrolamentos do estator.

No Capítulo 3 são apresentados conceitos fundamentais sobre RNA, como as suas diferentes aplicações e arquiteturas. É ainda definida a arquitetura da RNA a ser utilizada nesse trabalho.

No Capítulo 4 são apresentados conceitos fundamentais sobre a Transformada Rápida de Fourier e janelamento.

O Capítulo 5 apresenta a metodologia experimental utilizada para a emulação de curto-circuitos no enrolamento do estator do motor de indução em teste, apresentado a bancada de ensaios, aspectos sobre a construção da bobina exploratória externa, definição através de testes laboratoriais dos melhores pontos de alocação da bobina na carcaça do MIT e as abordagens para a realização do diagnóstico de curto-circuito no enrolamento do estator.

No Capítulo 6, são apresentados os principais resultados obtidos no diagnóstico de curto-circuito no enrolamento do estator a partir de três abordagens.

Por fim, no Capítulo 7 são expostas as principais conclusões obtidas e os trabalhos futuros.

1.5 Artigo Publicado

Durante o desenvolvimento deste trabalho, o seguinte artigo foi publicado:

- Vicente, J.; Ferreira, A.; Castoldi, M.; Teixeira, J. P.; Goedel, A. Stator Winding Fault Detection Using External Search Coil and Artificial Neural Network. *MATBUD' 2020 Scientific Technical Conference E mobility, Sustainable Materials and Technologies*, 2020

Capítulo 2

Estado da Arte

2 Estado da Arte

2.1 Introdução

Pelas características construtivas e o baixo custo de aquisição o motor de indução trifásico é o motor com maior aplicabilidade no setor industrial. Contudo, esses motores estão sujeitos a deterioração natural, que pode ser potenciada por exposições a ambientes agressivos e inadequados. Assim, metodologias para diagnósticos e detecção de falhas, inseridos numa estratégia de manutenção preditiva, é de suma importância a fim de reduzir danos aos motores e ao processo produtivo e também custos de reparações e manutenções forçadas (Guedes, 2016).

No decorrer dos últimos anos, pesquisas em âmbito acadêmico e industrial vieram se intensificando com o objetivo de desenvolver métodos que sejam eficientes, rápidos e robustos na identificação de falhas em motores de indução trifásicos.

Nas seções a seguir, são apresentadas algumas técnicas encontradas na literatura para a identificação de falhas em MIT

2.2 Diagnósticos Baseados na Análise de Sinais

Segundo Bellini *et al.* (2008), os motores de indução são sistemas elétricos altamente simétricos, procurando-se na fase de projeto e fabrico um equilíbrio entre fases tal que se obtenha um campo magnético girante. Deste modo, falhas alteram a propriedade simétrica do motor, e as grandezas dos motores, como tensão, corrente, vibração, campos magnéticos, temperatura e entre outras, podem sofrer alterações. As características de funcionamento do motor, podem ser utilizadas em metodologias de identificação de falhas, tentando extrair tais características dessas grandezas.

No trabalho de Filho *et al.* (2014), é realizada uma análise dos sinais de fluxo magnético e de vibração, com o objetivo de identificar frequências características de falhas de curto-circuito do enrolamento do estator. O método foi testado em laboratório utilizando um motor de 3,68 kW, para condições de equilíbrio e desequilíbrio de tensão e variação de binário no eixo. Os resultados obtidos indicam que a metodologia pode ser adaptada e empregada nos programas de manutenção do setor industrial.

Em Drif e Cardoso (2014), é proposta a identificação de falhas no enrolamento do estator utilizando as assinaturas de potências ativa e reativa no domínio da frequência, obtidas dos sinais de corrente e tensão do motor. O método proposto foi implementado em 6 motores de diferentes potências. A técnica se mostrou eficaz na detecção de falhas no enrolamento do

estator, onde as condições de falhas do enrolamento estator pode ser facilmente separadas de outras anormalidades pela combinação das potência ativa e reativa junto com o módulo da tensão do estator.

Em Hegde e Rao (2017) é empregado um método de identificação de falhas no enrolamento do estator baseado na vibração do motor em condições de curto-circuito e saudável. O sinal de vibração é obtido por meio do acelerômetro e processado utilizando a transformada de Fourier. Nota-se que, no espectro da frequência, há o surgimento de componentes de frequências particulares quando ocorre o curto-circuito no enrolamento do estator.

No artigo de Bouzida *et al.* (2014), a tensão induzida numa bobina externa é utilizada para a detecção de 1 a 4 barras quebradas do rotor. No sinal da tensão induzida nesses testes é possível verificar distorções com o aumento da quantidade de barras quebradas. Os sinais obtidos nos testes foram analisados no domínio da frequência. Com o aumento das barras quebradas houve o aparecimento de componentes harmônicas que não estavam presentes no espectro da tensão induzida com o motor saudável.

Em Park *et al.* (2019), é realizada a identificação de barras quebradas no rotor de motores de indução, utilizando o monitoramento do fluxo de dispersão radial no domínio da frequência. Os resultados experimentais apresentaram confiabilidade e sensibilidade na detecção de falhas no rotor.

Em Surya *et al.* (2017) o diagnóstico de falha no enrolamento do estator é implementado com uma bobina observadora interna, por análise de distorção harmônica total em comparação com a condição saudável. O método proposto apresentou boa eficácia na identificação de falha no enrolamento do estator.

Em Eftekhari *et al.* (2013) é proposta uma metodologia para a identificação de falhas de curto-circuito nas espiras do enrolamento do estator de motores de indução, que utiliza a extração de características a partir de imagens infravermelhos. O método proposto possui a capacidade de realizar o diagnóstico de falhas no enrolamento do estator, localização e a taxa de gravidade.

Mohammed, Melecio e Djurović (2019) realiza a identificação de falhas de curto-circuito entre as espiras em estágios incipientes utilizando a assinatura térmica dos enrolamentos obtidas da utilização de sensor *Fiber Bragg Grating* (FBG). Os resultados obtidos, sugerem que o método proposto poderia fornecer um diagnóstico confiável na identificação de curtos-circuitos, incluindo a detecção em estágios incipientes, o grau severidade e a localização da falha.

Em Garcia-Ramirez *et al.* (2014) são utilizadas imagens termográficas para a identificação de defeitos nos rolamentos, barras quebradas no rotor, desequilíbrio de carga e desequilíbrio de tensão. Os resultados obtidos experimentalmente permitem a detecção de falhas em motores de indução, bem como uma análise do motor.

Em Singh, Kumar e Naikan (2016) são propostas duas metodologias baseadas em termografia infravermelha para a detecção de curto-circuitos no enrolamento do estator. Uma técnica utiliza o monitoramento térmico durante o arranque e a outra aplica a técnica de pseudo coloração na imagem infravermelha do motor. As duas metodologias propostas foram eficazes na detecção de curto-circuitos, podendo ser utilizadas para prever o grau de severidade.

2.3 Diagnósticos a partir da modelagem do motor

Algumas técnicas presentes na literatura realizam a identificação de falhas em motores de indução a partir da modelagem do motor ou de modelos de controle.

No trabalho de Sadeghi *et al.* (2019) o motor é modelado sob condição de falha de curto circuito, e a detecção de falhas consiste na aplicação da frequência instantânea ao sinal de corrente. O sinal inicialmente é processado utilizando o método empírico de decomposição, e as funções de modo intrínseco mais relevantes são extraídas e por fim é calculada a frequência instantânea. Conforme a variação da frequência instantânea, é realizada a classificação da condição do motor.

Bouزيد e Champenois (2013), realizam a modelagem do motor de indução para as condições de falha de curto circuito de uma fase, fase-fase e fase-terra. O método de identificação adotado pelos autores consiste na aplicação da teoria das componentes simétricas nos sinais de corrente operando de forma saudável e sob condições de falhas no estator, tendo-se verificado que as componentes de sequências negativa e as componentes homopolares podem ser consideradas como um meio para a identificação de falhas no estator.

Eftekhari *et al.* (2014) realiza a modelagem do motor de indução com falha no estator e propõe a identificação de falhas realizando a análise das correntes trifásicas do motor de indução no espaço 3D. O método consiste em definir uma imagem 3D dos diagramas polares das intensidades das correntes como referência, obtida por meio das correntes com o motor sadio, e compará-la com as obtidas com o motor em condição de falha.

Em Wolkiewicz *et al.* (2016) é apresentada uma metodologia de identificação de falhas no enrolamento do estator para motores de indução que possuem o Controle Direto de Campo (DFOC). O método consiste na análise do desacoplamento de alguns termos do sinal de frequência atual a ser enviado ao sistema de controle e pelos sinais de saídas dos controladores

de corrente. A metodologia apresentou-se robusta em identificar falhas, sendo superior a técnicas como análise da assinatura da corrente do motor.

2.4 Diagnosticos de falhas baseados em Sistemas Inteligentes

Os sistemas inteligentes são capazes de identificar e determinar falhas em MIT sem necessitar do modelo matemático complexo do MIT, apenas efetuando análise de grandezas de referência. Os principais sistemas inteligentes utilizados são as Redes Neurais Artificiais, Logica Fuzzy, Algoritmos Genéticos, Árvores de Decisão, entre outros. Há ainda modelos híbridos, como o sistemas de inferência neuro-fuzzy adaptável (ANFIS, do inglês *Adaptive Neuro Fuzzy Inference System*) (Filippetti *et al.*, 2000).

No trabalho de Palacios *et al.* (2017), são utilizadas as correntes trifásicas do motor de indução no domínio do tempo para a identificação de falhas no enrolamento do estator e a classificação da severidade da falha, utilizando RNA. Os sinais de corrente são pré-processados e em seguida são aplicados em uma Rede Neuronal *Perceptron* Múltiplas Camadas (MLP, do inglês *Multilayer Perceptron*) para a identificação de falhas. Com a identificação de falhas é proposta a implementação do sinal defeituoso em duas soluções para a classificação da severidade, a primeira consiste na implementação de uma RNA MLP e a segunda solução é baseada em sistemas multiagente. As duas abordagens propostas apresentaram boa capacidade de generalização e robustez na identificação e classificação de curtos-circuitos no enrolamento do estator.

Utilizando a Lógica *Fuzzy*, Zidani *et al.* (2003) utiliza as correntes do estator, aplicando o modelo de Concordia no sinal, que em seguida é utilizado como entrada do sistema inteligente, afim de identificar falhas no enrolamento do estator. A metodologia proposta apresentou ser eficaz no diagnóstico de falhas no enrolamento do estator e ainda o grau de severidade.

Bazan *et al.* (2019) realiza a identificação de falhas nos enrolamentos do estator utilizando dois SI, Redes Neurais Artificiais e Árvores de Decisão. O método adotado consiste em aplicar um atraso a um sinal de corrente e compará-lo com outro sinal por meio da informação mútua, de forma a extrair características que servirão como entradas para os sistemas inteligentes. A metodologia sugerida foi eficaz para a identificação de falhas de curto-circuito no enrolamento do estator, mesmo na presença de condições adversas como variação de carga e assimetria da tensão de alimentação.

Em Konar e Chattopadhyay (2015) são empregados RNA, Máquinas de Vetores de Suporte (SVM - do inglês *Support Vector Machines*) e Funções de Base Radial (RBF - do inglês

Radial Basis Function) para o diagnóstico de falhas em MIT, utilizando características extraídas de sinais de vibração não estacionários, a partir de uma combinação de Transformada contínua e Transformada Hilbert com Algoritmo Genético. O método apresentou ser eficiente e consistente para o diagnóstico de falhas em motores de indução.

No artigo de Ghate e Dudul (2010), utilizam-se os sinais da corrente elétrica do motor como entrada para duas topologias de redes neurais, a *Perceptron* Multicamada e mapas auto organizáveis de Kohonen, para realizar a identificação de falhas de curto circuito no enrolamento de estator e excentricidade do rotor. Os resultados obtidos, acima de 96% de exatidão, permitem concluir que o método proposto pode ser utilizado para a identificação de falhas de curto-circuito.

No artigo de Romero-Troncoso *et al.* (2011) é desenvolvido um sistema para a identificação de falhas devido aos rolamentos, desbalanceamento e barras do rotor quebradas utilizando uma análise de entropia de informação junto com lógica *Fuzzy* através da análise da corrente de uma fase do MIT. A metodologia apresenta resultados satisfatórios na detecção de falhas em motores de indução trifásicos de forma automática, implementada em *hardware*.

No trabalho de Santos (2013), o autor utiliza diferentes topologias de redes neurais para a identificação de falhas de curto-circuito no enrolamento de estator e barras quebradas no rotor, utilizando as correntes trifásicas do motor que são processadas empregando transformada *Wavelet*. A metodologia proposta é capaz de identificar e classificar falhas no rotor e no estator de forma objetiva e eficiente.

No artigo de SU e Chong (2007) é utilizado o sinal de vibração do motor processado por uma transformada de Fourier, como entrada para uma Rede Neuronal Artificial para identificar falhas de barras quebradas e excentricidade. Por meio de resultados experimentais é demonstrado que o método proposto é eficaz, sendo robusto e automático para o monitoramento de motores de indução.

No trabalho de Broniera *et al.* (2013) é utilizado as correntes do estator no domínio do tempo como entrada de redes neurais para a detecção de falhas de curto circuito no enrolamento do estator, apresentando exatidões de 94,54%, validando o método proposto.

Capítulo 3

Redes Neurais Artificiais

3 Redes Neurais Artificiais

3.1 Introdução

As Redes Neurais Artificiais (RNA) são modelos computacionais inspirados no sistema nervoso de seres vivos, sendo formado por unidades de processamento, denotadas como neurónios artificiais, que são interligados por meio de pesos sinápticos artificiais (Silva *et al.*, 2017; Haykin, 2005).

Segundo Silva *et al.*, (2017), as principais características das RNA são:

- Capacidade de aprendizagem: Por meio de apresentações de exemplos (amostras de treinamento), os parâmetros internos das RNA são ajustados, tipicamente os pesos sinápticos, adquirindo assim conhecimento.
- Capacidade de generalizar: Após treinadas, as RNA podem generalizar o conhecimento obtido e estimar as possíveis saídas para casos desconhecidos.
- Organização de dados : Com base em informações de um processo, as RNA organizam as informações/dados em agrupamentos com características similares.
- Tolerância a falhas: Na maioria das aplicações, por ser constituída de vários neurónios artificiais e conexões sinápticas, caso a estrutura da RNA seja corrompida, a mesma não se torna inoperante.
- Facilidade de prototipagem: Na maioria dos casos, dependendo da aplicação e da arquitetura, as RNA são de fáceis de implementações em *hardware* ou *software*. Após o treinamento da RNA, os resultados são obtidos por meio de operações matemáticas fundamentais.

O processo na qual as RNA adquirem conhecimento é denominado como treinamento, que consiste em passos ordenados, para a sintonização dos pesos sinápticos e limiares de ativação dos neurónios. O treinamento das RNA pode ser supervisionado e não supervisionado. No treinamento supervisionado há o par entrada-saída, e os parâmetros das redes são ajustados entre a diferença do valor real com o valor gerado pela rede. No treinamento não supervisionado, não estão disponíveis os dados de saída, e a rede é responsável em identificar particularidades entre os dados e identifica-los em clusters semelhantes

3.2 Principais Aplicações

As aplicações de RNA são diversas, segundo Silva *et al.* (2017) são:

- Reconhecimento e classificação de padrões: Associa os padrões de entrada com uma classe previamente definida, como no reconhecimento de imagem, fala, escrita, entre outros.
- Aproximador de função: Consiste em efetuar o mapeamento da relação funcional entre as variáveis de entrada e saída, amplamente utilizado no mapeamento de processos difíceis de serem modelados utilizando as metodologias convencionais.
- Controle de Processos: As utilizadas para realizar identificações de ações de controle, aptos a atenderem requisitos de qualidade, eficiência e segurança. Esta aplicação é utilizada em sistemas de controle de processos industriais, manufatura, robótica, entre outras.
- Agrupamento (*Clustering*): Nesta aplicação, as RNA, realizam a identificação de semelhanças e particularidades entre as amostras de entrada e realiza o agrupamento das amostras com características similares. A mineração de dados e a classificação automática de classes, são exemplos dessa aplicação.
- Previsão/Predição: O objetivo desta aplicação é realizar a predição de valores futuros de um processo utilizando valores passados desse processo. A utilização desta aplicação é ampla, podendo citar aplicações na predição de series temporais, projeções no mercado de ações, entre outros.
- Otimização: São utilizadas para minimizar ou maximizar funções objetivo seguindo as restrições do processo. Utilizado em sistemas com programação dinâmica, otimização combinacional, entre outras.
- Memórias associativas: Nesta aplicação, as RNA são capazes de recuperar padrões corretos mesmo com elementos parciais, incertos ou imprecisos. Amplamente utilizada no processamento de imagens, identificação de caracteres, entre outras.

3.3 Neurónio Artificial

As RNA são compostas de um ou mais neurónios artificiais. O neurónio artificial é uma unidade de processamento de informações, sendo modelos não lineares, que possuem funções de ativação deriváveis (Silva *et al.*, 2017). Na Figura 3.1 é ilustrado o diagrama de um neurónio artificial.




Figura 3.1 - Neurônio artificial, adaptada de (Silva *et al.*, 2017)

Os neurónios artificiais são compostos por (Silva *et al.*, 2017; Suetake, 2012):

- Sinais de entrada $\{x_1, x_2, \dots, x_n\}$: São dados provenientes do meio externo, e são dados a serem analisados de uma determinada aplicação.
- Pesos sinápticos $\{w_1, w_2, \dots, w_n\}$: São valores utilizados para ponderar as variáveis de entrada, representam as conexões sinápticas biológicas.
- Combinador linear (Σ): Realiza o somatório dos sinais de entrada ponderados pelos pesos sinápticos.
- Limiar de Ativação ou *bias* (θ): é responsável por especificar o limite que o resultado do combinado linear possa produzir um valor de disparo para saída do neurónios.
- Potencial de ativação (u): é a diferença entre o resultado do combinador linear e o limiar de ativação, matematicamente é expresso pela Equação (3.1)
- Função de ativação ($g(\cdot)$): Possui como objetivo limitar a saída do neurónio dentre uma faixa de valores ou efetuar o mapeamento não linear.
- Sinal de saída (y): é a resposta gerada pela função de ativação, e representa a saída da RNA (Equação 3.2).

$$u = \sum_{i=1}^n w_i x_i - \theta \quad (3.1)$$

$$y = g(u) \quad (3.2)$$

3.4 Funções de Ativações

As funções de ativações, $g(\cdot)$, definem a saída dos neurónios a partir do potencial de ativação, as principais funções utilizadas em RNA são do tipo linear e sigmóides (Haykin, 2007).

As funções de ativações são divididas em dois grupos importantes, funções parcialmente diferenciáveis e funções totalmente diferenciáveis. As funções parcialmente diferenciáveis são

funções que não possuem as derivadas de primeira ordem, como a função degrau, função bipolar e a rampa simétrica, já as funções totalmente diferenciáveis, são funções que possuem derivada de primeira ordem, para todo o seu domínio, como as funções logística, tangente hiperbólica (T. Hiperbólica), linear e Elliot (Silva *et al.*, 2017).

- Função Logística: retorna valores entre 0 e 1, sendo expressa pela Equação (3.3) e o respectivo gráfico na Figura 3.2.

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (3.3)$$

onde, β é uma constante real, associada à inclinação da função.




Figura 3.2 - Função de ativação logística

- Função Tangente Hiperbólica: retorna valores entre -1 e 1, sendo expressa pela Equação (3.4) e o seu gráfico é apresentado na Figura 3.3

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (3.3)$$




Figura 3.3 - Função de ativação tangente hiperbólica

- Função Elliot: retorna valores entre -1 e 1, expressa pela Equação (3.5) e o respectivo gráfico é exibido na Figura 3.4.

$$g(u) = \frac{u \cdot \beta}{1 + |u \cdot \beta|} \quad (3.5)$$




Figura 3.4 - Função de ativação Elliot

- Função Linear: retorna valores equivalentes ao potencial de ativação, matematicamente é expressa pela Equação (3.6) e o respectivo gráfico é apresentado na Figura 3.5

$$g(u) = u \quad (3.6)$$

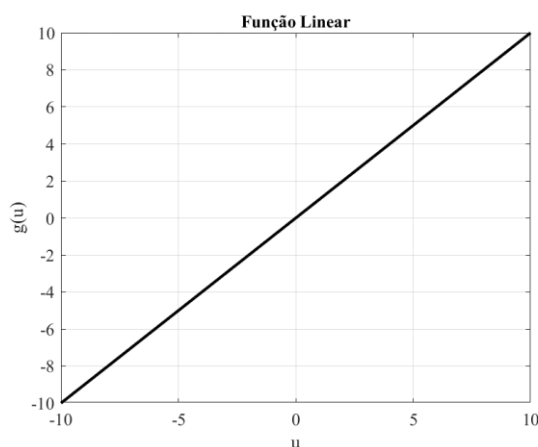


Figura 3.5 - Função de ativação linear

3.5 Arquiteturas de RNA

As RNA são organizadas em camadas, denominadas como camada de entrada, camada escondida e camada de saída. A camada de entrada é responsável por receber informações/dados do meio externo. As camadas escondidas são responsáveis pela maior parte

do processamento de uma RNA, sendo nessa camada a extração de padrões do sistema/processo em análise. A camada de saída apresenta as saídas finais da RNA, resultante do processamento das camadas anteriores (Silva *et al.*, 2017).

A forma como os neurónios de uma RNA estão dispostos e/ou interconectados com outros neurónios, é denominada arquitetura, e está diretamente relacionada com o algoritmo de treinamento a ser utilizado na arquitetura. As principais arquiteturas de RNA são:

- Redes *feedforward* de camada simples: Nessa arquitetura, as RNA são formadas somente pela camada de entrada e de saída. Sendo utilizadas em problemas de classificação simples e de filtros lineares. As principais redes dessa arquitetura é a *Perceptron* e a *Adaline*.
- Redes *feedforward* multicamadas: Está arquitetura é formada pela camada de entrada, uma ou várias camadas escondidas e a camada de saída. Empregadas para aproximação de funções, classificações de padrões, entre outras aplicações. As redes *Perceptron* Multicamadas (MLP, do inglês, *Multi-Layer Perceptron*) e Função de Base Radial (RBF), são exemplos que utilizam essa arquitetura.
- Redes Recorrentes: Nessa arquitetura, as saídas dos neurónios da camada de saída, são utilizados como entradas de feedback para outros neurónios. Utilizada em sistemas variantes no tempo, previsão temporal, entre outras. As redes Hopfield e a *Perceptron* com *feedback*, são exemplos de redes recorrentes.

3.5.1 Redes feedforward Perceptron Multicamadas

As Redes *Perceptron* Multicamadas (MLP, do inglês *Multilayer Perceptron*), ilustrada na Figura 3.6, são organizadas por camadas e possuem pelo menos uma camada escondida. (Suetake, 2012).

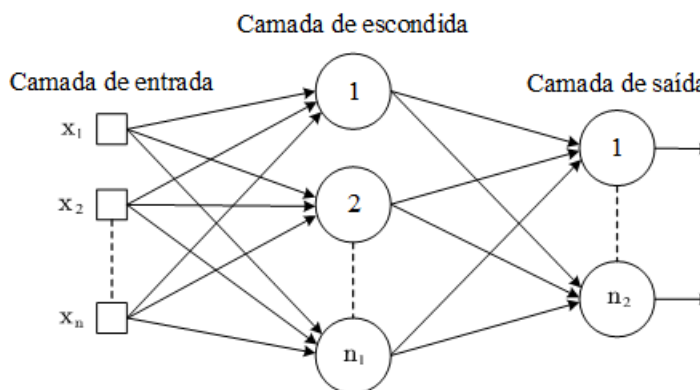


Figura 3.6 - Redes *Perceptron* Multicamadas, adaptado de (Silva *et al.*, 2017)

O treinamento dessa rede, é supervisionado e realizado utilizando o algoritmo *backpropagation* que é baseado no gradiente descendente e requer o uso de funções de ativações deriváveis. Esse algoritmo consiste em duas fases, a *forward* e a *backward*. Na fase *forward*, a propagação dos sinais/dados é realizado da camada de entrada até a camada de saída, os dados $\{x_n\}$ são aplicados na camada de entrada da rede e os resultados são obtidos na camada de saída, sendo comparados com as saídas desejadas, gerando um erro. Na fase *backward*, os parâmetros da RNA são ajustados, com base no erro obtido na última fase (*forward*). O processo é aplicado em iterações sucessivas com o objetivo de minimizar o erro entre a saída da rede e os alvos (Haykin, 2007; Silva *et al.*, 2017). Na Tabela 6.8 é ilustrado as fases do treinamento do algoritmo *backpropagation*.

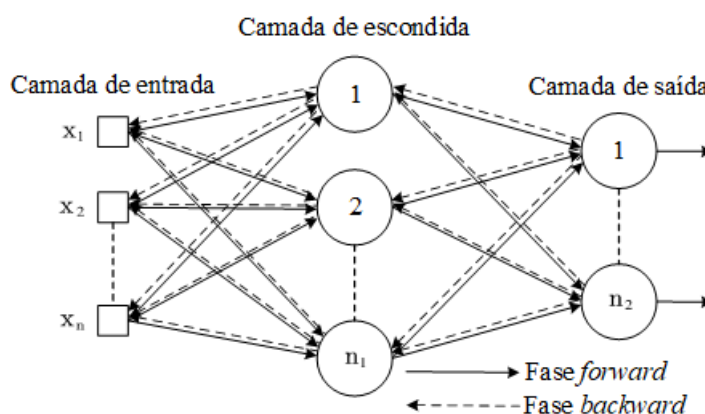


Figura 3.7 - Ilustração das fases do algoritmo *backpropagation*, adaptado de (Silva *et al.*, 2017)

Variações e otimização do algoritmo *backpropagation* surgiram com o objetivo de reduzir custos computacionais, otimizando resultados e mínimos locais. Entre elas, estão o algoritmo *backpropagation* Levenberg-Marquardt (L. Marquardt) (Levenberg, 1944; Marquard, 1963), o algoritmo *backpropagation* Regulação Bayesian (R. Bayesian) (Mackay, 1992) e o *backpropagation* resiliente (Riedmiller; Braun, 1992).

3.6 Validação Cruzada *k-fold*

A validação cruzada é realizada com o objetivo de avaliar a capacidade de generalização de um modelo. Uma técnica de validação cruzada é o *k-fold*, que consiste em dividir o conjunto de amostras em k -conjuntos. Neste trabalho, é utilizado $k-2$ conjuntos para o treinamento das RNA, 1 conjunto é utilizado para validação e 1 conjunto para teste. Após a divisão, o processo de treinamento é realizado k -vezes (k -RNA), até que todas as repartições sejam utilizadas como validação e teste (Haykin, 2007; Silva *et al.*, 2017). Durante o processo de treino, o conjunto de validação é utilizado para realizar a validação do modelo e interrompendo o processo de

treino, evitando um sobre ajuste ao dados de treino. Com a rede treinada, o conjunto de teste é utilizado para avaliação do modelo, já que são dados que não participaram do processo de treino. Na Figura 3.8, é ilustrado o processo de validação cruzada *k-fold*.

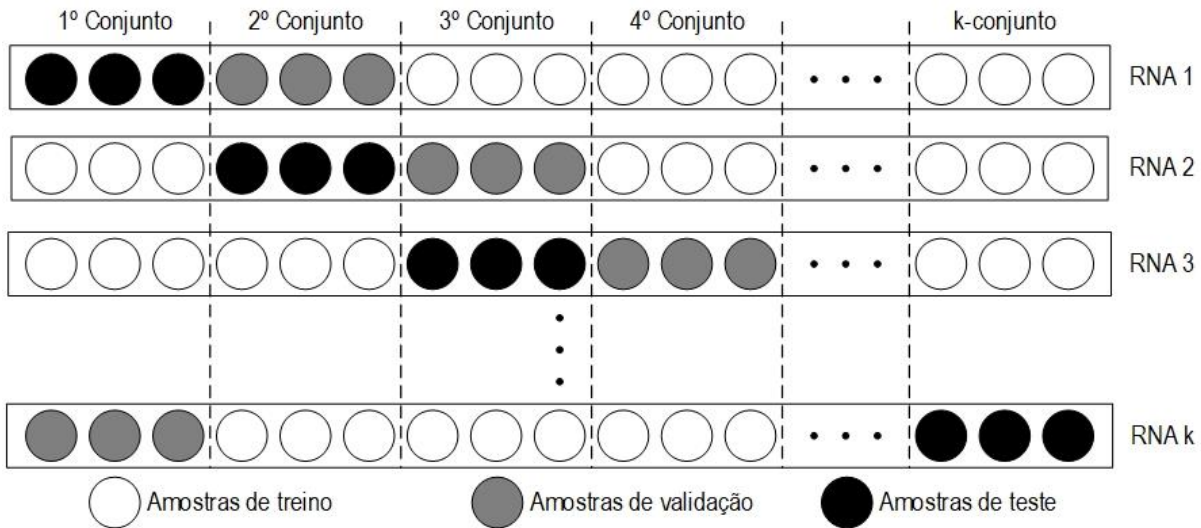


Figura 3.8 - Validação cruzada *k-fold*, adaptado de (Silva *et al.*, 2017)

Capítulo 4

Transformada de Fourier e Janelamento

4 Transformada de Fourier e Janelamento

4.1 Introdução

A transformada de Fourier é uma função que produz uma representação de um sinal, no domínio da frequência, mantendo todas as informações sobre o sinal original e permitindo que características ocultas ou de difícil visualização, sejam evidenciadas.

4.2 Transformada de Fourier

A transformada de Fourier de uma função $x(t)$ é definida pela Equação (4.1)

$$X(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (4.1)$$

onde, $X(\omega)$ é a representação do sinal $x(t)$ no domínio da frequência (ω).

4.3 Transformada Discreta de Fourier

Para sinais discretos, a transformada de Fourier, Equação (4.1), de uma sequência discreta $x(n)$ composta por N amostras de um sinal $x(t)$, é denominada como Transformada de Fourier Discreta (DFT, do inglês *Discrete Fourier Transform*), e sendo expressa pela Equação (4.2) (Oppenheim; Schaffer, 2009; Diniz; Silva; Netto, 2014).

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j(2\pi/N)k \cdot n} \quad (4.2)$$

onde, $X(k)$ é a representação da sequência discreta $x(n)$ no domínio da frequência; N é a quantidade total de amostras; k é um número inteiro, com $k = 0, 1, \dots, N-1$.

4.4 Transformada Rápida de Fourier

Por a complexidade computacional das DFT ser muito elevada, foi desenvolvido a Transformada Rápida de Fourier (FFT, do inglês *Fast Fourier Transform*), que são passos ordenados, que utilizam as propriedades do cálculo da DFT, com menos complexidade computacional. Uma das características da FFT, é o fato da quantidade das amostras (N), ser em potência de 2, como apresentado na Equação (4.3) (Oppenheim; Schaffer, 2009; Diniz; Silva; Netto, 2014).

$$N = 2^n \quad (4.3)$$

onde, n é um número inteiro positivo.

Em situações que o sinal a ser transformado, não atende à Equação (4.3), são inseridos zeros até a potência de 2 subsequente ou desejada.

A resolução de frequência de um sinal é dado pela Equação (4.4).

$$R = \frac{f_a}{N} \quad (4.4)$$

sendo, f_a a frequência de amostragem do sinal e R a resolução de frequência.

4.5 Janelamento

O janelamento de sinais é uma técnica que permite aumentar as características espectrais do sinal e reduzir problemas de descontinuidade nas bordas dos sinais. As principais janelas são de Hanning, Hamming, Blackman e Kaiser.

Na Figura 4.1 é ilustrado a Janela de Hamming, que é definida pela Equação (4.5).

$$w_{\text{ham}}[n] = \left(0.54 + 0.46 \cdot \cos\left(\frac{2\pi n}{N-1}\right) \right), 0 \leq n \leq N-1 \quad (4.5)$$




Figura 4.1 - Janela de Hamming

Capítulo 5

Materiais e Métodos

5 Materiais e Métodos

5.1 Introdução

Neste capítulo apresentam-se as principais técnicas, materiais e equipamentos utilizados na metodologia para a detecção de curto-circuito no enrolamento do estator. Inicialmente, é apresentada a metodologia utilizada para a reprodução de curto-circuito no enrolamento do estator de motores de indução, posteriormente é exposta a bancada de ensaios utilizada, especificando os seus equipamentos e componentes.

Na apresentação da bobina exploratória, é definido como foi realizada a sua construção, a qual baseia-se no trabalho de Ertan e Keysan (2009), tendo sido realizados testes para determinar os principais pontos onde a bobina deve ser colocada na carcaça do motor.

Na apresentação da metodologia proposta, descrevem-se as principais etapas realizadas, como a recolha dos dados, condições de funcionamento do motor e processamento de dados. Os dados são utilizados no domínio do tempo e em duas abordagens no domínio da frequência, uma que utiliza uma gama de pontos da FFT e a outra que utiliza a amplitude dos harmónicos.

5.2 Reprodução de Falhas no Estator

A reprodução de falhas de curto-circuito no enrolamento do estator segue a metodologia proposta em Suetake (2012), também desenvolvida por Broniera (2014).

Os motores de indução utilizados por Suetake (2012) e Broniera (2014), possuem 2 pares de polos e 36 ranhuras no estator, semelhantes ao motor utilizado neste trabalho. As bobinas estão alojadas de forma concêntrica nas ranhuras, como apresentado na Figura 5.1.

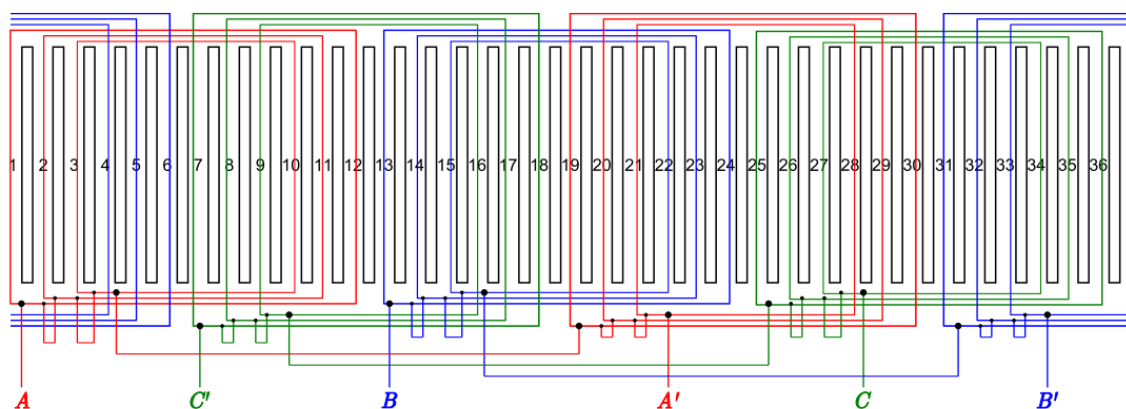


Figura 5.1 - Disposição das bobinas ao longo das ranhuras do estator (Suetake, 2012).

Na Figura 5.1, é possível notar que os possíveis curtos-circuitos que podem ocorrer são entre: espiras de uma bobina, bobinas de uma mesma fase, bobinas de fases diferentes e entre as bobinas das três fases. Devido à disposição das bobinas, os curtos-circuitos que apresentam maiores possibilidades de ocorrências são entre espiras de uma mesma bobina ou entre bobinas de uma mesma fase.

Os enrolamentos de cada fase do MIT são representados por seis bobinas, que estão alocadas em seis ranhuras, seguindo o esquema da Figura 5.1. Em cada enrolamento foram projetadas derivações, as quais localizam-se nos pontos intermediários e nas extremidades das bobinas situadas em cada ranhura, conforme exemplificado na Figura 5.2. As derivações tem a funcionalidade de permitir emular diferentes níveis de curto-circuito por fase, e/ou a emulação de curto-circuito entre fases.




Figura 5.2 - Derivações do enrolamento do estator para realização de ensaios de curto-circuito (Suetake, 2012)

Na Figura 5.3, é ilustrado como as tomadas adicionais no enrolamento do estator foram adicionadas. As modificações nos enrolamentos dos MIT foram realizadas por empresas especializadas em manutenção de MIT.




Figura 5.3 - Imagem ilustrativa das tomadas de derivação, adaptado de (Guedes, 2016)

As modificações foram realizadas de modo a respeitar as medidas originais e a classe de isolamento do MIT. Os enrolamentos do estator são compostos por 306 espiras por fase, nas

quais os enrolamentos foram modificados e criadas derivações permitindo realizar ensaios de curto circuito de 1%, 3%, 5%, 10%, 15% e 20%, que representam, respectivamente 3, 9, 15, 31 e 62 das espiras curto-circuitadas. Para realizar o controle correto do percentual de curto-circuito, as derivações foram alocadas em uma caixa de ligação, como mostra a Figura 5.4.



Figura 5.4 - Disposição das tomadas na caixa de ligação

A simulação das falhas de curto circuito em uma mesma fase, são realizadas conectando a tomada de 0% com a tomada do percentual de curto-circuito requerido. Entre a conexão das tomadas está presente uma chave de controle, acionada manualmente durante as coletas de dados. Com a utilização desta chave, o motor pode ser acionado sem condição de curto circuito e também ser exposto a condição de falha somente no tempo necessário para a coleta de dados.

5.3 Bancada Experimental

A bancada de ensaio utilizada é similar à proposta por Goedel (2007), sendo utilizada em pesquisas relacionadas com a estimação de parâmetros de motores de indução ou em estudos de detecção de falhas, como nas dissertações de (Bazan, 2016; Guedes, 2016; Vitor, 2015) assim como nos artigos de (Bazan *et al.*, 2017, 2019; Graciola *et al.*, 2016; Guedes *et al.*, 2018; Palacios *et al.*, 2017; Santos *et al.*, 2014) e entre outros estudos correlatos. A bancada de ensaios utilizada é do Laboratório de Sistemas Inteligentes (LSI), da Universidade Tecnológica Federal do Paraná, campus Cornélio Procópio.

A bancada foi projetada para o monitoramento de grandezas elétricas e mecânicas de motores de indução trifásicos, tais como tensão, corrente, vibração, binário e velocidade, sendo possível realizar a variação do binário de carga, variações nos níveis de tensão de alimentação

e a simulação de falhas como: curtos-circuitos no enrolamento do estator, barras quebradas no rotor e nos rolamentos.

A bancada de ensaios é formada por um painel de acionamento, um motor de indução, um gerador de corrente contínua (Gerador DC) de excitação separada, sendo necessário uma fonte de corrente contínua (Fonte DC), um transdutor de binário (Torquímetro), e por uma carga resistiva fixa. O esquema da bancada é ilustrado na Figura 5.5, e na Figura 5.6 é apresentada a bancada de ensaios utilizada.

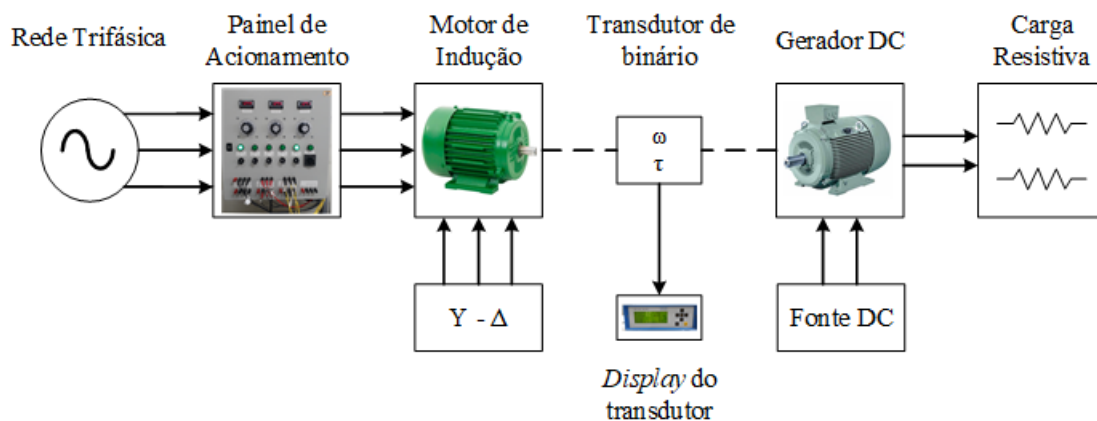


Figura 5.5 - Esquema da bancada de ensaios




Figura 5.6 - Bancada de ensaios

No painel de acionamento, estão presentes três autotransformadores monofásicos, utilizados para o ajuste da tensão de alimentação do MIT, uma chave seletora para acionamento do MIT de forma direta, em estrela (Y), delta (Δ), ou ainda ser acionado em estrela e depois alterado para delta. Os autotransformadores permitem a simulação de desequilíbrio na tensão de alimentação do motor em ensaio.

O motor de indução utilizado na bancada é alterado conforme o objetivo de pesquisa. Neste trabalho foi utilizado o motor adaptado por Broniera (2014), para a emulação de falhas

de curto-circuito no enrolamento do estator. Os parâmetros e características do MIT utilizado são apresentados na Tabela 5.1. A Tabela 5.2 contém as principais características do gerador de corrente contínua.

Tabela 5.1 - Parâmetros e características dos MIT utilizado

Item	Parâmetros/Características
Fabricante	WEG
Potência [cv/W]	1 / 735
Alimentação	3 ϕ
Tensão de Alimentação (Δ/Y) [V]	220/380
Corrente de Alimentação (Δ/Y) [A]	3,02/1,75
Número de polos	4
Frequência [Hz]	60
Velocidade Nominal [rpm]	1730
I_p/I_n	6,6
Fator de serviço	1,15
Fator de potência	0,81
Rendimento [%]	80,5

Tabela 5.2 - Parâmetros e características do gerador CC

Item	Parâmetros/Características
Fabricante	WEG
Potência [kW]	2
Excitação	Independente
Tensão de armadura [V]	250
Corrente de armadura [A]	11,2
Tensão de campo [V]	250
Corrente de campo [A]	0,51
Velocidade Nominal [RPM]	2000

O eixo do motor de indução está acoplado com o eixo do gerador DC através de um transdutor de binário de dupla faixa de atuação com sensor de velocidade integrado, da marca Kistler, modelo 4503A50W, possibilitando a leitura de sinais analógicos e digitais de binário e velocidade até 50 Nm e 7000 rpm, respectivamente.

O controle de binário no eixo do gerador DC, ocorre com a variação da tensão no enrolamento de campo ou com a carga imposta ao gerador, conectada no enrolamento de armadura. Como a carga resistiva conectada no enrolamento de armadura do gerador é fixa, a forma de alterar o binário no eixo do gerador é feita por meio de alterações na tensão de campo, realizadas pela fonte DC.

5.4 Bobina Exploratória Externa

A construção da bobina exploratória foi baseada no trabalho realizado por Ertan e Keysan (2009). Os autores realizaram testes utilizando 3 bobinas exploratórias com núcleos na horizontal, vertical e em forma de U, como ilustrado na Figura 5.7, com o objetivo de determinar qual o formato de núcleo que maximiza a tensão induzida.




Figura 5.7 - Configurações de núcleos, adaptado de (Ertan; Keysan, 2009)

Nos testes realizados por Ertan e Keysan (2009) a bobina exploratória com núcleo em formato de U, apresentou níveis de tensão induzida superiores. A bobina utilizada foi implementada com 120 espiras, comparativamente às outras configurações. Daqui, a bobina exploratória utilizada neste trabalho possui o núcleo em formato de U, seguindo os resultados apresentados por Ertan e Keysan (2009). Para construir a bobina exploratória foi utilizado o núcleo de ferro laminado de um transformador de pequeno porte, tendo-se adaptado aquele ao formato desejado.

A bobina exploratória foi projetada para 240 espiras, tendo-se estimado 25 metros de fio AWG 23. A bobina final contém 291 espiras, tendo sido produzida manualmente. De salientar que, de acordo com a lei de Faraday, o número de espiras afeta diretamente a amplitude da tensão induzida, sendo esta maior quanto maior for o número de espiras. Na Figura 5.8, apresenta-se a bobina exploratória construída.



Figura 5.8 - Bobina exploratória

5.4.1 Determinação do Ponto de Alocação da Bobina

No artigo de Ertan e Keysan (2009), os autores realizaram testes para determinar os melhores pontos de alocação das bobinas exploratórias nas carcaças dos motores de indução. A parte central dos motores apresentaram melhores resultados.

Com o intuito de validar os resultados apresentados pelos autores, foram realizados testes em seis posições diferentes na caraça de motor de indução, como ilustrado pela Figura 5.9, para o motor sadio, operando em vazio e com carga nominal.

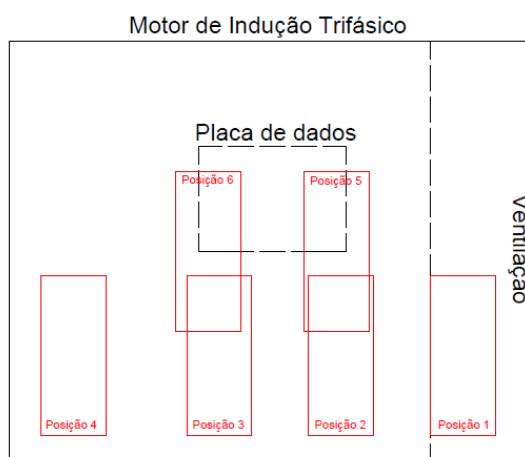


Figura 5.9 - Posições da bobina no MIT

Nas subseções a seguir, são apresentados os sinais das tensões induzida para as seis posições especificadas e com o motor operando a vazio e com carga nominal.

5.4.1.1 Motor operando em vazio

Nas Figura 5.10 a Figura 5.15, são apresentados os pontos de alocação da bobina exploratória no motor e respetivo sinal da tensão induzida, em seis posições distintas, numeradas de 1 a 6.




Figura 5.10 - Bobina na posição 1, MIT em vazio




Figura 5.11 - Bobina na posição 2, MIT em vazio




Figura 5.12 - Bobina na posição 3, MIT em vazio




Figura 5.13 - Bobina na posição 4, MIT em vazio




Figura 5.14 - Bobina na posição 5, MIT em vazio

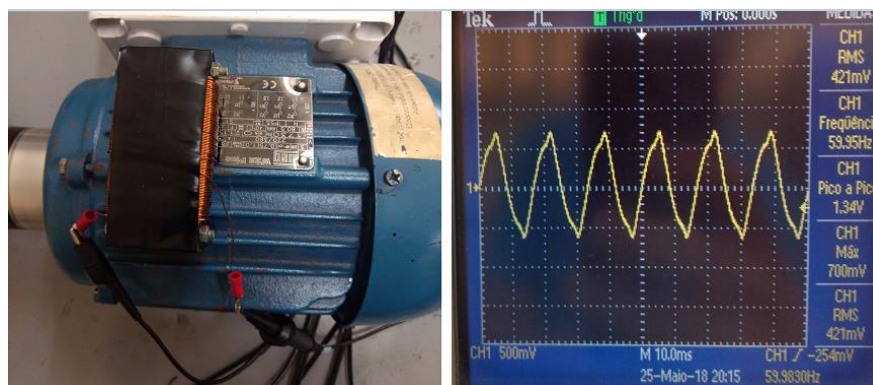


Figura 5.15 - Bobina na posição 6, MIT em vazio

Nota-se, que quando a bobina é colocada nas posições 2 e 3, Figura 5.11 e Figura 5.12 respectivamente, o sinal da tensão induzida não apresenta distorções e ruídos, assemelhando-se a um sinal sinusoidal.

Quando alocada nas extremidades do motor, posições 1 e 4, Figura 5.10 e Figura 5.13 respectivamente, os sinais apresentaram distorções e ruídos. Na posição 1, o sinal é praticamente 1/3 quando comparado com o sinal obtido na posição 3. Na posição 4, o sinal apresenta pequenas distorções nas cristas da onda.

Nas posições 5 e 6, Figura 5.14 e Figura 5.15 respectivamente, a bobina está com uma parte alocada na chapa de características que altera o fluxo de dispersão, afetando o fluxo concatenado na bobina e, desse modo, havendo distorções no sinal da tensão induzida, assemelha-se a uma onda triangular.

5.4.1.2 Motor operando com carga nominal

Nas Figura 5.16 a Figura 5.21, são apresentados os resultados dos testes com o posicionamento da bobina exploratória e respectivos sinais da tensão induzida para o motor operando com carga nominal, em seis posições distintas.




Figura 5.16 - Bobina na posição 1, MIT com carga nominal




Figura 5.17 - Bobina na posição 2, MIT com carga nominal




Figura 5.18 - Bobina na posição 3, MIT com carga nominal




Figura 5.19 - Bobina na posição 4, MIT com carga nominal




Figura 5.20 - Bobina na posição 5, MIT com carga nominal




Figura 5.21 - Bobina na posição 6, MIT com carga nominal

Com o motor operando com carga, as posições 2 e 3, Figura 5.17 e Figura 5.18, respectivamente, apresentaram sinais da tensão induzida com poucos ruídos e nem apresentam distorções nos sinais. Novamente, nestas posições, os sinais se assemelham com uma onda sinusoidal.

Nas extremidades do motor, posição 1 e 4, Figura 5.16 e Figura 5.19, os sinais da tensão induzida apresentaram distorções e ruídos. É possível notar que também houve uma redução significativa na amplitude dos sinais quando comparado com os sinais das posições 2 e 3.

Quando alocadas nas posições 5 e 6, Figuras Figura 5.20 e Figura 5.21 respectivamente, como já discutido, os sinais da tensão induzida são alterados devido à chapa de características do motor e, novamente, os sinais se assemelham com uma onda triangular.

Atendendo aos resultados dos testes e da análise efetuada, conclui-se que a parte central do motor, posições 2 e 3, apresentaram os melhores resultados para a aquisição dos sinais que se pretendem, sendo utilizadas para a aquisição dos dados.

5.5 Metodologia para a Detecção de Falhas

A metodologia para a detecção de falhas de curto-circuito nos enrolamentos do estator de motores de indução é apresentada esquematicamente na Figura 5.22.

O motor utilizado neste trabalho, foi testado em condições saudáveis e submetido a condições de curtos-circuitos de 1%, 3%, 5% e 10% entre as espiras de uma fase, com variações no binário de 0,5 Nm até 4,5 Nm com passos de 0,5 Nm para cada condição de funcionamento.

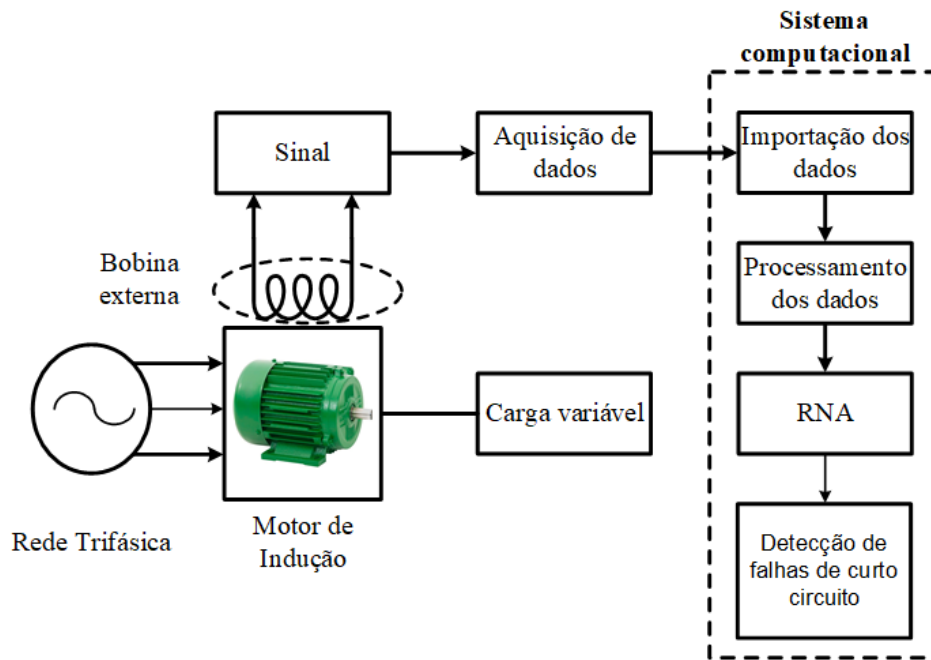


Figura 5.22 - Esquema metodológico

A bobina exploratória, foi colocada na parte central do motor, posições 2 e 3 acima identificadas nas Figura 5.11 e Figura 5.12, respectivamente, e os sinais da tensão induzida foram coletados conforme indicado na Tabela 5.3, através de um osciloscópio modelo TBS 1072b da Tektronix, com frequência de amostragem de 25kHz, resolução 8 *bits* e com 100 milissegundos de coleta, o que representa 6 ciclos por amostras com 2500 pontos, para cada condição de funcionamento. Posteriormente os dados foram importados para ambiente MATLAB®, onde são analisados nos domínios do tempo e da frequência.

Tabela 5.3 - Status de funcionamento do motor e variação do binário na coleta dos dados experimentais

Status do Motor	Binário Carga (Nm)	Número de aquisições
Saudável	0,5 – 4,5	9
C.C. 1%	0,5 – 4,5	9
C.C. 3%	0,5 – 4,5	9
C.C. 5%	0,5 – 4,5	9
C.C. 10%	0,5 – 4,5	9

Durante análises preliminares dos dados, verificou-se que os sinais da tensão induzida sofriam alterações nas amplitudes quando o binário era alterado. Atendendo a que a metodologia adotada tem como objetivo identificar distorções nos sinais, a abordagem no domínio do tempo considera os dados normalizados numa escala de -1 a 1, para retirar as variações de amplitude em relação à variação do binário. Nas abordagens realizadas no domínio da frequência foi adotada outra metodologia, sendo inserido o binário nos dados de entrada da

rede. Nas subseções a seguir descreve-se com mais algum detalhe o processamento dos dados para cada abordagem.

5.5.1 Domínio do tempo

O processamento dos dados no domínio tempo é ilustrado na Figura 5.23, e consiste na obtenção do maior valor absoluto da amostra. Em seguida, é realizada a normalização da amostra e, posteriormente, os dados são utilizados como entrada das RNA.




Figura 5.23 - Processamento dos dados para o domínio do tempo

5.5.2 Domínio da Frequência - Banda de Frequência

O processamento de dados realizado nesta abordagem é mostrado na Figura 5.24, que consiste em realizar a FFT para cada amostra, e em seguida é efetuada a coleta de uma gama de pontos da FFT de cada amostra, correspondente a uma banda de frequência, posteriormente é inserido o valor do binário da amostra, obtendo-se assim o conjunto de dados utilizados como entrada das RNA.




Figura 5.24 - Processamento dos dados para a abordagem no domínio da frequência

5.5.3 Domínio da Frequência - Amplitude Harmónicos

Na Figura 5.25 é exibido o processamento para esta abordagem. Inicialmente, é realizado a FFT de cada amostra, posteriormente é realizada a interpolação dos dados, e sendo executado a coleta de harmónicos, em seguida é realizado a inserção do binário e depois os dados são utilizados nas RNA




Figura 5.25 - Processamento dos dados para a abordagem no domínio da frequência

Para obter harmónicos próximos dos reais utilizou-se a interpolação nas FFT realizada, uma vez que a resolução de frequência não podem indicar com exatidão suficiente os harmónicos a serem utilizados.

Capítulo 6

Resultados e Discussões

6 Resultados e Discussões

6.1 Introdução

Neste capítulo são apresentados os principais resultados obtidos de 3 abordagens diferentes, para a identificação e a classificação do grau de severidade de curto-circuito no enrolamento do estator de motores de indução trifásicos, utilizando redes neuronais artificiais, sendo uma abordagem no domínio do tempo e duas no domínio da frequência.

O banco de dados utilizado é formado por cinco classes de operação do motor de indução, sendo elas, saudável, curto-circuito de 1%, 3%, 5% e 10% entre as espiras de uma fase. Para cada classe, o binário foi alterado de 12,5% a 112,5% (0,5 Nm a 4,5N.m) do binário nominal do motor utilizado.

Durante os ensaios realizados na secção 5.4.1, foi constatado que a amplitude da tensão na bobina exploratória tende a diminuir quando o binário é aumentado, ou vice-versa. Essas variações podem gerar dificuldades na generalização do problema por parte das RNA, por isso, faz-se necessário a utilização de metodologias de normalização, para retirar a variação na amplitude da tensão induzida, como empregado na abordagem no domínio do tempo, ou a indicação do valor do binário como um novo atributo, junto com as amostras a serem analisadas pelas RNA, como aplicado nas abordagens no domínio da frequência.

Para as 3 abordagens propostas é utilizada a arquitetura de RNA *perceptron* Multicamada Esta arquitetura é amplamente utilizada na detecção de falhas em máquinas elétricas, como em (Barzegaran; Mazloomzadeh; Mohammed, 2013; Bazan *et al.*, 2017, 2019; Broniera *et al.*, 2013; Ghate; Dudul, 2010; Palácios *et al.*, 2016; Schmitt *et al.*, 2015; Zarei; Tajeddini; Karimi, 2014). Para determinar as melhores topologias da arquitetura utilizada para cada abordagem, são realizados diversos testes com diferentes topologias. Os resultados das topologias selecionadas, são apresentados utilizando a matriz de confusão e a exatidão da topologia.

As RNA simuladas, foram implementadas em ambiente MATLAB®

6.2 Organização dos dados e cálculo de exatidão

O banco de dados foi dividido em 3 grupos, treinamento, validação e teste. O grupo de treinamento é formado por 80% das amostras do banco de dados, enquanto os grupos de validação e teste, contém 10% das amostras do banco de dados, cada. A divisão das amostras entre os grupos supracitados, é realizada de modo que, cada grupo fique o mais equilibrado

possível entre as classes, por exemplo, quando é utilizado 270 amostras, 10% corresponde a 27 amostras, assim é utilizado 3 classes com 5 amostras e 2 classes com 6 amostras.

O treinamento da arquitetura RNA *perceptron* Multicamadas é supervisionado. Desde modo, para cada amostra de entrada há o respectivo padrão de saída desejado da amostra. Assim, as cinco classes devem ser codificadas. A codificação adotada nesse trabalho, consiste em ter um neurónio específico para cada classe, dessa maneira, os padrões de saída desejado e as codificações para as cinco classes, são exibidas na Tabela 6.1.

Tabela 6.1 - Padrão de saída das redes neuronais

Status do motor	Saídas desejadas
Saudável	$[0\ 0\ 0\ 0\ 1]^T$
1%	$[0\ 0\ 0\ 1\ 0]^T$
3%	$[0\ 0\ 1\ 0\ 0]^T$
5%	$[0\ 1\ 0\ 0\ 0]^T$
10%	$[1\ 0\ 0\ 0\ 0]^T$

A falha de curto-circuito de 1%, por ser em estágio incipiente, causam pequenas variações nas condições de funcionamento do motor, onde os sinais se assemelham com os do motor saudável, como apresentado na Figura 6.1, por isso, para cada abordagem, as topologias que apresentarem as melhores exatidões utilizando as 5 classes, serão novamente simuladas, utilizando somente as amostras das classes saudáveis e de curtos-circuitos de 3%, 5% e 10%. Os novos padrões de saída e codificação são mostrados na Tabela 6.2.




Figura 6.1 - Sinal da tensão induzida com o motor saudável e com curto-circuito de 1%, binário de 0,5 Nm

Tabela 6.2 - Padrão de saída das redes neuronais sem as amostras de curto-circuito de 1%

Status do motor	Saídas desejadas
Saudável	$[0\ 0\ 0\ 1]^T$
3%	$[0\ 0\ 1\ 0]^T$
5%	$[0\ 1\ 0\ 0]^T$
10%	$[1\ 0\ 0\ 0]^T$

A exatidão (Exa.) das RNA é calculada pela quantidade de acertos do conjunto de teste, dividida pelo total de amostras do grupo, matematicamente, o cálculo da exatidão é dada pela Equação (6.1)

$$Exatidão = \frac{NA}{NT} \quad (6.1)$$

Onde, NA corresponde ao número de acerto no conjunto de teste e NT é o número de amostras do conjunto de teste.

Para a validação cruzada k -fold, a exatidão pode ser calculada como a somatória dos acertos dos k -testes, dividido pelo número total de amostras do banco de dados, como apresentado na Equação (6.2).

$$Exatidão = \frac{\sum_{i=1}^k NA(i)}{N} \quad (6.2)$$

Onde, N é a quantidade total de amostras utilizadas.

Os principais resultados são apresentados utilizando a matriz de confusão, que são matrizes que contém informações das condições reais e as predições realizadas por um sistema de classificação. Além de exibir os dados/amostras que foram classificados corretamente e incorretamente, pode também ser utilizada para identificar se o modelo proposto está favorecendo alguma classe. Neste trabalho, as linhas das matrizes de confusão são amostras reais e as classes prevista estão nas colunas. Na última coluna, é dada a exatidão de cada classe junto com a exatidão geral na última linha dessa coluna. Ainda, na última linha é apresentado as taxa de ocorrência (Occ.) na classificação de uma classe pelas RNA.

6.3 Análise no Domínio do Tempo

As amostras utilizadas nesta abordagem, são normalizadas pelos respectivos valores absolutos, assumindo valores de $[-1, 1]$. Esta metodologia, remove as variações de amplitude nos sinais

da tensão induzida causado pela variação do binário, que poderiam influenciar na generalização das RNA.

Inicialmente foram realizados testes com diferentes topologias de RNA que utilizavam como entrada as 45 amostras com 2500 pontos cada. As exatidões obtidas nesses testes não foram satisfatórios, apresentando exatidões abaixo dos 50% e um alto custo computacional para o treinamento das diferentes topologias de RNA. A baixa quantidade de amostra por classe, 9, afetou as exatidões das topologias testadas, uma vez que, o espaço amostral é baixo, as redes apresentaram dificuldade em generalizar o problema proposto. Com o objetivo de aumentar a quantidade de amostras por classe e condição de binário, cada amostra que possuía 6 ciclos, foi dividida em 6 amostras com 1 ciclo, contendo 416 pontos cada. Esta divisão, possibilitou o aumento do banco de dados para 270 amostras, sendo 54 amostras por classe.

Novas simulações foram realizadas, utilizando o novo banco de dados, sendo dividido em 80% das amostras para treinamento, 10% para validação e 10% para teste. A exatidão dessas simulações é analisada, com o objetivo de definir as melhores topologias a serem aplicadas ao problema. Na definição das topologias é determinado o número de neurónios na Camada Escondida (CE), funções de ativação na camada escondida e Camada de Saída (CS) e o algoritmo de treino. As topologias testadas e as respectivas exatidões são apresentados na Tabela 6.3.

Tabela 6.3 - Resultados preliminares no domínio do tempo

Top.	Alg. Treino	# Neurónio CE	Função CE	Função CS	Exatidão [%]
1	R. Bayesian	45	T. Hiperbólica	Elliot	66,7
2	R. Bayesian	30	Elliot	Elliot	70,4
3	R. Bayesian	25	T. Hiperbólica	Linear	74,0
4	R. Bayesian	25	Elliot	Elliot	85,2
5	R. Bayesian	25	Logística	Elliot	88,9
6	L. Marquardt	25	T. Hiperbólica	Linear	77,8
7	L. Marquardt	50	T. Hiperbólica	Elliot	85,2
8	L. Marquardt	35	T. Hiperbólica	Elliot	85,2
9	L. Marquardt	50	Elliot	Elliot	81,5
10	L. Marquardt	25	Elliot	Elliot	81,5

Dentre as topologias testadas que utilizam o algoritmo de treino Regulação de Bayesian (R. Bayesian), o teste 5 apresentou a melhor exatidão, já os testes 7 e 8 apresentaram as melhores precisões para o algoritmo Levenberg-Marquardt (L. Marquardt). As topologias das redes neuronais dos testes 5 e 8 foram selecionadas para a execução da validação cruzada *k-fold*, por apresentarem as melhores exatidões, sendo denotadas de topologia 5 e topologia 8,

respectivamente. A topologia do teste 7 é semelhante a topologia do teste 8, o que as difere, é a quantidade de neurónios na camada escondida, por conter um número superior de neurónios, requer o ajuste de mais pesos sinápticos, assim, aumentando o custo computacional, por isso a topologia do teste 7 não foi selecionada.

Para as estruturas selecionadas, topologia 5 e topologia 8, foi efetuado a validação cruzada *k-fold*, com 10 conjuntos ($k=10$). As exatidões obtidas foram de 68,9% para a topologia 5 e 68,5% para a topologia 8. Nas Tabela 6.4 e Tabela 6.5 são apresentados os resultados da classificação da topologia 5 e topologia 8, respectivamente.

Tabela 6.4 - Matriz de confusão para a topologia 5

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	31	22	1	0	0	57,4
	C.C. 1%	19	25	10	0	0	46,3
	C.C. 3%	6	7	33	8	0	61,1
	C.C. 5%	1	1	9	43	0	79,6
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	54,4	45,5	62,3	84,3	100,0	68,9

Na matriz de confusão dos resultados da topologia 5, Tabela 6.4, observa-se que as amostras com do motor saudável foram frequentemente confundidas com as amostras de curto-circuito de 1% e vice-versa. Uma das razões dessa confusão é que os curto-circuito de 1% é uma falha em estágio incipiente e causa pequenas variações nas condições de funcionamento dos motores. Já as condições de curtos-circuitos de 10% foram todas identificadas, e nenhuma outra classe de curto-circuito foi classificada como curto-circuito 10%.

Tabela 6.5 - Matriz de confusão para a topologia 8

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	38	15	0	1	0	70,4
	C.C. 1%	16	29	8	1	0	53,7
	C.C. 3%	11	8	20	15	0	37,0
	C.C. 5%	1	2	7	44	0	81,5
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	57,6	53,7	57,1	72,1	100,0	68,5

As classificações realizadas pela topologia 8, Tabela 6.5, apresentaram situações semelhantes aos apresentados pela topologia 5, novamente, para as amostras saudáveis e de

curto-circuito de 1%, as redes neuronais apresentaram dificuldades em identificá-los, confundindo-se entre essas classes. Na identificação das amostras de curto-circuito de 3% a RNA não apresentou uma boa generalização, apresentando exatidão abaixo de 40% e as amostras classificadas incorretamente ficaram dispersas entre as condições de saudáveis, curto-circuito de 1% e 5%, enquanto que as amostras de curtos-circuitos de 10% foram classificadas 100%, e em nenhum caso as redes indicaram esse nível de severidade para outra condição de funcionamento do motor.

A exatidão abaixo dos 70%, das topologias implementadas está na confusão gerada pelas amostras saudáveis e de curto-circuito de 1%, por isso, novas simulações são realizadas, com as mesmas topologias das RNA, mas sem as amostras de curto-circuito 1% no banco de dados.

As novas exatidões obtidas foram de 81,5% para a topologia 5 e 86,1% para a topologia 8. Os resultados das classificações dessas topologias são apresentados nas matrizes de confusão da Tabela 6.6 e Tabela 6.7, respectivamente.

Tabela 6.6 - Matriz de confusão topologia 5 sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	49	5	0	0	90,7
	C.C. 3%	9	33	12	0	61,1
	C.C. 5%	1	13	40	0	74,1
	C.C. 10%	0	0	0	54	100,0
	Occ. [%]	83,1	64,7	76,9	100,0	81,5

Tabela 6.7 - Matriz de confusão topologia 8 sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	51	3	0	0	94,4
	C.C. 3%	9	36	9	0	66,7
	C.C. 5%	3	6	45	0	83,3
	C.C. 10%	0	0	0	54	100,0
	Occ. [%]	81,0	80,0	83,3	100,0	86,1

Com a exclusão das amostras de 1%, nota-se que a rede da topologia 5, apresentou melhores resultados na identificação dos dados saudáveis 90,7%, antes 57,4%. A rede ainda apresentou algumas confusões entre as classificações das amostras de curto-circuito de 3% e

5%, o que afetou a exatidão da topologia. As amostras de curto-circuito de 10% foram todas identificadas e em nenhum caso outra classe foi indicada como curto-circuito de 10%.

Semelhante as classificações da topologia 5, com a retirada das amostras de curto-circuito de 1%, a topologia 8 apresentou melhora no resultado da identificação do motor saudável, 94,4% antes 70,4%, enquanto para as amostras de curto-circuito de 3% e 5% houve alguma confusão na classificação, e obteve 100% de exatidão na identificação das amostras de 10%.

Na Figura 6.2 é apresentado a exatidão das topologia 5 e topologia 8 com e sem a utilização das amostras de 1% no banco de dados.




Figura 6.2 - Exatidão da topologia 5 e topologia 8 com e sem as amostras de C.C. 1%

Na Figura 6.3 é realizado o comparativo das exatidões obtidas para cada classe utilizando as amostras de curto-circuito de 1% e sem a utilização da mesma, para as duas topologias de RNA testadas. Com a retirada dos dados de curto-circuito de 1%, houve um aumento expressivo na identificação das amostras do motor saudável, enquanto que em todos os testes realizados, os curto-circuito de 10% apresentaram exatidão de 100%.

De modo geral, com a retirada dos dados de curto-circuito de 1%, houve a melhoria na exatidão das classes remanescentes, a única ocasião onde houve um decréscimo na exatidão, foi na identificação das classes de curto-circuito de 5% da topologia 5.




Figura 6.3 - Exatidão das classes com e sem as amostras de C.C. 1%

6.4 Análise no Domínio da Frequência - Banda de Frequências

Nesta abordagem, é realizado a FFT de cada amostra com comprimento N de 8192 (2^{13}) pontos e janelamento de Hamming. Por meio da FFT obtida para cada amostra, são selecionados os primeiros 400 pontos por amostra, que corresponde à banda de frequências de 0 a aproximadamente 1220 Hz e engloba os harmônicos até à 20ª ordem (1200 Hz). Na Figura 6.4 é exemplificado a abordagem adotada, em azul os pontos a serem utilizados como entrada das RNA e em vermelho os pontos não utilizados.




Figura 6.4 - Exemplo da abordagem adotada

Na Figura 6.5 é ilustrado o sinal da Figura 6.4 contendo frequência de 180Hz a 2100Hz.




Figura 6.5 - Exemplo da abordagem adotada para frequência de 180Hz a 2100Hz

Nesta análise, a variação da amplitude da tensão induzida devido a alteração do binário, foi mantida, mas o valor do binário da amostra foi inserido adicionalmente como um novo atributo na entrada da RNA. A normalização, semelhante à realizada no domínio do tempo, poderia ser aplicada nesta abordagem, não sendo adotada devido à opção de trabalhar com o sinal no domínio da frequência.

De modo similar à abordagem no domínio do tempo, foram realizados testes iniciais utilizando as 45 amostras, novamente os resultados obtidos não foram satisfatórios, devido ao baixo espaço amostral, e assim, as amostras foram divididas outra vez em outras 6 amostras, sendo 1 ciclo da onda sinusoidal para cada nova amostra, aumentando o espaço amostral para 270 amostras.

Com o novo espaço amostral, foram realizados testes para identificar as melhores topologias de RNA a serem utilizadas nessa abordagem. Para cada amostra é realizada a FFT, posteriormente é extraídos os primeiros 400 pontos (até aos 1200 Hz) e inserido o valor do binário da amostra, para criar a entrada das RNA.

Na Tabela 6.8 é apresentado as exatidões obtidas das diferentes topologias testadas, utilizando a validação cruzada *k-fold*, com 10 conjuntos ($k=10$).

Tabela 6.8 - Resultados no domínio da frequência banda de frequência

Top.	Alg. Treino	# Neurónio CE	Função CE	Função CS	Exatidão [%]
1	R. Bayesian	25	Elliot	Elliot	70,0
2	R. Bayesian	15	Elliot	Elliot	70,7
3	R. Bayesian	7	Elliot	Elliot	80,0
4	R. Bayesian	25	T. Hiperbólica	Elliot	72,6
5	R. Bayesian	15	T. Hiperbólica	Elliot	70,7
6	R. Bayesian	7	T. Hiperbólica	Elliot	82,2
7	R. Bayesian	25	Logística	Elliot	72,6
8	R. Bayesian	15	Logística	Elliot	73,7
9	R. Bayesian	7	Logística	Elliot	79,3
10	R. Bayesian	25	T. Hiperbólica	Linear	65,6
11	R. Bayesian	15	T. Hiperbólica	Linear	71,1
12	R. Bayesian	7	T. Hiperbólica	Linear	65,9
13	R. Bayesian	25	Elliot	Logística	38,9
14	R. Bayesian	15	Elliot	Logística	39,3
15	R. Bayesian	7	Elliot	Logística	36,7
16	R. Bayesian	25	Elliot	T. Hiperbólica	74,4
17	R. Bayesian	15	Elliot	T. Hiperbólica	72,6
18	R. Bayesian	7	Elliot	T. Hiperbólica	81,1
19	R. Bayesian	25	Linear	Elliot	73,7
20	R. Bayesian	15	Linear	Elliot	74,8
21	R. Bayesian	7	Linear	Elliot	74,8
22	L. Marquardt	50	Elliot	Elliot	65,2
23	L. Marquardt	35	Elliot	Elliot	68,9
24	L. Marquardt	25	Elliot	Elliot	71,9
25	L. Marquardt	50	T. Hiperbólica	Elliot	70,0
26	L. Marquardt	35	T. Hiperbólica	Elliot	65,2
27	L. Marquardt	25	T. Hiperbólica	Elliot	67,8
28	L. Marquardt	50	Logística	Elliot	65,9
29	L. Marquardt	35	Logística	Elliot	70,7
30	L. Marquardt	25	Logística	Elliot	67,8
31	L. Marquardt	50	T. Hiperbólica	Linear	54,8
32	L. Marquardt	35	T. Hiperbólica	Linear	64,4
33	L. Marquardt	25	T. Hiperbólica	Linear	63,0
34	L. Marquardt	50	Elliot	Logística	37,0
35	L. Marquardt	35	Elliot	Logística	38,5
36	L. Marquardt	25	Elliot	Logística	38,9
37	L. Marquardt	50	Elliot	T. Hiperbólica	61,9
38	L. Marquardt	35	Elliot	T. Hiperbólica	70,0
39	L. Marquardt	25	Elliot	T. Hiperbólica	71,9
40	L. Marquardt	50	Linear	Elliot	73,3
41	L. Marquardt	35	Linear	Elliot	73,3
42	L. Marquardt	25	Linear	Elliot	67,4

Dentre as topologias que utilizam o algoritmo de treinamento R. Bayesian as topologias 6 e 18 foram as que apresentaram as melhores exatidões, por isso, os resultados das classificações dessas topologias são apresentados nas Tabela 6.9 e Tabela 6.10, respectivamente. Já para as topologias que utilizam o algoritmo L. Marquardt, as melhores

topologias foram as 24 e 41 e os seus resultados estão apresentados nas Tabela 6.11 e Tabela 6.12, respectivamente.

Tabela 6.9 - Matriz de confusão para a topologia 6

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	49	5	0	0	0	90,7
	C.C. 1%	6	39	7	2	0	72,2
	C.C. 3%	2	7	36	9	0	66,7
	C.C. 5%	0	3	7	44	0	81,5
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	86,0	72,2	72,0	80,0	100,0	82,2

Os resultados obtidos pela topologia do teste 6, são apresentados na Tabela 6.9. Para está topologia, as amostras saudáveis apresentaram uma precisão acima de 90%, enquanto para as amostras de curto-circuito de 10% todas as amostras foram classificadas corretamente e nenhuma amostra de outra classe foi indicada com este grau de severidade.

Tabela 6.10 - Matriz de confusão para a topologia 18

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	43	10	1	0	0	79,6
	C.C. 1%	7	38	7	2	0	70,4
	C.C. 3%	2	9	39	4	0	72,2
	C.C. 5%	0	1	8	45	0	83,3
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	82,7	65,5	70,9	88,2	100,0	81,1

Na topologia do teste 18, Tabela 6.10, a RNA apresentou uma maior confusão na identificação das amostras saudáveis e com curto-circuito de 1%, quando comparada com os resultados da topologia do teste 6. Novamente as amostras de curto-circuito de 10% foram todas classificadas corretamente e em nenhum caso a rede indicou uma amostra de outra severidade com esse grau.

Tabela 6.11 - Matriz de confusão para a topologia 24

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	45	8	1	0	0	83,3
	C.C. 1%	12	29	8	5	0	53,7
	C.C. 3%	6	10	27	11	0	50,0
	C.C. 5%	1	4	10	39	0	72,2
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	70,3	56,9	58,7	70,9	100,0	71,9

Para a topologia do teste 24, Tabela 6.11, as amostras de curto-circuito de 1% e 3% foram responsáveis pelas exatidões mais baixas 53,7% e 50,0% respectivamente. A RNA apresentou confusões na classificação das amostras saudáveis e de curto-circuito de 1%, enquanto que as amostras do curto-circuito de 10% foram todas classificadas corretamente.

Tabela 6.12 - Matriz de confusão para a topologia 41

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	41	10	1	2	0	75,9
	C.C. 1%	8	34	9	3	0	63,0
	C.C. 3%	3	10	30	11	0	55,6
	C.C. 5%	1	3	11	39	0	72,2
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	77,4	59,6	58,8	70,9	100,0	73,3

Nos resultados da topologia 41, Tabela 6.12, de modo semelhante aos resultados da topologia anterior as amostras de 1% e 3% são responsáveis pelas exatidões mais baixas. A maioria das amostras errôneas são classificadas em classes vizinhas. A exatidão na identificação das classes saudáveis foi de 75,9%. As falhas de curto circuito de 10% foram todas classificadas corretamente.

Nesta abordagem, os curto-circuitos de 1% e 3% foram responsáveis pelas principais fontes de classificação errada, as RNA testadas indicavam esses graus de severidade, sendo outra condição de funcionamento.

Devido à semelhança dos sinais de curto-circuito de 1% com as amostras do motor saudável, essas amostras foram retirados do banco de dados e as topologias apresentadas anteriormente foram simuladas novamente.

As novas exatidões são de 85,6%, 84,7%, 78,7% e 81,0% para as topologias 6, 18, 24 e 41, respectivamente. E os resultados obtidos são exibidos nas Tabela 6.13, Tabela 6.14, Tabela 6.15 e Tabela 6.16, respectivamente

Tabela 6.13 - Matriz de confusão para a topologia 6 sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	50	4	0	0	92,6
	C.C. 3%	6	38	10	0	70,4
	C.C. 5%	0	11	43	0	79,6
	C.C. 10%	0	0	0	54	100,0
Occ. [%]		89,3	71,7	81,1	100,0	85,6

Na classificação da topologia 6, Tabela 6.13, há uma confusão na identificação das amostras saudáveis com as amostras de curto-circuito de 3%, mas a identificação do motor saudável é acima de 90%. Houve um total de 21 amostras (9,7% das amostras totais) que a RNA classificou como curto-circuito de 5% enquanto era curto-circuito de 3% e vice-versa. Enquanto que as amostras de curto-circuito de 10% foram todas classificadas corretamente e nenhuma amostra de outra classe foi classificada como curto-circuito de 10%.

Tabela 6.14 - Matriz de confusão para a topologia 18 sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	50	4	0	0	92,6
	C.C. 3%	7	36	11	0	66,7
	C.C. 5%	1	10	43	0	79,6
	C.C. 10%	0	0	0	54	100,0
Occ. [%]		86,2	72,0	79,6	100,0	84,7

De modo semelhante aos resultados da topologia 6, houve uma confusão de 11 amostras na classificação de motor saudável e de curto-circuito de 3%, enquanto a confusão entre os curtos-circuitos de 3% e 5% foram responsáveis por classificar erroneamente 21 amostras (9,7% das amostras totais). As amostras de curto-circuito de 10% novamente foram classificadas corretamente e nenhuma outra classe foi indicada com esse grau de severidade.

Tabela 6.15 - Matriz de confusão para a topologia 24 sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	50	4	0	0	92,6
	C.C. 3%	7	29	18	0	53,7
	C.C. 5%	2	15	37	0	68,5
	C.C. 10%	0	0	0	54	100,0
Occ. [%]		84,7	60,4	67,3	100,0	78,7

Para a topologia 24, Tabela 6.15, a classificação das amostras saudáveis apresentou uma precisão acima de 90%. A maior taxa de amostras classificadas erroneamente pela RNA utilizada, ocorreu na confusão em identificar as falhas de curto-circuito de 3% e 5%, apresentando exatidões de 53,7% e 68,5%, respectivamente. Para a classe de curto-circuito de 10%, nenhuma amostra de outra classe foi indicada nesta classe e todas as amostras dessa classe foram classificadas corretamente.

Tabela 6.16 - Matriz de confusão para a topologia 41 sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	49	3	2	0	90,7
	C.C. 3%	3	33	18	0	61,1
	C.C. 5%	1	14	39	0	72,2
	C.C. 10%	0	0	0	54	100,0
Occ. [%]		92,5	66,0	66,1	100,0	81,0

A classificação das topologia 41, Tabela 6.16, para as amostras saudáveis apresentou uma precisão acima de 90%. Novamente, a maior taxa de amostras classificadas erroneamente pela RNA, está associada na identificação das amostras de curto-circuito de 3% e 5%, a confusão entre essas classes é de 32 amostras, que representam 14,8% de imprecisão global da RNA. As amostras de curto-circuito de 10% apresentaram exatidão de 100% e nenhuma outra classe foi indicada com esse nível de curto-circuito.

Na **Erro! Fonte de referência não encontrada.**, é apresentado as exatidões obtidas das diferentes topologias analisadas, utilizando as amostras de curto-circuito de 1% no banco de dados e sem a sua utilização. De modo geral, as exatidões melhoraram, mas não apresentaram ganhos expressivos, principalmente, pela confusão na identificação das classes de curto-circuito 3% e 5%, afetando a exatidão das topologias de RNA testada.




Figura 6.6 - Comparativo das exatidões das diferentes topologias testadas com e sem as amostras de C. C. 1%

Nas Figura 6.7 são apresentadas as exatidões dentre as classes para as topologias 6 e 18, que utilizavam o algoritmo de treino R. Bayesian, com e sem a utilização das amostras de curto-circuito de 1%.




Figura 6.7 - Comparativo na exatidão das classes das duas topologias que utilizam R. Bayesian com e sem a utilização das amostras de C. C. 1%

Nas Figura 6.8 são apresentadas as exatidões dentre as classes para as topologias que utilizavam o algoritmo de treino L. Marquardt, com a utilização dos dados de curto-circuito de 1% e sem.

Com a retirada dos dados de curto-circuito de 1%, as RNA analisadas apresentaram melhoras expressivas na detecção do motor em condições saudáveis, como apresentado nos gráficos das Figura 6.7 e Figura 6.8, já as demais classes as suas exatidões ficaram próximas com as obtidas utilizando as amostras de curto-circuito de 1%. Para todas topologias analisadas o metodo se mostrou eficiente em identificar os curto-circuito de 10%, obtendo 100% de

exatidão em todas as análises e em nenhum caso outra classe foi indicado como sendo essa severidade.




Figura 6.8 - Comparativo da exatidão das classes das duas topologias que utilizam L. Marquardt com e sem a utilização das amostras de C. C. 1%

6.5 Análise no Domínio da Frequência Amplitudes Harmônicas

Nesta abordagem, é realizado a FFT de cada amostra, com comprimento de 8192 (2^{13}) pontos e janelamento de Hamming, posteriormente é efetuado em cada amostra a interpolação para aumentar a resolução na frequência. A interpolação é realizada com o objetivo de obter as amplitudes para as frequências próximas das ordens harmônica desejadas, uma vez que, a resolução de frequência da FFT, é de 3,05 Hz, não fornece as ordem harmônicas corretamente, por exemplo, para a ordem harmônica fundamental, 60Hz, a frequência mais próxima a essa sem a interpolação é 61 Hz.

Para ser utilizado como entrada das RNA, foram coletadas as amplitude dos harmônicos de 1ª a 17ª ordem, da FFT interpolada. Na Figura 6.9 é exemplificado a abordagem adotada, em azul, é a FFT interpolado, enquanto que em vermelho são as amplitudes a serem coletadas.

Nesta análise, é inserido o valor do binário da correspondente amostra como um atributo a ser analisado pelas RNA, junto com as amplitudes harmônicas selecionadas. Esta metodologia é a mesma aplicada na abordagem do domínio da frequência que utilizava uma banda de frequências.

Nesta abordagem, não foram realizados testes utilizando as 45 amostras com 6 ciclos cada, uma vez que, nas abordagens anteriores não se obteve bons resultados por conta do espaço

amostral ser baixo, desse modo, as amostras que possuíam 6 ciclos, foram divididas em amostras com 1 ciclo, aumentando o espaço amostral para 270 amostras.




Figura 6.9 - Exemplo da coletado dos dados

Foram realizadas diversas simulações com diferentes topologias, com o objetivo de determinar as melhores topologias a serem utilizadas nessa abordagem. Inicialmente é realizado a FFT, em seguida é efetuado a interpolação e extraídos as amplitudes das harmônicas requeridas e por fim é inserido o valor de binário da amostra. Os dados foram divididos em 3 grupos, treinamento, validação e teste, que contêm 80%, 10% e 10% das amostras respectivamente.

As exatidões obtidas utilizando as diferentes topologias e a validação cruzada *k-fold*, com 10 conjuntos, é apresentada na Tabela 6.17. Dentre as topologias que utilizam o algoritmo de treino R. Bayesian as topologias 2, 5, 8 e 16 são as topologias que apresetaram as melhores exatidões, 86,7% cada, sendo analisados os resultados das topologias 2 e 5, apresentados nas Tabela 6.18 e Tabela 6.19, respectivamente. Para as topologias que utilizam o algoritmo L. Marquardt, as que apresentaram as melhores exatidões foram a 30 e 33, obtendo exatidões de 84,1% cada, seus resultados são apresentados nas Tabela 6.20 e Tabela 6.21, respectivamente.

Pela matriz de confusão da topologia 2, Tabela 6.18, há uma precisão acima de 90% na identificação do motor operando de forma saudável, dentre as amostras classificadas incorretamente, 4 foram cassificadas como curto-circuito de 1% e 1 como curto-circuito de 3%. A maior taxa de imprecisão foi na identificação das amostras de curto-circuito de 1% e 3%. Entretanto houve outra confusão na classificação entre as classes de 3% e 5%. A classe de curto-circuito de 10% obteve 100% de acerto e nenhuma outra classe foi indicada com esse grau de severidade.

Tabela 6.17 - Resultados no domínio da frequência: ordem harmônicas

Top.	Alg. Treino	# Neurónio CE	Função CE	Função CS	Precisão [%]
1	R. Bayesian	25	Elliot	Elliot	83,7
2	R. Bayesian	15	Elliot	Elliot	86,7
3	R. Bayesian	7	Elliot	Elliot	85,6
4	R. Bayesian	25	T. Hiperbólica	Elliot	85,2
5	R. Bayesian	15	T. Hiperbólica	Elliot	86,7
6	R. Bayesian	7	T. Hiperbólica	Elliot	84,1
7	R. Bayesian	25	Logística	Elliot	84,1
8	R. Bayesian	15	Logística	Elliot	86,7
9	R. Bayesian	7	Logística	Elliot	84,8
10	R. Bayesian	25	T. Hiperbólica	Linear	68,9
11	R. Bayesian	15	T. Hiperbólica	Linear	75,2
12	R. Bayesian	7	T. Hiperbólica	Linear	81,5
13	R. Bayesian	25	Elliot	Logística	40,0
14	R. Bayesian	15	Elliot	Logística	35,9
15	R. Bayesian	7	Elliot	Logística	35,2
16	R. Bayesian	25	Elliot	T. Hiperbólica	86,7
17	R. Bayesian	15	Elliot	T. Hiperbólica	84,8
18	R. Bayesian	7	Elliot	T. Hiperbólica	83,7
19	R. Bayesian	25	Linear	Elliot	74,4
20	R. Bayesian	15	Linear	Elliot	72,2
21	R. Bayesian	7	Linear	Elliot	73,7
22	L. Marquardt	35	Elliot	Elliot	79,3
23	L. Marquardt	21	Elliot	Elliot	78,2
24	L. Marquardt	7	Elliot	Elliot	81,9
25	L. Marquardt	35	T. Hiperbólica	Elliot	81,1
26	L. Marquardt	21	T. Hiperbólica	Elliot	80,0
27	L. Marquardt	7	T. Hiperbólica	Elliot	82,6
28	L. Marquardt	35	Logística	Elliot	81,5
29	L. Marquardt	21	Logística	Elliot	81,1
30	L. Marquardt	7	Logística	Elliot	84,1
31	L. Marquardt	35	T. Hiperbólica	Linear	74,4
32	L. Marquardt	21	T. Hiperbólica	Linear	79,6
33	L. Marquardt	7	T. Hiperbólica	Linear	84,1
34	L. Marquardt	35	Elliot	Logística	42,6
35	L. Marquardt	21	Elliot	Logística	42,2
36	L. Marquardt	7	Elliot	Logística	36,7
37	L. Marquardt	35	Elliot	T. Hiperbólica	70,7
38	L. Marquardt	21	Elliot	T. Hiperbólica	76,3
39	L. Marquardt	7	Elliot	T. Hiperbólica	80,4
40	L. Marquardt	35	Linear	Elliot	74,4
41	L. Marquardt	21	Linear	Elliot	74,4
42	L. Marquardt	7	Linear	Elliot	73,0

Tabela 6.18 - Matriz de confusão dos resultados da topologia 2

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	49	4	1	0	0	90,7
	C.C. 1%	5	40	9	0	0	74,1
	C.C. 3%	0	10	41	3	0	75,9
	C.C. 5%	0	0	4	50	0	92,6
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	90,7	74,1	74,5	94,3	100,0	86,7

Tabela 6.19 - Matriz de confusão dos resultados da topologia 5

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	47	7	0	0	0	87,0
	C.C. 1%	5	43	5	1	0	79,6
	C.C. 3%	0	9	41	4	0	75,9
	C.C. 5%	0	0	5	49	0	90,7
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	90,4	72,9	80,4	90,7	100,0	86,7

Nos resultados da topologia 5, Tabela 6.19, novamente há confusões entre a identificação das classes, exceto para o curto-circuito de 10% que possui exatidão de 100%. A detecção do motor saudável é próxima de 90%, afetada pelas confusões geradas com as amostras de curto-circuito de 1%.

Tabela 6.20 - Matriz de confusão dos resultados da topologia 30

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	49	2	2	1	0	90,7
	C.C. 1%	7	35	10	1	0	66,0
	C.C. 3%	1	8	38	8	0	69,1
	C.C. 5%	0	1	2	51	0	94,4
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	86,0	76,1	73,1	83,6	100,0	84,1

Para a topologia 30, Tabela 6.20, a detecção do motor operando de forma saudável, foi de 90,7%. Na identificação das amostras de curto-circuito de 1% e 3%, foram ambas confundidas

com as classes adjacentes, afetando as suas exatidões. As amostras com curto-circuito de 10% foram todas identificadas e não houve a ocorrência de nenhuma outra classe.

Tabela 6.21 - Matriz de confusão dos resultados da topologia 33

		Classe prevista					Exa. [%]
		Saudável	C.C. 1%	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	47	6	1	0	0	87,0
	C.C. 1%	6	37	11	0	0	68,5
	C.C. 3%	0	7	41	6	0	75,9
	C.C. 5%	0	0	6	48	0	88,9
	C.C. 10%	0	0	0	0	54	100,0
	Occ. [%]	88,7	74,0	69,5	88,9	100,0	84,1

Para a topologia 33, Tabela 6.21, a taxa de exatidão para o motor saudável foi de 87,0%, enquanto que as amostras de curto-circuito de 1% teve 17 amostras classificadas erroneamente nas classes adjacentes. Para a detecção de curto-circuito de 10% a rede apresentou 100% de exatidão e não classificou nenhuma classe com esse nível de severidade.

Devido à semelhança das amostras de curto-circuito de 1%, com as amostras saudáveis, as mesmas foram retiradas do banco de dados e as topologias 2, 5, 30 e 33 foram novamente simuladas, obtendo exatidões de 94,4%, 95,4%, 92,6% e 91,2%, e os respectivos resultados são expostos nas Tabela 6.22, Tabela 6.23, Tabela 6.24 e Tabela 6.25.

Tabela 6.22 - Matriz de confusão para a topologia 2, sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	54	0	0	0	100,0
	C.C. 3%	1	47	6	0	87,0
	C.C. 5%	0	5	49	0	90,7
	C.C. 10%	0	0	0	54	100,0
	Occ. [%]	98,2	90,4	89,1	100,0	94,4

Com a retirada das amostras curto-circuito de 1%, os resultados da topologia 2, Tabela 6.22, obteve 100% de exatidão na classificação das amostras saudáveis e de curto-circuito de 10%. Entretanto na classificação das amostras de curto-circuito de 3% e 5% a rede classificou erroneamente 11 amostras entre essas classes.

Os resultados da topologia 5, Tabela 6.23, apresentaram 98% de exatidão na classificação das amostras saudáveis e 100% na classificação das amostras de curto-circuito de

10%. E novamente, as principais classes classificadas incorretamente fora as de curto-circuito de 3% e 5%.

Tabela 6.23 - Matriz de confusão para a topologia 5, sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	53	1	0	0	98,1
	C.C. 3%	0	49	5	0	90,7
	C.C. 5%	0	4	50	0	92,6
	C.C. 10%	0	0	0	54	100
Occ. [%]		100	90,7	90,9	100	95,4

Tabela 6.24 - Matriz de confusão para a topologia 30, sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	51	2	1	0	94,4
	C.C. 3%	0	42	12	0	77,8
	C.C. 5%	0	1	53	0	98,1
	C.C. 10%	0	0	0	54	100,0
Occ. [%]		100,0	93,3	80,3	100,0	92,6

Para a topologia 30, Tabela 6.24, apresentou exatidão de 94,4% para as amostras saudáveis. As principais classificações errôneas foram na identificação da amostra de curto-circuito 3% com o curto-circuito de 5%, já as classes de 10% foram 100% classificadas corretamente.

Tabela 6.25 - Matriz de confusão para a topologia 33, sem as amostras de curto-circuito de 1%

		Classe prevista				Exa. [%]
		Saudável	C.C. 3%	C.C. 5%	C.C. 10%	
Classe real	Saudável	52	2	0	0	96,3
	C.C. 3%	1	45	8	0	83,3
	C.C. 5%	0	8	46	0	85,2
	C.C. 10%	0	0	0	54	100,0
Occ. [%]		98,1	81,8	85,2	100,0	91,2

Para a topologia 33, os resultados apresentados na Tabela 6.25, apresentaram exatidão acima de 96% para as amostras saudáveis e 100% para as amostras de curto-circuito de 10%. Novamente a RNA classificou amostras de curto-circuito de 3% como sendo curto-circuito de 5% e vice-versa.

Na Figura 6.10 é apresentado as exatidões das diferentes topologias analisadas nessa abordagem, onde os dados de curto-circuitos a 1% foram ou não utilizados. Com a retirada das amostras as exatidões foram acima de 91% e no melhor caso, topologia 5, a exatidão foi de 95,4%.

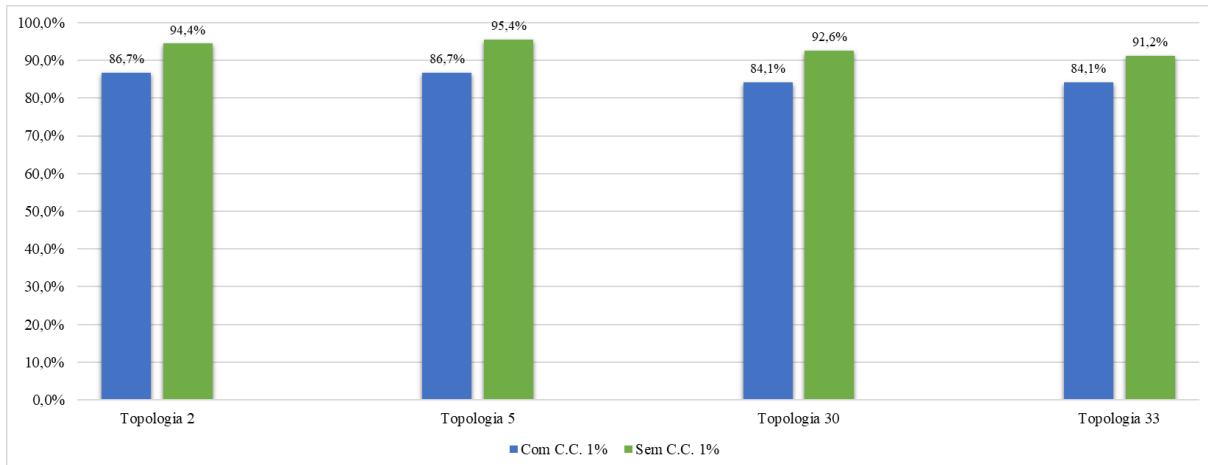


Figura 6.10 - Exatidão das diferentes topologias analisadas, com e sem as amostras de curto-circuito de 1%

Na Figura 6.11 é apresentado a exatidão por classe das topologias que utilizam o algoritmo de treino R. Bayesian.




Figura 6.11 - Comparativo da exatidão das classes das duas topologias que utilizam R. Bayesian com e sem a utilização das amostras de C. C. 1%

Na Figura 6.12 é apresentado a exatidão por classe das topologias que utilizam o algoritmo de treino L. Marquardt.

De modo geral, para as 4 topologias analisadas, a classificação das classes saudáveis apresentaram melhoras na exatidão, aproximadamente acima de 95%, quando os dados de curto-circuito 1% foram retirados do banco de dados. Para as amostras de curto-circuito de 3%

e 5%, houveram topologias que as exatidões apresentaram melhoras e em topologias que a exatidão diminuiu, isso deve-se as confusões gerada pelas RNA na classificação dessas classes. As amostras de curto-circuito de 10% apresentaram 100% de precisão, independente da utilização ou não das amostras de curto-circuito de 1%.




Figura 6.12 - Comparativo da exatidão das classes das duas topologias que utilizam L. Marquardt com e sem amostras de C. C. 1%

6.6 Discussão dos Resultados

Pelos resultados apresentados, a abordagem 3, que utiliza as amplitudes das ordens harmônicas da FFT, apresentou as melhores exatidões quando utilizava ou não as amostras de curto-circuito de 1%. Os melhores resultados das abordagens 1 e 2, foram obtidos quando retirados as amostras de curto-circuito de 1%, com 86% de exatidão cada, já a abordagem 3 apresentou resultado superior aos obtidos nas outras abordagens, 87% de exatidão, mesmo utilizando os dados de curto-circuito de 1% e com a retirada dessas amostras chegou-se 95% de exatidão.

Com a retirada dos dados de curto-circuito de 1%, a identificação do motor operando de forma saudável foi acima de 90%, independente da abordagem.

A metodologia proposta apresentou 100% de exatida na classificação das amostras de curto-circuito de 10%, independente da abordagem ou da utilização dos dados de curto-circuito de 1% e a ocorrência dessa classe foi de 100%, indicando que nenhuma classe foi indicada com esse nível de curto-circuito.

A taxa de exatidão levando em consideração a 3ª abordagem, com a topologia 5, foi entre 87% e 95%, e na Tabela 6.26 é realizado o comparativo entre trabalhos que utilizam sistemas inteligentes na identificação de falhas de curto-circuito no enrolamento do estator.

Tabela 6.26 - Comparativo entre os resultados desse trabalho e trabalhos recentes no diagnóstico de curtos circuitos no enrolamento do estator

Referência	Palácios <i>et al.</i> (2016)	Bazan <i>et al.</i> (2019)	Ballal <i>et al.</i> (2007)	Este estudo
Motor [kW]	0,75	0,75 e 1,48	0,37 (monofásico)	0,75
Dados de Entrada	Corrente	Corrente	Corrente, Velocidade, Temp. enrolamento Temp. rolamento e ruído	Tensão induzida
Preprocessamento	DT/PCA	DT/DMI	DF/FFT	Amplitude Harmónica
Classificador	RNA	RNA e AD	ANFIS	RNA
Nível de falha	3%, 5% e 10%	1%, 3%, 5% e 10%	Até 8 espiras	1%, 3%, 5% e 10%
Variação de binário	Sim	Sim	Sim	Sim
Exatidão	~ 90%	83% - 97%	94% - 97%	87%-95%

Os melhores resultados obtidos neste trabalho estiveram próximos aos trabalhos apresentados na Tabela 6.26, mostrando que se obtiveram resultados ao nível do estado da arte e a 2 pontos percentuais dos melhores resultados.

Capítulo 7

Conclusão

7 Conclusão

Neste trabalho foi apresentada uma metodologia de diagnóstico de falhas de curto-circuito no enrolamento do estator, que consiste na análise nos domínios do tempo e da frequência do sinal de tensão induzida em uma bobina exploratória externa por meio de RNA. Os resultados apresentados utilizam dados reais, obtidos experimentalmente com o motor operando em condições saudáveis e com diferentes níveis de curto-circuitos no enrolamento do estator, além de variações do binário, simulando condições de funcionamento presentes em ambiente industrial.

A bobina exploratória externa foi construída baseada na literatura e por meio de testes laboratoriais foram testados os melhores pontos de alocação na carcaça do motor de indução, tendo-se verificado que estes são na parte central. Nessa parte do motor, os sinais da tensão induzida apresentam um nível de ruído inferior ao obtido noutras posições e a forma de onda é, aproximadamente, sinusoidal. Durante estes testes, foi observado que a amplitude da tensão induzida é influenciada pelo binário desenvolvido pelo motor. Para binários elevados, a amplitude da tensão induzida sofreu redução e vice-versa. Daqui, no processamento dos dados foi necessária a adoção de metodologias de normalização e também da inclusão do binário como atributos a serem analisados pelas RNA, já que essas variações poderiam influenciar nos resultados.

O diagnóstico e a detecção de falhas ocorre a partir da análise de RNA dos sinais em três abordagens distintas. Na primeira abordagem os dados são utilizados no domínio do tempo, sem a utilização de nenhuma ferramenta de processamento, somente recorrendo a uma normalização das amplitudes. Na segunda abordagem os dados são utilizados no domínio da frequência, recorrendo a uma gama de pontos da FFT correspondente às frequências de 0 a 1200 Hz, enquanto na terceira abordagem, os dados também são utilizados no domínio da frequência, mas recorrendo-se às amplitudes dos harmônicos da FFT de cada amostra.

Para cada abordagem foram realizados diferentes testes com variações na topologia das RNA do tipo MLP, tendo sido analisados os melhores casos para cada abordagem. Da análise dos resultados, obteve-se 69% de exatidão para a primeira abordagem, 82% de exatidão para a segunda abordagem e 87% para a terceira abordagem.

As três metodologias, nas suas diferentes abordagens, apresentaram problemas na identificação das amostras saudáveis, quando no banco de dados estava presente as amostras de curto-circuito de 1%. Esse grau de severidade de curto-circuito é uma falha em estágio

incipiente, e as condições de funcionamento do motor aproximam-se muito das condições de funcionamento do motor operando de forma saudável, induzindo as RNA a classificar essa falha como saudável ou indicar amostras saudáveis como curto-circuito de 1%, por isso as topologia analisadas nas três abordagens foram novamente executadas com o banco de dados composto por amostras saudáveis e de curtos-circuitos maiores que 3%.

Com a retirada das amostras de curto-circuito de 1%, as novas exatidões foram de 86% para a primeira abordagem, 86% para segunda abordagem e de 95% para a terceira abordagem. A exatidão das RNA na identificação das amostras saudáveis foram acima de 90%. As principais fontes de inexatidão das topologias testadas, foram na classificação de amostras de curto-circuito de 3% com o curto-circuito de 5% e vice-versa. No diagnóstico do curto-circuito de 10%, obteve-se 100% de exatidão, nas três abordagens propostas, independentemente se as amostras de curto-circuito de 1% estavam presente no banco de dados utilizado, e em nenhuma hipótese outra classe foi classificada com esse grau de severidade, mostrando a robustez da metodologia proposta para a detecção desse grau de severidade de curto-circuito.

Dentre as 3 abordagens propostas, verifica-se que a terceira abordagem, que consiste em utilizar a amplitude dos harmônicos da FFT de cada amostra, apresentou os melhores resultados. Esta abordagem obteve exatidão superior utilizando as amostras de curto-circuito de 1%, quando comparado com as exatidões das outras abordagens que não utilizam as amostras de curto-circuito de 1% e quando retirado essa classe de curto-circuito a abordagem obteve exatidão acima de 95%.

Do exposto, a metodologia proposta no diagnóstico de curtos-circuitos no enrolamento do estator apresentou dificuldades em identificar as falhas em estágios incipientes, precisamente o curto-circuito de 1%, sugerindo que análises de otimizações na bobina exploratória devem ser revistas, com o intuito de melhorar a detecção de falhas nesse estágios.

Por comparação dos melhores resultados obtidos com a 3ª abordagem, usando as amplitudes harmônicas, a exatidão final com a topologia 5 foi de 86,7% e 95,4% com e sem amostras de curto circuito de 1% das espiras. Este resultado está ao nível do estado da arte apresentado por outros autores e situa-se apenas a 2 pontos percentuais dos melhores resultados publicados.

7.1 Trabalhos Futuros

Os trabalhos futuros associados a esta pesquisa são estabelecidos com o intuito de aperfeiçoar o método proposto para a identificação de falhas em motores de indução. As principais atividades para os trabalhos futuros são:

- Avaliar a metodologia proposta para motores de indução com maiores potências.
- Avaliar a metodologia proposta para motores alimentados com desequilíbrio das tensões.
- Realizar otimizações na bobina exploratória para melhorar a identificação de falhas em estágios incipientes.
- Aperfeiçoar a metodologia proposta para a identificação de outros tipos de falhas em MIT.
- Aumentar o número de amostras nas diversas condições do motor, de forma às redes neuronais poderem aprender com mais casos.

Referências

- Ayhan, B.; Chow, M. Y.; Song, M. H. Multiple Signature Processing-Based Fault Detection Schemes for Broken Rotor Bar in Induction Motors. *IEEE Transactions on Energy Conversion*, v. 20, n. 2, p. 336–343, 2005.
- Ballal, M. S.; Khan, Z. J.; Suryawanshi, H. M.; Sonolikar, R. L. Adaptive Neural Fuzzy Inference System for the Detection of Inter-Turn Insulation and Bearing Wear Faults in Induction Motor. *IEEE Transactions on Industrial Electronics*, v. 54, n. 1, p. 250–258, 2007.
- Barzegaran, M.; Mazloomzadeh, A.; Mohammed, O. A. Fault Diagnosis of the Asynchronous Machines Through Magnetic Signature Analysis Using Finite-Element Method and Neural Networks. *IEEE Transactions on Energy Conversion*, v. 28, n. 4, p. 1064–1071, 2013.
- Bazan, G. H. Medidas de Informação e Sistemas Inteligentes Aplicados no Diagnóstico de Curto-Circuito do Estator de Motores de Indução Trifásicos. Dissertação (Mestrado), Universidade Tecnológica Federal do Paraná, 2016.
- Bazan, G. H.; Scalassara, P. R.; Endo, W.; Goedel, A.; Godoy, W. F.; Palácios, R. H. C. Stator Fault Analysis of Three-Phase Induction Motors Using Information Measures and Artificial Neural Networks. *Electric Power Systems Research*, v. 143, p. 347–356, 2017.
- Bazan, G. H.; Scalassara, P. R.; Endo, W.; Goedel, A.; Palácios, R. H. C.; Godoy, W. F. Stator Short-Circuit Diagnosis in Induction Motors Using Mutual Information and Intelligent Systems. *IEEE Transactions on Industrial Electronics*, v. 66, n. 4, p. 3237–3246, 2019.
- Bellini, A.; Filippetti, F.; Tassoni, C.; Capolino, G. A. Advances in Diagnostic Techniques for Induction Machines. *IEEE Transactions on Industrial Electronics*, v. 55, n. 12, p. 4109–4126, 2008.
- Bonnett, A.; Yung, C. Increased Efficiency Versus Increased Reliability. *IEEE Industry Applications Magazine*, v. 14, n. 1, p. 29–36, 2008.
- Bouzid, M. B. K.; Champenois, G. New Expressions of Symmetrical Components of the Induction Motor Under Stator Faults. *IEEE Transactions on Industrial Electronics*, v. 60, n. 9, p. 4093–4102, 2013.
- Broniera, P. Diagnóstico de Curto-Circuito no Enrolamento de Estator em Máquinas de Indução Trifásicas Utilizando Redes Neurais Artificiais. Dissertação (Mestrado), Universidade Tecnológica Federal do Paraná, 2014.
- Broniera, P. J.; Gongora, W. S.; Goedel, A.; Godoy, W. F. Diagnosis of Stator Winding Inter-turn Short Circuit in Three-Phase Induction Motors by Using Artificial Neural Networks. *2013 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)*, p. 281–287, 2013.
- Choudhary, A.; Goyal, D.; Shimi, S. L.; Akula, A. Condition Monitoring and Fault Diagnosis of Induction Motors : A Review. *Archives of Computational Methods in Engineering*, v. 26, n. 4, p. 1221–1238, 2019.
- Diniz, P. S. R.; Silva, E. A. B.; Netto, S. L. Processamento Digital de Sinais. 2. ed. Porto Alegre: Bookman, 2014.
- Drif, M.; Cardoso, A. J. M. Stator Fault Diagnostics in Squirrel Cage Three-Phase Induction Motor Drives Using the Instantaneous Active and Reactive Power Signature Analyses. *IEEE Transactions on Industrial Informatics*, v. 10, n. 2, p. 1348–1360, 2014.
- Eftekhari, M.; Moallem, M.; Sadri, S.; Hsieh, M. F. A Novel Indicator of Stator Winding Inter-

- Turn Fault in Induction Motor Using Infrared Thermal Imaging. *Infrared Physics and Technology*, v. 61, p. 330–336, 2013.
- Eftekhari, M.; Moallem, M.; Sadri, S.; Hsieh, M. F. Online Detection of Induction Motor's Stator Winding Short-Circuit Faults. *IEEE Systems Journal*, v. 8, n. 4, p. 1272–1282, 2014.
- Ertan, H. B.; Keysan, O. External Search Coil as a Means of Measuring Rotor Speed of an Induction Motor. *2009 8th International Symposium on Advanced Electromechanical Motion Systems and Electric Drives Joint Symposium, ELECTROMOTION 2009*, n. July, p. 1–6, 2009.
- Filho, P. C. M. L.; Pederiva, R.; Brito, J. N. Detection of stator winding faults in induction machines using flux and vibration analysis. *Mechanical Systems and Signal Processing*, v. 42, n. 1–2, p. 377–387, 2014.
- Filippetti, F.; Franceschini, G.; Tassoni, C.; Vas, P. Recent Developments of Induction Motor Drives Fault Diagnosis Using AI Techniques. *IEEE Transactions on Industrial Electronics*, v. 47, n. 5, p. 994–1004, 2000.
- Garcia-Ramirez, A. G.; Morales-Hernandez, L. A.; Osornio-Rios, R. A.; Benitez-Rangel, J. P.; Garcia-Perez, A.; Romero-Troncoso, R. J. Fault Detection in Induction Motors and the Impact on The Kinematic Chain Through Thermographic Analysis. *Electric Power Systems Research*, v. 114, p. 1–9, 2014.
- Ghate, V. N.; Dudul, S. V. Expert Systems with Applications Optimal MLP neural network classifier for fault detection of three phase induction motor. *Expert Systems With Applications*, v. 37, n. 4, p. 3468–3481, 2010.
- Goedtel, A. Estimador Neural de Velocidade para Motores de Indução Trifásicos. Tese (Doutoramento), Escola de Engenharia de São Carlos, Universidade de São Paulo, 2007.
- Graciola, C. L.; Goedtel, A.; Suetake, M.; Sumar, R. R. Neural Speed Estimator for Line-Connected Induction Motor Embedded in a Digital Processor. *Applied Soft Computing Journal*, v. 40, p. 616–623, 2016.
- Guedes, J. J. Identificação de Falhas de Curto-Circuito de Estator em Motores de Indução Trifásicos Utilizando Evolução Diferencial. Dissertação (Mestrado), Universidade Tecnológica Federal do Paraná, 2016.
- Guedes, J. J.; Castoldi, M. F.; Goedtel, A.; Agulhari, C. M.; Sanches, D. S. Parameters Estimation of Three-Phase Induction Motors Using Differential Evolution. *Electric Power Systems Research*, v. 154, p. 204–212, 2018.
- Hassan, O. E.; Amer, M.; Abdelsalam, A. K.; Williams, B. W. Induction Motor Broken Rotor Bar Fault Detection Techniques Based on Fault Signature Analysis – A review. *IET Electric Power Applications*, v. 12, n. 7, p. 895–907, 2018.
- Haykin, S. *Neural Networks - A Comprehensive Foundation*. 3. ed. Upper Saddle River: NJ: Prentice Hall PTR, 2007.
- Hegde, V.; Rao, M. S. Electric Power Components and Systems Detection of Stator Winding Inter-Turn Short Circuit Fault in Induction Motor Using Vibration Signals by MEMS Accelerometer Detection of Stator Winding Inter-Turn Short Circuit. *Electric Power Components and Systems*, v. 5008, 2017.
- Konar, P.; Chattopadhyay, P. Multi-Class Fault Diagnosis of Induction Motor Using Hilbert and Wavelet Transform. *Applied Soft Computing Journal*, v. 30, p. 341–352, 2015.
- Levenberg, K. A Method for The Solution of Certain Non-Linear Problems In Least Squares. *Quarterly of applied mathematics*. v. 2, n. 2, p. 164–168, 1944.

- Mackay, D. J. C. Bayesian Interpolation. *Neural computation*, v. 4, p. 415–447, 1992.
- MARQUARD, D. W. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *SIAM Journal on Applied Mathematics*, v. 11, n. 2, 1963.
- Mohammed, A.; Melecio, J. I.; Djurović, S. Stator Winding Fault Thermal Signature Monitoring and Analysis by in Situ FBG Sensors. *IEEE Transactions on Industrial Electronics*, v. 66, n. 10, p. 8082–8092, 2019.
- Oppenheim, A. V.; Schaffer, R. W. Discrete-Time Signal Processing. 3. ed. Upper Saddle River, NJ, USA: Prentice Hall, 2009.
- Palácios, R. H. C.; da Silva, I. N.; Goedtel, A.; Godoy, W. F. A Comprehensive Evaluation of Intelligent Classifiers for Fault Identification in Three-Phase Induction Motors. *Electric Power Systems Research*, v. 127, p. 249–258, 2015.
- Palácios, R. H. C.; da Silva, I. N.; Goedtel, A.; Godoy, W. F.; Lopes, T. D. Diagnosis of Stator Faults Severity in Induction Motors Using Two Intelligent Approaches. *IEEE Transactions on Industrial Informatics*, v. 13, n. 4, p. 1681–1691, 2017.
- Palácios, R. H. C.; Goedtel, A.; Godoy, W. F.; Fabri, J. A. Fault Identification in the Stator Winding of Induction Motors Using PCA with Artificial Neural Networks. *Journal of Control, Automation and Electrical Systems*, 2016.
- Park, Y.; Yang, C.; Kim, J.; Kim, H.; Lee, S. B.; Gyftakis, K. N.; Panagiotou, P. A.; Kia, S. H. Capolino, G. A. Stray Flux Monitoring for Reliable Detection of Rotor Faults Under the Influence of Rotor Axial Air Ducts. v. 66, n. 10, p. 7561–7570, 2019.
- Riedmiller, M.; Braun, H. Rprop - A Fast Adaptive Learning Algorithm. *Proceedings of the International Symposium on Computer and Information Science VII*, 1992.
- Riera-Guasp, M.; Antonino-Daviu, J. A.; Capolino, G. A. Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: State of the art. *IEEE Transactions on Industrial Electronics*, v. 62, n. 3, p. 1746–1759, 2015.
- Romero-Troncoso, R. J.; Cabal-Yepez, E.; Osornio-Rios, R. A.; Miranda-Vidales, H. FPGA-based online detection of multiple combined faults in induction motors through information entropy and fuzzy inference. *IEEE Transactions on Industrial Electronics*, v. 58, n. 11, p. 5263–5270, 2011.
- Sadeghi, R.; Samet, H.; Ghanbari, T. Detection of Stator Short-Circuit Faults in Induction Motors Using the Concept of Instantaneous Frequency. *IEEE Transactions on Industrial Informatics*, v. 15, n. 8, p. 4506–4515, 2019.
- Santos, F. M. da C.. Identificação de falhas em motores de indução trifásicos usando sistemas inteligentes. Tese (Doutoramento). Universidade de São Paulo, São Carlos, 2013.
- Santos, T. H.; Goedtel, A.; Silva, S. A. O.; Suetake, M. Speed Estimator in Closed-Loop Scalar Control Using Neural Networks. *Proceedings - 2014 International Conference on Electrical Machines, ICEM 2014*, p. 2570–2576, 2014.
- Schmitt, H. L.; Scalassara, P. R.; Goedtel, A.; Endo, W. Detecting Bearing Faults in Line-Connected Induction Motors Using Information Theory Measures and Neural Networks. *Journal of Control, Automation and Electrical Systems*, v. 26, n. 5, p. 535–544, 2015.
- 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. 2320–3765, 2014.

- Silva, I. N.; Spatti, D. H.; Flauzino, R. A., Liboni, L. H. B.; Alves, S. F. R. Artificial Neural Networks: Apractical course. Springer International Publishing, 2017.
- Singh, G.; Kumar, T. C. A.; Naikan, V. N. A. Induction Motor Inter Turn Fault Detection Using Infrared Thermographic Analysis. *Infrared Physics and Technology*, v. 77, p. 277–282, 2016.
- Su, H.; Chong, K. T.. Induction machine condition monitoring using neural network modeling. *IEEE Transactions on Industrial Electronics*, v. 54, n. 1, p. 241-249, 2007.
- Suetake, M. Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos. Tese (Doutoramento), Universidade de São Paulo, 2012.
- Surya, G. N.; Khan, Z. J.; Ballal, M. S.; Suryawanshi, H. M. A Simplified Frequency-Domain Detection of Stator Turn Fault in Squirrel-Cage Induction Motors Using an Observer Coil Technique. *IEEE Transactions on Industrial Electronics*, v. 64, n. 2, p. 1495–1506, 2017.
- Vitor, A. L. O. Detecção de Falhas de Estator em Motores de Indução Trifásicos Utilizando Transformada Wavelet, Medida RMS e Potência de Previsão. Dissertação (Mestrado), Universidade Tecnológica Federal do Paraná, 2015.
- Wolkiewicz, M.; Tarchała, G.; Orłowska-Kowalska, T.; Kowalski, C. T. Online Stator Interturn Short Circuits Monitoring in the DFOC Induction-Motor Drive. *IEEE Transactions on Industrial Electronics*, v. 63, n. 4, p. 2517–2528, 2016.
- Yeh, C. C.; Sizov, G. Y.; Sayed-Ahmed, A.; Demerdash, N. A.; Povinelli, R. J.; Yaz, E. E.; Ionel, D. M. A Reconfigurable Motor for Experimental Emulation of Stator Winding Interturn and Broken Bar Faults in Polyphase Induction Machines. *IEEE Transactions on Energy Conversion*, v. 23, n. 4, p. 1005–1014, 2008.
- Zarei, J.; Tajeddini, M. A.; Karimi, H. R. Vibration Analysis for Bearing Fault Detection and Classification Using an Intelligent Filter. *Mechatronics*, v. 24, n. 2, p. 151–157, 2014.
- Zidani, F.; Benbouzid, M. E. H.; Diallo, D.; Naït-Saïd, M. S. Induction Motor Stator Faults Diagnosis by a Current Concordia Pattern-Based Fuzzy Decision System. *IEEE Transactions on Energy Conversion*, v. 18, n. 4, p. 469–475, 2003.