

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

JACQUELINE JORDAN GUEDES

**IDENTIFICAÇÃO DE FALHAS DE CURTO-CIRCUITO DE
ESTATOR EM MOTORES DE INDUÇÃO TRIFÁSICOS
UTILIZANDO EVOLUÇÃO DIFERENCIAL**

DISSERTAÇÃO

CORNÉLIO PROCÓPIO

2017

JACQUELINE JORDAN GUEDES

**IDENTIFICAÇÃO DE FALHAS DE CURTO-CIRCUITO DE
ESTATOR EM MOTORES DE INDUÇÃO TRIFÁSICOS
UTILIZANDO EVOLUÇÃO DIFERENCIAL**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Engenharia Elétrica” – Área de Concentração: Acionamentos Eletroeletrônicos.

Orientador: Marcelo Favoretto Castoldi

Co-orientador: Alessandro Goedtel

CORNÉLIO PROCÓPIO

2017

TERMO DE APROVAÇÃO
Título da Dissertação Nº 35:

Identificação de falhas de curto-circuito de estator em motores de indução trifásicos utilizando evolução diferencial

por

Jacqueline Jordan Guedes

Orientador: **Prof. Dr. Marcelo Favoretto Castoldi**

Esta dissertação foi apresentada como requisito parcial à obtenção do grau de MESTRE EM ENGENHARIA ELÉTRICA – Área de Concentração: Sistemas Eletrônicos Industriais, pelo Programa de Pós-Graduação em Engenharia Elétrica – PPGEE – da Universidade Tecnológica Federal do Paraná – UTFPR – Câmpus Cornélio Procópio, às 9h do dia 14 de dezembro de 2016. O trabalho foi aprovado pela Banca Examinadora, composta pelos professores:

Prof. Dr. Marcelo Favoretto Castoldi
(Presidente)

Prof. Dr. Rodrigo Andrade Ramos
USP

Prof. Dr. Wagner Fontes Godoy
UTFPR – CP

Prof. Dr. Rodrigo Henrique Cunha Palácios
UTFPR – CP

Visto da coordenação:

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

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

Dados Internacionais de Catalogação na Publicação

- G924 Guedes, Jacqueline Jordan
Identificação de falhas de curto-circuito de estator em motores de indução trifásicos utilizando evolução diferencial / Jacqueline Jordan Guedes. – 2017.
69 f. : il. color. ; 30 cm
- Orientador: Marcelo Favoretto Castoldi.
Coorientador: Alessandro Goedel.
Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. Cornélio Procópio, 2017.
Bibliografia: p. 63-69.
1. Motores elétricos de indução. 2. Localização de falhas (Engenharia). 3. Algoritmos. 4. Engenharia Elétrica – Dissertações. I. Castoldi, Marcelo Favoretto, orient. II. Goedel, Alessandro. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. IV. Título.

CDD (22. ed.) 621.3

Aos meus pais, pelo apoio e amor incondicional.

AGRADECIMENTOS

Agradeço a Deus, pois tudo que precisei e desejei eu tive forças para conseguir.

Agradeço aos meus pais por todo apoio, dedicação e carinho para que eu conseguisse chegar até aqui. Sei que abriram mão de muitas coisas para que eu pudesse estudar e ter o conforto que sempre tive. Dizer obrigado não é suficiente, mas que eu consiga retribuir tudo o que fizeram e fazem por mim até hoje.

Agradeço ao meu irmão, minha cunhada e aos meus sobrinhos, por alegrarem os dias em que tive oportunidade de estar com eles e por entenderem quando eu não pude estar presente.

Ao meu namorado pela paciência e apoio, pois estava presente para me animar e encorajar em todos os momentos em que eu queria desistir ou achava que não iria conseguir.

Aos amigos que estiveram sempre presentes e me ajudaram a encarar os problemas de maneira mais leve, e aqueles que ficaram do meu lado até tarde me ajudando nos trabalhos.

A todos os membros do Laboratório de Sistemas Inteligentes (LSI) pela parceria e amizade. Com vocês até os dias mais difíceis se tornaram divertidos. Percebi que realmente somos uma equipe e que aqui todos vencem juntos.

Ao meu orientador, Prof. Marcelo Castoldi, pela sua orientação e por todos os anos e trabalhos que desenvolvemos juntos. Acredito que ganhei um grande amigo e incentivador. Muitas vezes, quando as dificuldades se mostraram grandes demais, ele me mostrou como torná-las minúsculas e, principalmente, sempre acreditou em mim.

Agradeço também ao meu co-orientador, Prof. Alessandro Goedtel, por todo auxílio prestado e pelo incentivo à pesquisa. Ao Prof. Rodrigo Palácios e ao Prof. Wagner Godoy por me auxiliarem todas as vezes em que tive dificuldades e pelos ensinamentos e conselhos para melhoria deste trabalho.

Ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná, Cornélio Procópio, pela oportunidade a mim concedida. A parceria com a Universidade de São Paulo no projeto Casadinho/Procad. A CAPES e

Fundação Araucária pelo apoio financeiro para a realização da pesquisa.

”Fé é acreditar no que você não vê; e a recompensa da fé é ver o que você acredita”

Santo Agostinho de Hipona

RESUMO

GUEDES, Jacqueline Jordan. IDENTIFICAÇÃO DE FALHAS DE CURTO-CIRCUITO DE ESTATOR EM MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO EVOLUÇÃO DIFERENCIAL. 69 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2017.

O motor de indução trifásico do tipo gaiola de esquilo é a principal máquina de conversão eletromecânica devido a sua robustez e facilidade de manutenção, sendo indispensável nos processos produtivos industriais. Por sua grande importância, pesquisas na área de identificação de falhas são realizadas constantemente com o objetivo de diminuir as taxas de manutenções corretivas e permitir uma manutenção programada, diminuindo perdas no processo produtivo, decorrentes de paradas indesejadas. Com esse propósito, o presente trabalho propõe o estudo e desenvolvimento de uma metodologia alternativa que utiliza a Evolução Diferencial para identificação de falhas de curto-circuito de estator em motores de indução conectados diretamente à rede elétrica, por meio dos sinais de tensão e corrente adquiridos no domínio do tempo. O algoritmo de Evolução Diferencial é utilizado para estimar os parâmetros elétricos do motor de indução, a partir do modelo do circuito elétrico equivalente e a identificação da falha ocorre a partir do cálculo da variação percentual da indutância de magnetização estimada com o motor sem falhas. A base de dados utilizada para o trabalho foi obtida por meio de experimentos laboratoriais realizados com dois motores diferentes de 1 CV e um motor de 2 CV, sob condições de variação de conjugado, tensões equilibradas e desequilibradas.

Palavras-chave: Motores de Indução Trifásicos, Evolução Diferencial, Identificação de Falhas, Falhas de Estator

ABSTRACT

GUEDES, Jacqueline Jordan. THREE-PHASE INDUCTION MOTOR STATOR SHORT-CIRCUIT FAULT IDENTIFICATION USING DIFFERENTIAL EVOLUTION. 69 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2017.

The squirrel cage three-phase induction motor is the main electromechanical conversion machine due to its robustness and easy maintenance, therefore it is indispensable in the industrial production processes. Due to its great importance, surveys related to its fault identification are conducted constantly, in order to reduce the corrective maintenance rates and allow a scheduled maintenance, reducing the losses in the production process, due to unexpected stops. With this purpose, this work proposes the study and development of an alternative methodology based on Differential Evolution algorithm to identify stator short-circuit failures in induction motors connected directly on the electric grid, through its voltage and current signals acquired in the time domain. This Differential Evolution algorithm is used to estimate the induction motor electric parameters based on its equivalent electric circuit model and the fault identification occurs in result of the calculation of the estimated magnetization inductance percentage variation considering a healthy motor. The database used for this work was obtained through laboratory experiments performed with two different types of 1 CV motor and a 2 CV motor under different conditions of torque variation and unbalanced voltages.

Keywords: Three-Phase Induction Motor, Differential Evolution, Fault Identification, Stator Fault

LISTA DE FIGURAS

FIGURA 1	–	Modelo de transformador do motor de indução trifásico	19
FIGURA 2	–	Circuito elétrico equivalente final do MIT	21
FIGURA 3	–	Circuito simplificado do MIT	22
FIGURA 4	–	Comparação entre correntes estimada e experimental	23
FIGURA 5	–	Processo vetorial de mutação do DE	27
FIGURA 6	–	Processo de <i>crossover</i> do DE	28
FIGURA 7	–	Processo de mutação, cruzamento e seleção do <i>target vector</i>	28
FIGURA 8	–	Funcionamento do DE	29
FIGURA 9	–	Diagrama esquemático do algoritmo proposto	31
FIGURA 10	–	Imagem ilustrativa dos <i>taps</i> de derivação	34
FIGURA 11	–	Disposição dos <i>taps</i> na caixa de ligação do MIT rebobinado	35
FIGURA 12	–	Bancada experimental do laboratório de Sistemas Inteligentes da UTFPR	36
FIGURA 13	–	Fluxograma de tratamento do sinal	39
FIGURA 14	–	Fluxograma da utilização do DE para criação da tabela de referência	42
FIGURA 15	–	Processo de seleção do vetor referência	43
FIGURA 16	–	Fluxograma da utilização do DE para identificação de falha	44
FIGURA 17	–	Espectro para identificação de falha no MIT	46
FIGURA 18	–	Diagrama do sistema de identificação de falha	46
FIGURA 19	–	Comparação entre as correntes da tabela de referência do Motor 1	49
FIGURA 20	–	Comparação entre as correntes da tabela de referência do Motor 2	49
FIGURA 21	–	Comparação entre as correntes da tabela de referência do Motor 3	50
FIGURA 22	–	Identificação da falha corretamente no espectro	52
FIGURA 23	–	Identificação da falha indicando um falso positivo no espectro	52
FIGURA 24	–	Análise do desequilíbrio de tensão na estimativa de parâmetros	53
FIGURA 25	–	Identificação da falha corretamente no espectro	54
FIGURA 26	–	Identificação da falha indicando um falso positivo no espectro	55
FIGURA 27	–	Análise do desequilíbrio de tensão na estimativa de parâmetros	55
FIGURA 28	–	Identificação da falha corretamente no espectro	57
FIGURA 29	–	Identificação da falha indicando um falso negativo no espectro	57
FIGURA 30	–	Análise do desequilíbrio de tensão na estimativa de parâmetros	58

LISTA DE TABELAS

TABELA 1	–	Parâmetros estimados em um motor de 5HP do <i>Simulink</i> [®]	23
TABELA 2	–	Comparação entre AG e DE (DAS; SUGANTHAN, 2011)	30
TABELA 3	–	Parâmetros e características dos MIT utilizados nos experimentos	34
TABELA 4	–	Níveis de falha aplicados aos motores	37
TABELA 5	–	Níveis de desequilíbrio de tensão aplicado aos MIT	37
TABELA 6	–	Condições de operação dos MIT utilizados	38
TABELA 7	–	Parâmetros estimados por meio do DE para o Motor 1	40
TABELA 8	–	Parâmetros estimados por meio do DE para o Motor 2	40
TABELA 9	–	Parâmetros estimados por meio do DE para o Motor 3	40
TABELA 10	–	Espaço de busca utilizado no DE	41
TABELA 11	–	Variação da indutância de magnetização (L_M) do Motor 2	45
TABELA 12	–	Desvio percentual de L_M para identificação de falha no MIT	45
TABELA 13	–	Resultado da validação do Motor 1 para tensões equilibradas e com 2% de desequilíbrio	51
TABELA 14	–	Resultado da validação do Motor 2 para tensões equilibradas e com 2% de desequilíbrio	54
TABELA 15	–	Resultado da validação do Motor 3 para tensões equilibradas e com 2% de desequilíbrio	56
TABELA 16	–	Comparação de resultados entre motores estudados	59
TABELA 17	–	Comparação de resultados entre motores estudados	59
TABELA 18	–	Comparativo entre os resultados desta pesquisa e trabalhos recentes para identificação de falhas de estator	59

LISTA DE SIGLAS

MIT	Motores de Indução Trifásicos
MUSIC	Algoritmo de classificação multisinais, do inglês <i>Multiple-Signal Classification</i>
TH	Transformada de <i>Hilbert</i>
TWD	Transformada de <i>Wavelet</i> Discreta
FFT	Transformada Rápida de Fourier, do inglês <i>Fast Fourier Transform</i>
TWC	Transformada <i>Wavelet</i> Contínua
PMC	<i>Perceptron</i> Multicamadas
SVM	Máquinas de Vetores de Suporte, do inglês <i>Support Vector Machines</i>
RBF	Funções de Base Radial, do inglês <i>Radial Basis Function</i>
DE	Evolução Diferencial, do inglês <i>Differential Evolution</i>
SI	Sistemas Inteligentes
ACO	Otimização por Colônia de Formigas, do inglês <i>Ant Colony Optimization</i>
FA	Vagalumes, do inglês <i>Firefly Algorithm</i>
ABC	Colônia de Abelhas Artificial, do inglês <i>Artificial Bee Colony</i>
AG	Algoritmos Genéticos
FO	Função Objetivo

SUMÁRIO

1 INTRODUÇÃO	12
1.1 JUSTIFICATIVA	15
1.2 OBJETIVOS	16
1.2.1 Objetivo Geral	16
1.2.2 Objetivos Específicos	16
1.3 ORGANIZAÇÃO DO TRABALHO	17
2 MODELAGEM DO MOTOR DE INDUÇÃO TRIFÁSICO	18
2.1 INTRODUÇÃO	18
2.2 CIRCUITO ELÉTRICO EQUIVALENTE	19
2.3 PSEUDO-PARÂMETROS DO MIT	22
2.4 CONCLUSÃO DO CAPÍTULO	24
3 EVOLUÇÃO DIFERENCIAL	25
3.1 INTRODUÇÃO	25
3.2 PRINCÍPIO DE FUNCIONAMENTO	26
3.3 ALGORITMO PROPOSTO	30
3.4 CONCLUSÃO DO CAPÍTULO	32
4 METODOLOGIA	33
4.1 INTRODUÇÃO	33
4.2 REPRODUÇÃO DE DEFEITOS DE ESTATOR NOS MOTORES	33
4.3 BANCADA EXPERIMENTAL	35
4.4 BANCO DE DADOS	36
4.4.1 Tratamento de dados	38
4.4.2 Aplicação do DE	39
4.4.3 Identificação da falha	44
4.5 CONCLUSÃO DO CAPÍTULO	47
5 RESULTADOS OBTIDOS	48
5.1 INTRODUÇÃO	48
5.2 IDENTIFICAÇÃO DE FALHAS DE ESTATOR	48
5.2.1 Resultados obtidos para o Motor 1	51
5.2.2 Resultados obtidos para o Motor 2	53
5.2.3 Resultados obtidos para o Motor 3	56
5.3 CONCLUSÃO DO CAPÍTULO	58
6 CONCLUSÃO	61
6.1 PERSPECTIVAS PARA TRABALHOS FUTUROS	61
6.2 PRODUÇÃO CIENTÍFICA	62
REFERÊNCIAS	63

1 INTRODUÇÃO

Motores de indução trifásicos (MIT) são amplamente utilizados no setor industrial para mover, principalmente, bombas, compressores e ventiladores, representando 68% do consumo energético industrial no Brasil. Este percentual corresponde a 35% da energia elétrica total consumida no país (SAUER et al., 2015).

Embora possua características construtivas robustas, o MIT sofre desgastes naturais em suas partes. Além disso, existem ocasiões em que as cargas aplicadas e os ambientes de operação não são adequados para seu melhor desempenho. Desta forma, pode-se acelerar o processo de deterioração da máquina e, por consequência, reduzir sua vida útil ou causar danos irreparáveis em seus componentes (TRIGEASSOU, 2013).

As falhas do MIT podem ser elétricas ou mecânicas, devido a problemas de estator e rotor, rolamentos, excentricidade, desalinhamento e desgaste de acoplamento (SINGH et al., 2016). Defeitos em rolamentos e estator representam juntos mais de 75% das falhas em motores de indução, sendo 41% para rolamentos e 37% para enrolamento de estator. As falhas de rotor totalizam 10% das paradas indesejadas do MIT e as demais, tais como excentricidade, desalinhamento, desgaste de acoplamento ou conexões elétricas, correspondem a 12% do total de defeitos (VAIMANN et al., 2015).

Mesmo em seu estágio inicial, tais defeitos podem afetar o desempenho da máquina, gerando prejuízos para o processo industrial (SUETAKE, 2012). Paradas não programadas são grandes problemas no setor industrial, pois incrementam tanto os gastos com manutenção quanto os prejuízos na produção.

Nas falhas de estator, por exemplo, quando ocorre assimetria nos enrolamentos, a máquina continua operando com o conjugado reduzido. No entanto, a falha de curto-circuito de estator pode evoluir em um curto espaço de tempo, causando um dano irreparável (BELLINI et al., 2008).

Essas circunstâncias mostram a necessidade de realizar um diagnóstico eficiente da falha para evitar maiores danos, tanto à máquina quanto ao processo produtivo

(SESHADRINATH et al., 2014). Os defeitos elétricos e mecânicos podem ser identificados por meio de alterações apresentadas ao longo de seu funcionamento (GHATE; DUDUL, 2010), como a variação da temperatura, vibrações mecânicas, ruídos, alteração de campo eletromagnético e sinais de corrente (GARCIA-RAMIREZ et al., 2014; BAYRAM; ŞEKER, 2015; ROSHANFEKR; JALILIAN, 2015).

No trabalho de Garcia-Ramirez et al. (2014) faz-se o uso de imagens termográficas para a identificação de falhas. No estudo são descritos os testes realizados com defeitos de rolamento, barra de rotor quebrada, desalinhamento, variação de carga mecânica e desequilíbrio de tensão de 5%.

O trabalho de Garcia-Perez et al. (2012) propõe em seu estudo uma análise espectral de alta resolução baseada no algoritmo de classificação multi-sinais (MUSIC - do inglês *Multiple-Signal Classification*), que utiliza o sinal de som produzido por um motor de indução para a identificação da frequência relacionada ao defeito.

Os métodos que utilizam os sinais de corrente como dados de entrada permitem a identificação de falhas no estator, rotor, rolamento e excentricidade. Os referidos sinais podem ser medidos mediante por meio da utilização de transformadores de corrente ou transdutores de efeito Hall, dispensando a instalação de sensores adicionais, como no caso da temperatura e vibração (PALÁCIOS et al., 2016; GODOY et al., 2016).

No trabalho de Filho et al. (2014), a falha no estator é diagnosticada por meio de uma relação estabelecida com os sinais de fluxo magnético e vibração, com o objetivo de identificar as frequências características das falhas. A metodologia proposta foi testada em um motor de 1 CV alimentado com tensões desequilibradas e operação com carga nominal.

Utilizando a Transformada de *Hilbert* (TH) e a Transformada de *Wavelet* Discreta (TWD), Ahamed et al. (2014) propõe uma abordagem para diagnóstico de falhas de curto-circuito no estator por meio da assinatura de corrente do motor em janelas de estado estacionário. A metodologia foi aplicada utilizando as correntes trifásicas de um motor de 1 CV, em bancada de ensaios. As correntes foram monitoradas por três sensores Hall, com a máquina ligada diretamente à rede elétrica com tensões equilibradas e operando a vazio.

O trabalho de Drif e Cardoso (2014) propõem o diagnóstico da falha de estator em alimentação direta da rede ou por inversor de frequência, comparando-se a assinatura das potências instantâneas ativa e reativa. Os sinais de tensões e correntes são apresentados

como espectros normalizados, obtidos por meio da Transformada Rápida de Fourier (FFT - do inglês *Fast Fourier Transform*) em escala linear com uma janela retangular. Para validar a metodologia proposta, os autores utilizaram dados experimentais de 5 motores com potências distintas, sob condições de operação a vazio e com carga, alimentados diretamente da rede com tensões desequilibradas ou acionados por inversores de frequência.

Konar e Chattopadhyay (2015) utilizam uma combinação da Transformada *Wavelet* Contínua (TWC) e TH com Algoritmo Genético (AG) extraindo as características e redução da dimensionalidade das informações obtidas dos sinais de vibração não estacionários. No referido trabalho são utilizados classificadores *Perceptron* Multicamadas (PMC), Máquinas de Vetores de Suporte (SVM - do inglês *Support Vector Machines*) e Funções de Base Radial (RBF - do inglês *Radial Basis Function*) para diagnóstico das falhas.

O trabalho de Das et al. (2010) mostra o monitoramento de pequenas falhas de curto-circuito no enrolamento do estator por meio do sinal de corrente de linha do motor, utilizando técnicas de processamento de sinais e redução de dados juntamente com as Transformadas Park e TWC. Os autores utilizaram a técnica de SVM.

AlThobiani et al. (2013) também utilizaram o SVM e compararam-na com a *Simplified Fuzzy ARTmap*, para analisar o sinal de corrente durante o transitório da máquina. Estes sinais são decompostos em componentes individuais por meio da expansão de *Fourier-Bessel*.

Artigos recentes na literatura pesquisada indicam que o uso das RNAs tem apresentado resultados promissores. Em Barzegaran et al. (2013), os autores apresentam um método para diagnóstico de falhas nos enrolamentos do estator por meio de sinais magnéticos associados a elementos finitos.

Ainda utilizando-se RNA, Godoy et al. (2015) apresenta como estratégia o monitoramento das amplitudes dos sinais das correntes no domínio do tempo, utilizando um semiciclo da forma de onda para classificar a falha de curto-circuito de estator.

Palácios et al. (2015) avalia os métodos de classificação de padrões, como *Naive Bayes*, *k-Nearest Neighbor*, SVM, RNA e Árvore de Decisão, para identificação de falhas do MIT, por meio das amplitudes das correntes do motor no domínio do tempo.

Por fim, no trabalho de Duan e Živanović (2013) são utilizados dados de corrente (em regime transitório e permanente) para diagnóstico de falha do estator a partir da análise de parâmetros estimados. O artigo de Tretrong et al. (2012) apresenta uma

técnica de identificação de parâmetros do motor por meio de AG, com o intuito de diagnosticar falhas em máquinas elétricas. Para a estimativa dos parâmetros de resistência e indutância de estator foi utilizado o modelo de sequência zero, bem como a velocidade da máquina e dados de corrente e tensão de todas as suas três fases.

Assim, a proposta deste trabalho consiste em apresentar uma estratégia para o diagnóstico de falhas de curto-circuito no enrolamento do estator. São utilizados os sinais de corrente e tensão em regime permanente, além do módulo da velocidade como entradas do sistema. Estes serão utilizados em um algoritmo de Evolução Diferencial (DE - do inglês *Differential Evolution*), junto ao modelo do circuito elétrico equivalente do MIT, para estimar seus parâmetros elétricos.

Diferente da RNA, que trabalha com classificador de padrões, o DE trabalha como um aproximador de funções buscando uma ótimo global, ou seja, a melhor solução para determinado problema. Dessa forma, sua utilização para identificação de falhas de estator torna-se um método alternativo, ainda pouco estudado, que faz a classificação da falha por meio de análise de parâmetros do motor de indução trifásico, utilizando-se o modelo do mesmo.

A identificação da falha ocorre pela análise da variação percentual do parâmetro de magnetização em relação a um valor de referência, estimado com o MIT sem falha. Para isso, cria-se uma tabela de referência com os parâmetros estimados quando o motor opera em situação sem falha e com tensões equilibradas. O processo detalhado para identificação da falha é apresentado no Capítulo 4.

1.1 JUSTIFICATIVA

Atualmente, o consumo do setor industrial corresponde a, aproximadamente, um terço da matriz energética do Brasil, dos quais, cerca de dois terços estão relacionados a sistemas motrizes (EPE, 2016). Esses dados mostram a importância dos MIT dentro da indústria e, por consequência, os estudos relacionados ao mesmo, tais como dimensionamento correto das máquinas e técnicas de manutenção.

As técnicas de manutenção contribuem para o aumento da vida útil do motor e também para o processo produtivo. Uma vez que as máquinas são monitoradas regularmente, paradas não programadas são evitadas, pois seu acompanhamento permite programar o melhor momento para realizar possíveis reparações no MIT.

Na maior parte dos casos, as falhas apresentam assinaturas características em

sinais de corrente e vibração (BAYRAM; ŞEKER, 2015), por exemplo. Assim, o estudo de métodos que utilizam técnicas de processamento seguidos de técnicas de classificação torna-se cada vez mais importante. Além da eficiência para a identificação da falha, deve-se considerar também os aspectos relacionados ao custo benefício, como o baixo esforço computacional.

Nesse aspecto, os sistemas inteligentes (SI) destacam-se por sua simplicidade na implementação computacional, o que os tornam métodos atrativos para o diagnóstico precoce da falha e posterior monitoramento de sua evolução, a fim de permitir a programação da manutenção corretiva no momento adequado (BELLINI et al., 2008).

Entre os tipos de SI destacam-se as RNA, lógica *Fuzzy* e os AE. Embora a utilização do DE para a identificação de falhas em MIT seja ainda pouco estudada, acredita-se que por ser um método robusto, assim como as RNA, é possível obter resultados satisfatórios. Por isso, esse trabalho estuda a identificação de falhas de curto-circuito de estator utilizando DE.

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

Desenvolver um método de diagnóstico de falhas de curto-circuito entre as espiras do enrolamento de estator em motores de indução trifásicos acionados diretamente da rede de alimentação, baseado em um algoritmo de Evolução Diferencial.

1.2.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos do trabalho são apresentados a seguir:

- Analisar os sinais das correntes e tensões de fase dos motores de indução operando em condições sem falhas e com falhas;
- Desenvolver um algoritmo baseado na evolução diferencial capaz de estimar os parâmetros do MIT em regime permanente;
- Desenvolver uma técnica para identificação de falhas de enrolamento de estator a partir da variação dos parâmetros estimados.

1.3 ORGANIZAÇÃO DO TRABALHO

O trabalho está organizado da seguinte forma:

No Capítulo 2 é apresentada a modelagem do motor de indução utilizada no presente trabalho, junto ao DE.

No Capítulo 3 é apresentado o funcionamento do DE e sua aplicação para identificação de falhas.

No Capítulo 4 é descrita a metodologia para a produção de defeitos controlados no estator do MIT, aquisição dos dados, tratamento do sinal e método para identificação das falhas de curto-circuito no estator.

No Capítulo 5 são apresentados os resultados obtidos.

Por fim, no Capítulo 6 são apresentadas as conclusões do trabalho e suas perspectivas futuras.

2 MODELAGEM DO MOTOR DE INDUÇÃO TRIFÁSICO

2.1 INTRODUÇÃO

Este capítulo descreve o comportamento do motor de indução trifásico a partir da análise do circuito elétrico equivalente monofásico, que permite o estudo das características eletromecânicas do mesmo, bem como o efeito de carga apresentado para a fonte de energia, em regime permanente, fornecendo informações suficientes para a estimação de parâmetros do MIT.

O motor de indução trifásico é composto por um estator e um rotor. O estator é constituído de um enrolamento trifásico, com defasagem de 120° entre as fases. Já o rotor do MIT pode ser tanto bobinado quanto em gaiola de esquilo - sendo que o último apresenta como principais vantagens sua simplicidade e robustez de construção em relação ao bobinado, o que faz com que este seja o tipo de motor mais utilizado nas indústrias (KRAUSE et al., 2013).

A principal característica que diferencia um motor de indução dos motores de corrente contínua e síncronos é a ausência da corrente de campo contínua (CC) para que a máquina entre em operação (ONG, 1998). Nesse caso, aplica-se tensão alternada diretamente ao estator que é transmitida ao rotor por indução, semelhante a um transformador (KRAUSE et al., 2013).

No presente trabalho, objetiva-se a identificação das falhas de estator por meio dos dados de corrente e de tensão da máquina. Tais medidas de corrente serão utilizadas como dados de entrada para o algoritmo de evolução diferencial, que tem por objetivo identificar o valor dos parâmetros elétricos da máquina, tais como resistências de estator e rotor, as indutâncias de dispersão de estator e rotor e a indutância de magnetização. Nesse processo, os dados relativos à tensão de alimentação da máquina serão utilizados como entrada do circuito elétrico equivalente, o qual determina os parâmetros estimados por meio das medidas de corrente.

2.2 CIRCUITO ELÉTRICO EQUIVALENTE

Para representar o circuito elétrico equivalente do MIT em regime permanente, deve-se considerar uma máquina simétrica com tensões equilibradas, conectadas em Y, com valores de fase para tensão e corrente. Assim, é possível deduzir o circuito para uma única fase e então aplicar uma defasagem de $\pm 120^\circ$ para as outras fases.

Considerando que as correntes do rotor representam o resultado de uma ação de um transformador, por serem consequência do fluxo magnético produzido no estator, o circuito do motor de indução, inicialmente, é formado pelos circuitos de estator e rotor, com ambos conectados por meio de um transformador ideal, conforme Figura 1.

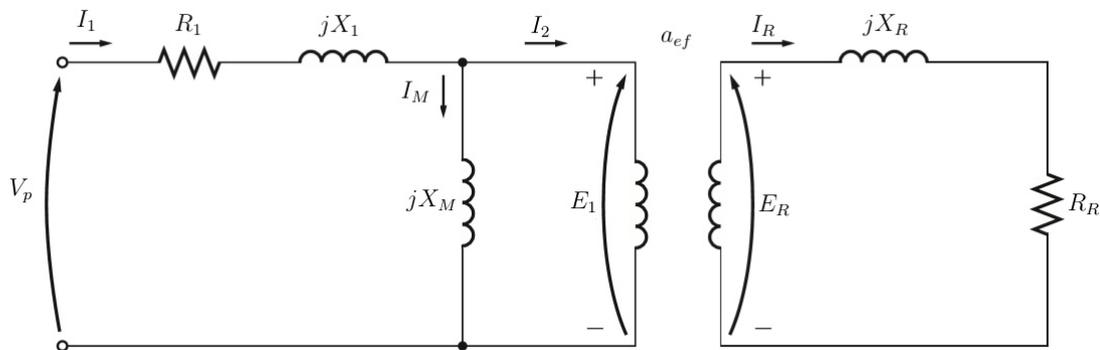


Figura 1: Modelo de transformador do motor de indução trifásico

Fonte: Adaptado de Krause et al. (2013)

Na Figura 1, V_p é a tensão de fase de terminal do estator; I_1 é a corrente do estator; R_1 é a resistência efetiva do estator; X_1 é a reatância de dispersão do estator; I_M é a corrente do ramo de magnetização; X_M é a reatância de dispersão do ramo de magnetização; I_2 é a corrente do rotor referida ao primário; E_1 é tensão induzida do rotor referida ao primário; a_{ef} é a relação de espiras do transformador ideal; E_R é tensão induzida do rotor; I_R é a corrente do rotor; R_R é a resistência efetiva do rotor; X_R é a reatância de dispersão do rotor;

Considerando primeiramente a parte do estator, a tensão de fase de terminal pode ser descrita por (1).

$$V_p = E_1 + I_1(R_1 + jX_1) \quad (1)$$

Quanto ao circuito do rotor, é possível representá-lo de acordo com (2)

$$E_R = I_R(R_R + jX_R) \quad (2)$$

ou ainda

$$I_R = \frac{E_R}{(R_R + jX_R)} \quad (3)$$

Entretanto, por tratar-se de uma máquina rotativa, deve-se levar em consideração a velocidade do rotor, uma vez que a tensão induzida em suas barras depende dessa velocidade. Portanto, torna-se necessário saber qual o escorregamento do rotor, representado em (4).

$$s = \frac{\omega_{sinc} - \omega_m}{\omega_{sinc}} \quad (4)$$

onde

s é o escorregamento do motor;

ω_{sinc} é a velocidade angular síncrona;

ω_m é a velocidade angular mecânica.

Assim, (3) pode ser reescrita por (5) considerando o escorregamento, que influencia diretamente na tensão induzida e reatância de dispersão do rotor (que é dependente da frequência).

$$I_R = \frac{sE_{R0}}{(R_R + jsX_{R0})} \quad (5)$$

ou ainda

$$I_R = \frac{E_{R0}}{(R_R/s + jX_{R0})} \quad (6)$$

Por fim, para obter-se o circuito elétrico equivalente final do motor de indução deve-se referir a corrente de rotor, a resistência de rotor e a reatância de dispersão do rotor, apresentado por (7), (8), (9) e (10), para o primário.

$$I_2 = \frac{I_R}{a_e f} \quad (7)$$

$$E_1 = a_e f E_{R0} \quad (8)$$

$$R_2 = a_{ef}^2 R_R \quad (9)$$

$$X_2 = a_{ef}^2 X_{R0} \quad (10)$$

A Figura 2 apresenta o circuito elétrico equivalente final do motor de indução trifásico, por fase, formado pelos cinco parâmetros elétricos da máquina.

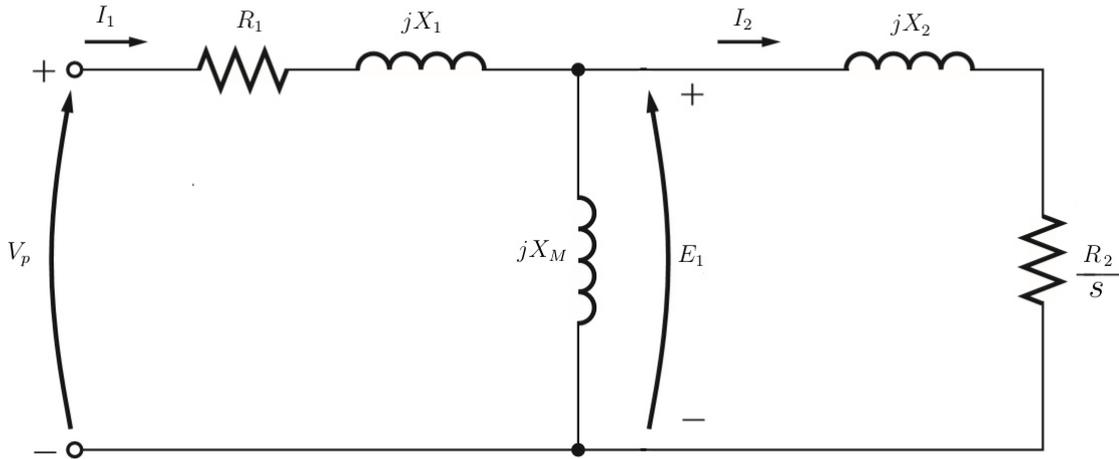


Figura 2: Circuito elétrico equivalente final do MIT

Fonte: Adaptado de Krause et al. (2013)

O circuito elétrico equivalente pode ser simplificado ainda por uma impedância equivalente, calculando-se o paralelo entre os ramos de magnetização e do rotor, e o resultado somado ao equivalente do estator, de acordo com (11).

$$Z_{eq} = (R_1 + jX_1) + \frac{(R_2/s + jX_2)jX_M}{R_2/s + j(X_2 + X_M)} \quad (11)$$

A Figura 3 mostra o circuito elétrico equivalente em sua forma mais simplificada, representado matematicamente em (12).

$$V_p = I_1 Z_{eq} \quad (12)$$

ou ainda

$$I_1 = \frac{V_p}{Z_{eq}} \quad (13)$$

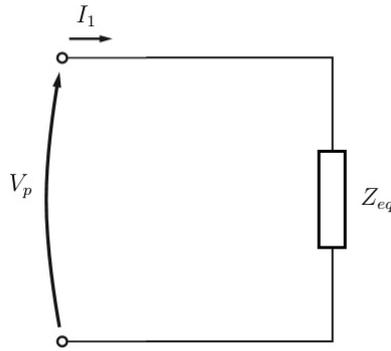


Figura 3: Circuito simplificado do MIT

Fonte: Autoria própria

Dessa forma, a modelagem apresentada neste capítulo é essencial para recriar o sinal de corrente que será comparado com a corrente experimental do presente trabalho. Utilizando-se a tensão de estator experimental como entrada para o modelo apresentado na Figura 3, estimam-se os parâmetros por meio do DE e obtém-se uma corrente estimada, que é comparada ao sinal de corrente experimental.

2.3 PSEUDO-PARÂMETROS DO MIT

Por meio dos sinais de tensão e corrente apresentados é possível calcular o valor, em módulo e fase, da impedância equivalente do sistema. No entanto, esse valor pode ser determinado por inúmeras combinações dos parâmetros do circuito equivalente, pois o modelo não apresenta todo o comportamento do MIT, o que permite que o DE encontre mais de uma solução satisfatória para o problema.

Para que haja a estimação efetiva dos parâmetros, somente com a curva de corrente como sinal de entrada, utiliza-se também o período de transitório da máquina, para que seja analisado todo o seu comportamento (BOUDISSA; BOUNEKHLA, 2012; GUEDES, 2015).

Para ilustrar tal afirmação, a Figura 4 apresenta uma comparação entre os sinais de corrente simulado e estimado de um motor do *Simulink*[®], com os períodos em regime transitório e permanente. Os parâmetros foram estimados a partir do circuito elétrico equivalente e, portanto, utilizando somente o período de regime permanente.

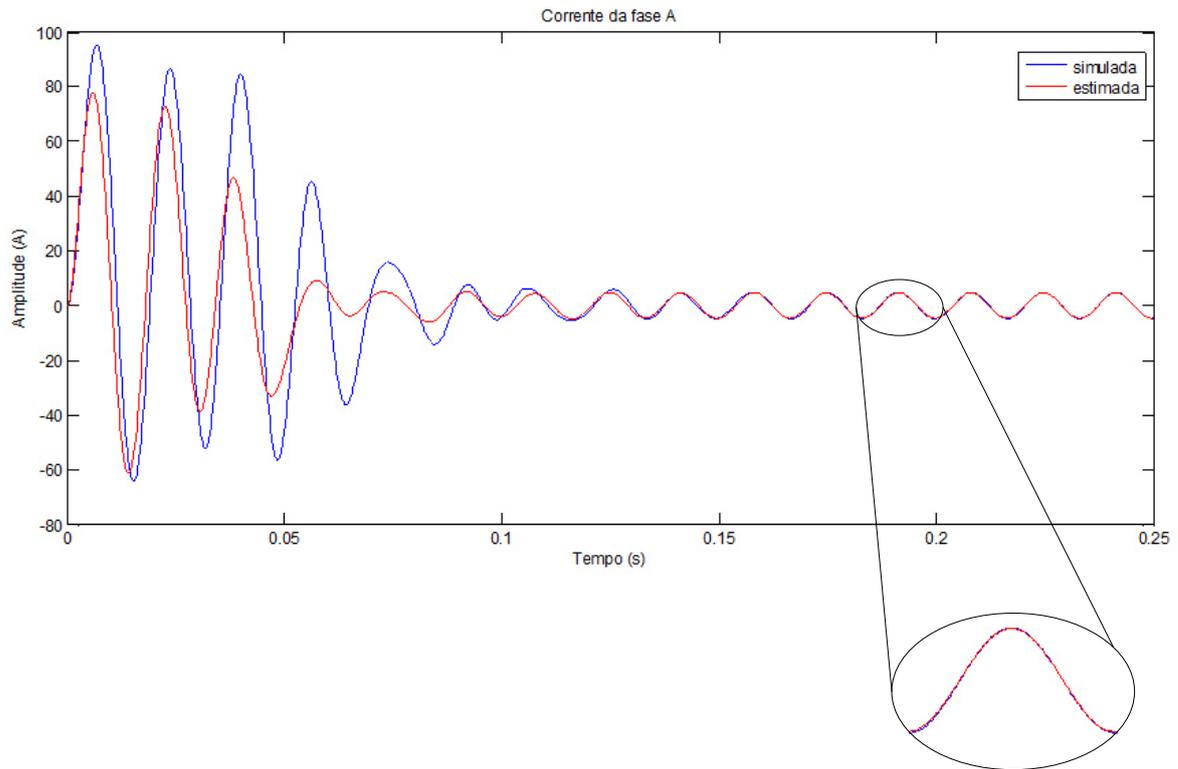


Figura 4: Comparação entre correntes estimada e experimental

Fonte: Autoria própria

A Tabela 1 apresenta o valor dos parâmetros estimados, junto aos parâmetros reais da máquina.

Tabela 1: Parâmetros estimados em um motor de 5HP do Simulink®

Modelo do motor: 5HP 460V 60Hz 1750 RPM					
	R_1	L_1	R_2	L_2	L_M
Simulado	1,115 Ω	0,00597 H	1,083 Ω	0,00597 H	0,2037 H
Estimado	2 Ω	0,0058 H	1,832 Ω	0,0032 H	0,2079 H
Diferença	+ 79,37 %	- 2,85%	+ 69,16%	- 46,43%	+ 2,06%

Analisando a Tabela 1 e a Figura 4, observa-se que, embora alguns parâmetros apresentem grandes diferenças (superior a 45%), houve uma aproximação satisfatória no regime permanente. Dessa forma, os parâmetros estimados nesse trabalho podem ser considerados pseudo-parâmetros do circuito elétrico equivalente, pois representam o comportamento da máquina no seu regime permanente mas não necessariamente em todo o seu domínio de operação. Os pseudo-parâmetros serão tratados no decorrer do texto apenas como parâmetros do circuito elétrico equivalente por questão de simplificação.

2.4 CONCLUSÃO DO CAPÍTULO

O modelo do MIT será utilizado junto ao DE para determinar os parâmetros do circuito elétrico equivalente, e então realizar a identificação da falha mediante análise do comportamento da indutância de magnetização, que será explicado detalhadamente no Capítulo 4.

O Capítulo 3 apresenta o funcionamento do DE, aplicado para a identificação de falhas de curto-circuito de estator.

3 EVOLUÇÃO DIFERENCIAL

3.1 INTRODUÇÃO

Problemas complexos de otimização global são comuns na comunidade científica e buscam encontrar uma solução que otimize determinado sistema. Tais sistemas consistem em um conjunto de objetivos que devem ser maximizados (ou minimizados), atendendo um conjunto de restrições (TALBI, 2009) .

Por sua complexidade, muitas vezes não é possível a determinação da solução exata para o sistema por meio de métodos matemáticos. Entretanto, pode-se obter um conjunto de boas soluções que satisfaça os objetivos e restrições do problema.

Nesse cenário, os sistemas inteligentes têm se destacado para a resolução de problemas, baseados em características e comportamentos biológicos e neurobiológicos (RAO, 2009). Entre os principais sistemas inteligentes destacam-se as RNA (HAYKIN, 1998), a lógica *Fuzzy* (ROSS, 2009) e os algoritmos bio-inspirados (YANG et al., 2013).

Os algoritmos bio-inspirados fundamentam-se nos conceitos de adaptação, aprendizado, auto-organização, competição e cooperação de um conjunto de soluções, a fim de selecionar qual delas melhor se adapta ao sistema (TALBI, 2009). Além disso, possuem como característica comum sua generalização para resolução de problemas, pois um mesmo algoritmo pode ser utilizado para vários sistemas, apenas com pequenos refinamentos aos objetivos e as restrições desejadas (BLUM; ROLI, 2003).

Algoritmos como PSO (EBERHART; SHI, 2001), colônia de formigas (ACO - do inglês *Ant Colony Optimization*) (SHAUKAT et al., 2014), vagalumes (FA - do inglês *Firefly Algorithm*) (YANG, 2010) e colônia de abelhas (ABC - do inglês *Artificial Bee Colony*) (KARABOGA et al., 2014) são classificados como algoritmos de inteligência coletiva.

Outra classe muito utilizada em problemas de engenharia são os AE, baseados na Teoria de Evolução e Genética, dos quais destacam-se o algoritmo de Evolução Diferencial

(DE) e os Algoritmos Genéticos (AG).

Este capítulo introduz o princípio de funcionamento dos AE, com ênfase para o DE, uma vez que a proposta desse trabalho é a utilização do mesmo para a estimação dos parâmetros do MIT em regime permanente, a fim de identificar falhas de curto-circuito de estator.

3.2 PRINCÍPIO DE FUNCIONAMENTO

O princípio de funcionamento de um AE é baseado na teoria de evolução. Analogamente, a população composta pelas soluções candidatas é manipulada a cada iteração para melhorar o grau de aptidão dos indivíduos dessa população em relação ao seu ambiente, ou seja, a função objetivo (SANCHES, 2013).

Para entender o funcionamento do DE é necessário saber alguns componentes do sistema evolutivo (RUTKOWSKI, 2008), como:

- População de indivíduos: organismos genéticos que fazem parte do processo evolutivo, ou seja, as soluções candidatas, também chamadas de cromossomos;
- *Fitness*: habilidade de um indivíduo para sobreviver ou reproduzir-se, ou seja, grau de aptidão da solução candidata em relação a FO;
- Seleção: os indivíduos mais adaptados sobrevivem e perpetuam;
- Mutação: modificação do material genético, podendo introduzir características distintas das existentes nos demais indivíduos, o que aumenta a diversidade da população e evita que o algoritmo fique preso a mínimos locais;
- Cruzamento ou *crossover*: método de reprodução que consiste na transferência de material genético dos ancestrais aos sucessores.

O DE foi desenvolvido por Price et al. (2006) e é iniciado criando-se a primeira população, que corresponde a um conjunto de soluções obtidas aleatoriamente a partir de um espaço de busca limitado.

Na sequência, todas as soluções candidatas são avaliadas, inserindo-as no processo de otimização e verificando seu *fitness*, a partir do valor da Função Objetivo (FO). Após calcular o *fitness* inicia-se um processo de mutação e cruzamento, respectivamente, para

então reavaliar o grau de aptidão das novas respostas. Esse processo se repete até que a solução desejada seja encontrada.

No processo de mutação, dois ou mais indivíduos da população inicial são selecionados aleatoriamente, conforme apresentado na Figura 5. Para o caso de seleção de dois indivíduos, utilizado no presente trabalho, determina-se a diferença vetorial entre ambos, aplicando-se a essa diferença um fator de ponderação, cujo resultado é somado ao primeiro indivíduo da população inicial, conforme apresentado em (14). O cromossomo que sofre a mutação, o primeiro indivíduo, é denominado *target vector* e também será utilizado no processo de cruzamento. Todos os indivíduos da população são, ao menos uma vez, *target vector*.

$$v_{i,G+1} = x_{r_1,G} + F \cdot (x_{r_3,G} - x_{r_2,G}) \quad (14)$$

onde

$v_{i,G+1}$ é o elemento i da população mutada;

F é o fator de ponderação aplicado a diferença vetorial;

$x_{r_1,G}$, $x_{r_2,G}$ e $x_{r_3,G}$ são os cromossomos sorteados aleatoriamente da população antes da mutação.

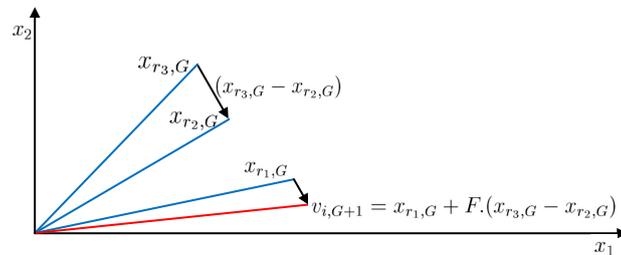


Figura 5: Processo vetorial de mutação do DE

Fonte: Autoria própria

O fator de ponderação corresponde a um valor que, tipicamente, varia entre 0 e 1. Quanto mais próximo de zero for esse fator, menor será a perturbação da mutação em relação ao *target vector*, ao passo que, quanto mais próximo de um, maior será a perturbação, evitando que as soluções fiquem presas em regiões locais.

Seguinte a mutação ocorre o processo de cruzamento entre a população mutada e o população inicial. Nesse processo, o *target vector* é cruzado com o seu vetor modificado, a fim de gerar um cromossomo com melhor aptidão. Para isso, cria-se um vetor aleatório,

entre 0 e 1, com o mesmo número de elementos dos cromossomos. Então, define-se uma taxa de cruzamento, também um valor típico entre 0 e 1, que é a probabilidade de cruzamento de um indivíduo de determinada população. Quando o valor atribuído ao gene do cromossomo for inferior a taxa de cruzamento, seleciona-se o elemento da população mutada, caso contrário, seleciona-se o do *target vector*, conforme apresentado na Figura 6.

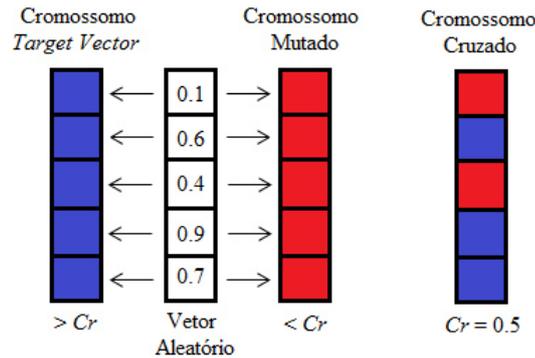


Figura 6: Processo de *crossover* do DE

Fonte: Autoria própria

Finalizado o processo de cruzamento, a nova população é avaliada pela função objetivo para análise do grau de aptidão de cada cromossomo. Esse processo não garante que o cromossomo após sofrer a mutação seja melhor do que o *target vector*. Para isso, compara-se então o cromossomo *target vector* com o cromossomo correspondente que sofreu a mutação e seleciona-se, entre os dois, o que tiver maior grau de aptidão, conforme apresentado na Figura 7.

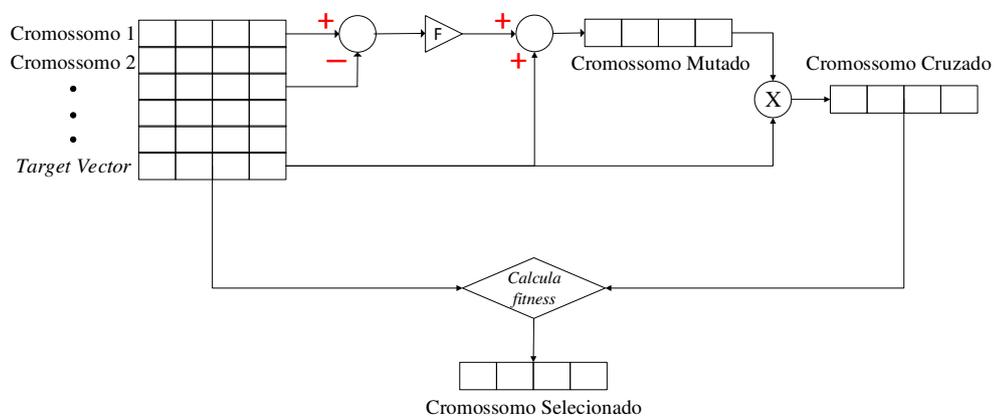


Figura 7: Processo de mutação, cruzamento e seleção do *target vector*

Fonte: Autoria própria

Se houver então alguma resposta que satisfaça o critério de parada o algoritmo é finalizado e a resposta fornecida ao usuário. Caso contrário, a população cruzada passa a ser a nova população inicial e o processo reinicia, até que uma resposta seja encontrada. A Figura 8 apresenta um fluxograma de funcionamento do DE.

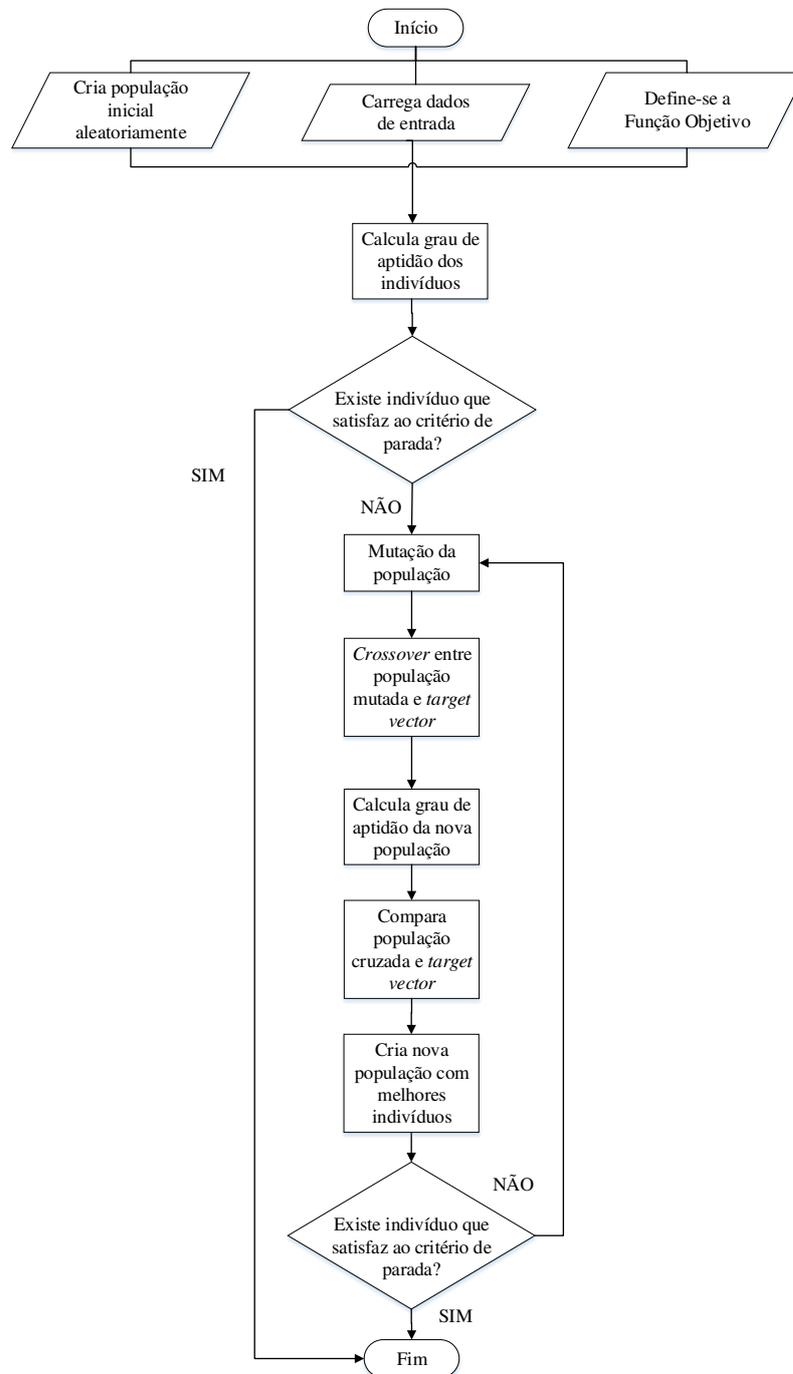


Figura 8: Funcionamento do DE

Fonte: Autoria própria

A principal diferença entre o AG e o DE é o operador de mutação, pois no AG atribui-se uma taxa de mutação, o que significa que apenas uma porcentagem dos cromossomos sofrem mutação, enquanto que no DE todos os indivíduos são submetidos a esse processo. Além disso, a forma de mutação entre ambos é diferente. No AG os cromossomos são mutados individualmente e no DE a mutação de cada cromossomo acontece com pelo menos outros dois, evitando que a solução fique presa em uma região de mínimo local (OUYANG; PANO, 2015).

O cruzamento também tem grande importância para evitar que a solução fique presa em uma região de mínimo local, pois no DE esse processo acontece de forma aleatória entre dois indivíduos, enquanto que no AG são estabelecidos pontos de corte para cruzamento de dois indivíduos. A Tabela 2 apresenta as principais diferenças nos processos de seleção, cruzamento e mutação entre o AG e o DE.

Tabela 2: Comparação entre AG e DE (DAS; SUGANTHAN, 2011)

	Principais diferenças entre AG e DE	
	Algoritmo Genético	Evolução Diferencial
Mutação	- alguns indivíduos	- todos indivíduos
	- alteração aleatória do cromossomo	- diferença vetorial entre cromossomos
Cruzamento	- 2 cromossomos geram 2 cromossomos	- 2 cromossomos geram 1 cromossomo
	- cruzamento por pontos de corte	- cruzamento randômico
Seleção inicial	- cromossomos mais aptos participam do cruzamento	- todos tem a mesma chance no processo
Seleção final	- somente cromossomos alterados podem ser selecionados	- melhores cromossomos são selecionados, independente de sofrer alteração
Tempo	processamento mais lento	processamento mais rápido

3.3 ALGORITMO PROPOSTO

No presente trabalho, o DE é utilizado na estimação dos parâmetros do motor de indução.

A partir da curva de entrada de corrente e de tensão, cria-se uma população inicial aleatória com os parâmetros do circuito elétrico equivalente do MIT, apresentados na Figura 2. Em seguida, esses parâmetros são inseridos ao modelo do circuito elétrico equivalente do MIT para gerar uma curva de corrente que será comparada com a curva inicial.

Assim, o objetivo da aplicação do DE no trabalho é minimizar a FO, que consiste na diferença entre a curva experimental e a curva estimada de corrente, para identificar os parâmetros do MIT. A comparação é feita através do método dos mínimos quadrados, apresentado em (15).

$$FO = \frac{1}{2} \sum_{j=1}^{n_{\text{pontos}}} \frac{(I_{\text{entrada}_j} - I_{\text{estimada}_j})^2}{n_{\text{pontos}}} \quad (15)$$

Tanto a curva de entrada quanto a estimada possuem a mesma quantidade de pontos, 258 por período, distribuídos igualmente no mesmo intervalo de tempo.

Tais dados são usados no DE, conforme apresentado na Figura 8, até que os parâmetros do MIT sejam determinados. A Figura 9 apresenta um esquemático da utilização do DE.

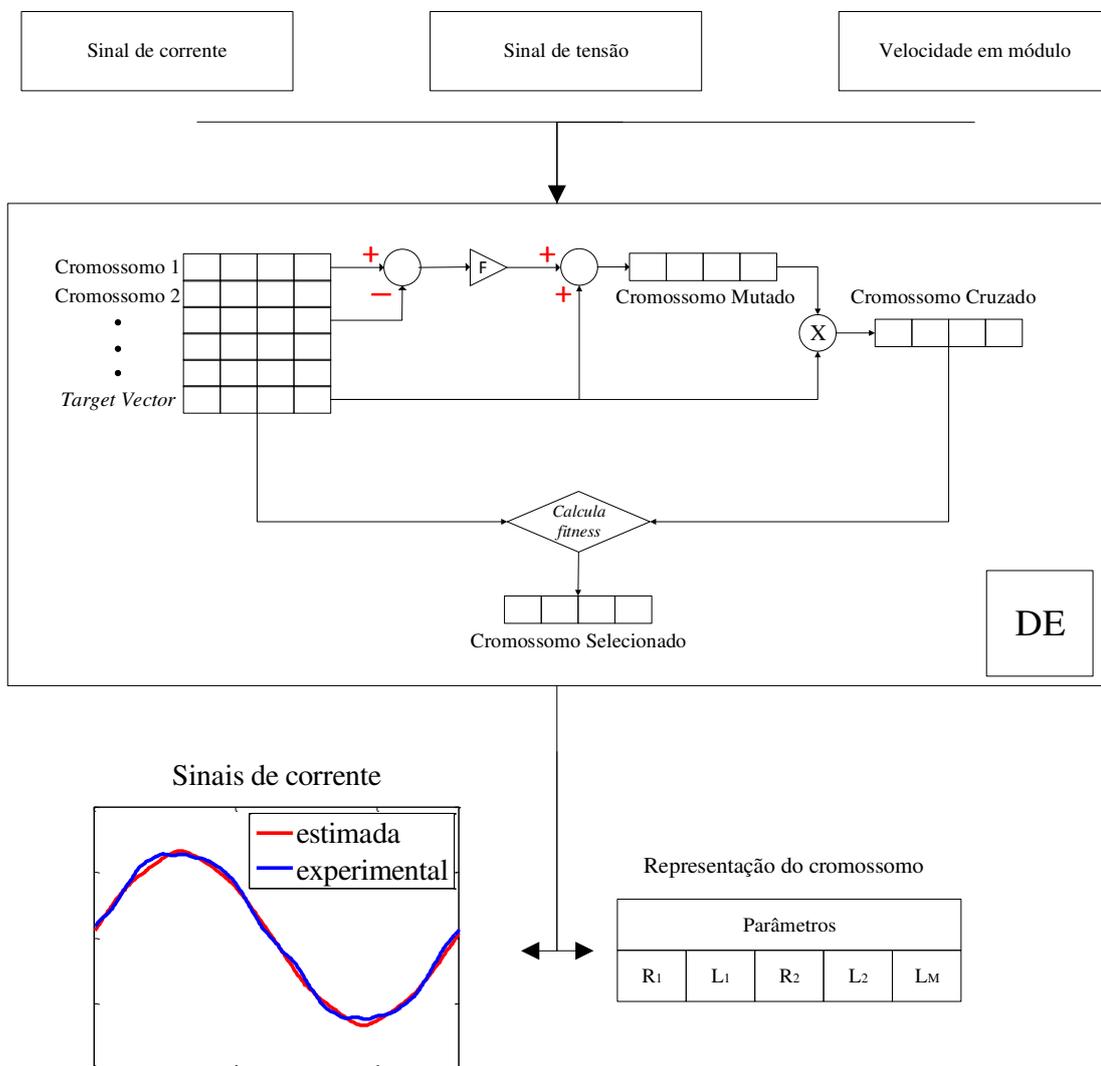


Figura 9: Diagrama esquemático do algoritmo proposto

Fonte: Autoria própria

3.4 CONCLUSÃO DO CAPÍTULO

Neste capítulo foi apresentado o princípio de funcionamento do DE que foi utilizado no presente trabalho. O DE é fundamental para o desenvolvimento do trabalho, uma vez que este é capaz de estimar os parâmetros do circuito elétrico equivalente, a partir de sinais de tensão, corrente e valor absoluto de velocidade, utilizando uma modelagem em regime permanente.

O Capítulo 4 apresenta a metodologia utilizada para a identificação de falhas, explicando todo o processo de aquisição de sinais com e sem falhas, ou seja, todo o processo anterior ao DE e, além disso, como foi realizada a identificação da falha a partir dos parâmetros estimados pelo DE.

4 METODOLOGIA

4.1 INTRODUÇÃO

As características construtivas do MIT fazem dele o motor mais utilizado no setor industrial. Entretanto, estes também sofrem deterioração naturais ou por exposições a ambientes inadequados e, por esse motivo, o estudo de falhas em MIT é muito importante para minimizar danos à máquina e ao processo produtivo.

Conforme mencionado no Capítulo 1, as falhas de estator representam 37% dos defeitos em máquinas elétricas (ZAREI et al., 2014). Para analisar o comportamento das falhas e seu efeitos são desenvolvidos estudos em laboratório que simulam o ambiente industrial, com diversas condições de operação e situações de falhas, com o objetivo de criar métodos eficientes de diagnósticos de falhas quando aplicados em condições reais.

Nesse sentido, esse trabalho propõe um método para detecção de falhas de estator por meio de sinais de corrente, tensão e módulo da velocidade - todos em regime permanente, o que permite o seu monitoramento *online*. A metodologia foi testada e validada utilizando-se um banco de dados composto por ensaios em laboratório, simulando várias condições de operação e falhas. Este banco de dados foi usado em Lopes (2016), Bazan (2016), Broniera (2014), Godoy (2016) e Palácios (2016).

4.2 REPRODUÇÃO DE DEFEITOS DE ESTATOR NOS MOTORES

Os parâmetros e características dos motores utilizados no presente trabalho são apresentados na Tabela 3. As falhas de curto-circuito no enrolamento do estator resultam do dano causado a isolação dos condutores da bobina, que podem falhar quando submetidos a sobreaquecimento, vibração ou sobretensão. Isso leva a um curto-circuito entre as espiras, fazendo com que a corrente de falta circule pelas espiras danificadas. Com o efeito térmico da corrente de falta, o isolamento se degrada progressivamente, aumentando significativamente a amplitude da referida corrente, podendo levar a uma falha irreparável

(RIERA-GUASP et al., 2015).

Tabela 3: Parâmetros e características dos MIT utilizados nos experimentos

Item	Motor1	Motor2	Motor3
Marca	WEG	WEG	WEG
Potência	1 CV	1 CV	2 CV
Alimentação	3ϕ	3ϕ	3ϕ
Frequência	60 Hz	60 Hz	60 Hz
Velocidade Nominal	1730 rpm	1730 rpm	1750 rpm
I_p/I_n	8,0	6,6	7,1
Isolação	Tipo F	Tipo F	Tipo F
Fator de Serviço	1,15	1,15	1,15
Fator de potência	0,80	0,81	0,78
Rendimento	82,5%	80,5%	84,2%

O curto-circuito entre as bobinas altera a simetria da corrente do estator para uma forma assimétrica. Isso ainda permite que a máquina continue em operação, porém com torque reduzido (DLAMINI; BARENDSE, 2012).

Para a reprodução das falhas, o estator foi rebobinado conforme a metodologia de Suetake (2012), e desenvolvido por Broniera (2014), possuindo 6 bobinas isoladas com verniz e respeitando as medidas originais e classe de isolação do MIT, permitindo que várias derivações de diferentes bobinas fossem construídas. Essas derivações permitiram ensaios de 1% 3%, 5%, 10%, 15% e 20% de curto-circuito no estator. A Figura 10 ilustra os *taps* adicionais inseridos no enrolamento do motor de indução.



Figura 10: Imagem ilustrativa dos *taps* de derivação

Fonte: Lopes (2016)

Visando o controle sobre a falha, foi proposto um método de aquisição automatizado em Broniera (2014), onde foram realizadas adequações eletromecânicas, as quais

permitiram executar o fechamento das derivações para emular as falhas de curto-circuito, como apresentado na Figura 11.

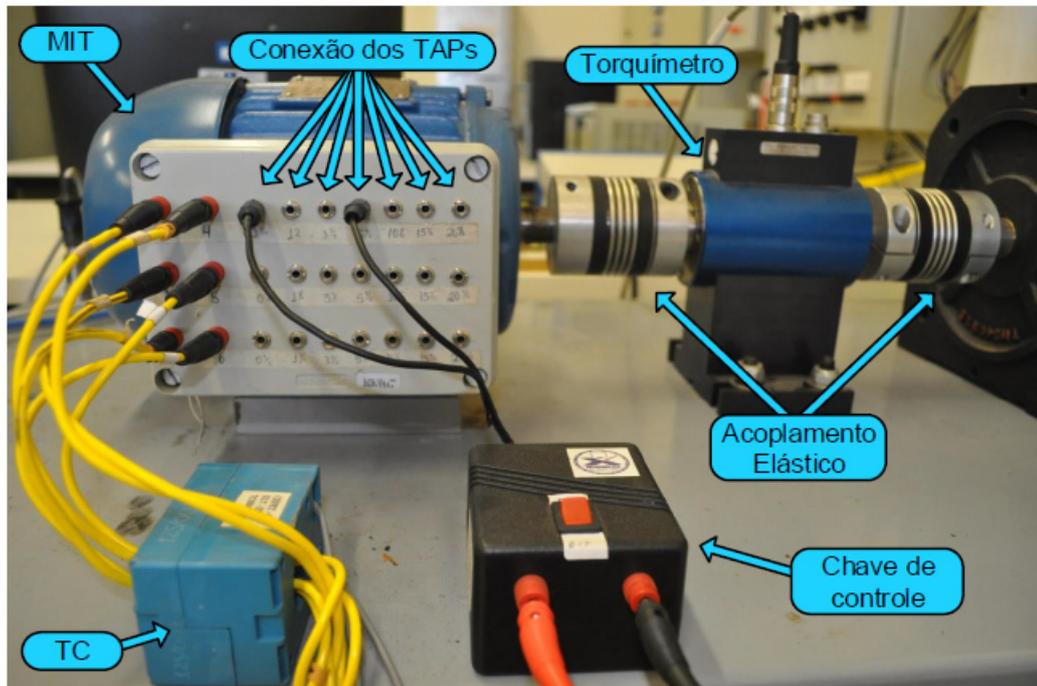


Figura 11: Disposição dos *taps* na caixa de ligação do MIT rebobinado
Fonte: Lopes (2016)

Além das falhas de estator, existem também as falhas de rotor e rolamento. No entanto, como o foco desse trabalho consiste na identificação de falhas em estator, os processos para a reprodução de outras falhas não serão abordados neste trabalho. Entretanto as mesmas são descritas em Broniera (2014), Lopes (2016), Palácios (2016).

4.3 BANCADA EXPERIMENTAL

A bancada utilizada, apresentada na Figura 12, foi projetada por Goedtel (2007) para o monitoramento de tensões, correntes, vibrações, torque e velocidade de um motor de indução trifásico. O condicionamento de sinal dos sensores *Hall* faz com que as tensões e correntes de fase sejam repassadas às entradas analógicas da placa de aquisição de dados (DAQ). Por meio da interface de comunicação USB da DAQ com o computador, as informações são adquiridas e armazenadas com o uso do *software* MATLAB[®], com uma taxa de aquisição de 25000 pontos por segundo de amostragem.

Esta dispõe de um motor de indução acoplado a um Gerador de Corrente Contínua (GCC) de 2kW de potência, 250V de tensão nominal de campo e 250V de tensão nominal

de armadura - que faz a imposição do conjugado no eixo do motor -, o qual está acoplado a um torquímetro de dupla faixa de atuação com sensor de velocidade integrado. O dispositivo da marca *Kistler*, modelo 4503A50W, permite a leitura de sinais analógicos ou digitais até $50Nm$ e $7000rpm$. A mesma estrutura de ensaio foi utilizada nos trabalhos desenvolvidos por Palácios et al. (2016), Godoy et al. (2015), Palácios et al. (2015), Santos et al. (2014), entre outros.

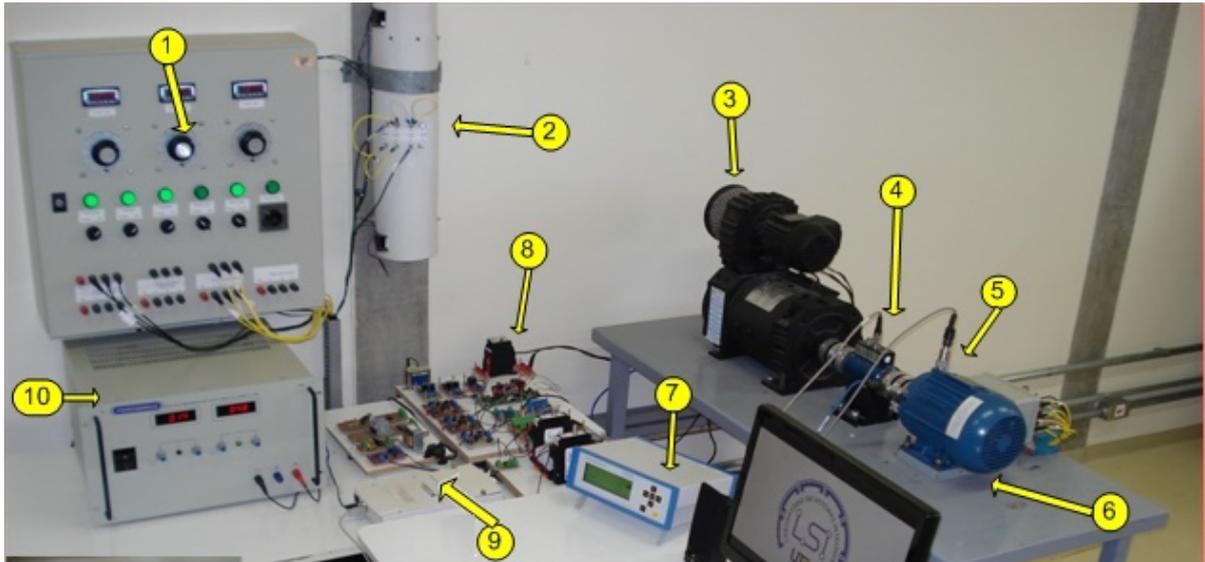


Figura 12: Bancada experimental do laboratório de Sistemas Inteligentes da UTFPR

A bancada apresentada na Figura 12 é composta por: (1) Variadores de Tensão, (2) Carga da Máquina CC, (3) Gerador de Corrente Contínua, (4) Torquímetro, (5) Sensor de Vibração, (6) Motor de Indução, (7) *Display* do Torquímetro, (8) Contator para Geração Automática de Curto-Circuito de Estator, (9) Placa de Aquisição, (10) Fonte CC.

4.4 BANCO DE DADOS

A identificação da falha por meio do DE utiliza os sinais de corrente e tensão como sinais de entrada. Além disso, também é necessário um método que informe o módulo da velocidade para determinar o escorregamento, presente no circuito elétrico equivalente do MIT, conforme apresentado em (4), no Capítulo 2. Atualmente existem diversos estudos que apresentam alternativas aos sensores de velocidade - em alguns casos mais caros que o próprio MIT - e são capazes de realizar a medição da mesma com baixo custo, como no trabalho de Graciola et al. (2016).

Nesse trabalho foram utilizadas as correntes e suas respectivas tensões do MIT em situações sem falhas e com falhas para diferentes níveis de curto, por motor, conforme apresentado na Tabela 4. Os diferentes níveis de curto por motor devem-se aos *taps* inseridos nos motores.

Tabela 4: Níveis de falha aplicados aos motores

Distribuição das falhas			
Nível de falha	Motor 1	Motor 2	Motor 3
Sem falha	X	X	X
3%	X	X	X
5%	X	X	X
7%		X	
10%	X		X
15%	X		
20%	X		

Para cada uma dessas situações foram aplicados 6 níveis de conjugado de carga, variando de 10% a 150% do torque nominal. Além disso, também foram considerados 9 níveis de desequilíbrio de tensão, conforme apresentado na Tabela 5.

Tabela 5: Níveis de desequilíbrio de tensão aplicado aos MIT

Níveis de desequilíbrio de tensão					
Fase A	-2%	-4%	-6%	-8%	-10%
Fase B	+2%	+4%	+6%	+8%	
Fase C	-2%	-4%	-6%	-8%	

Nesse caso, os desequilíbrios relacionados a fase A foram aplicados individualmente, enquanto que os desequilíbrios das fases B e C foram aplicados simultaneamente, para simular diversas condições de operação. Por exemplo, para a fase A aplicou-se somente -2% de desequilíbrio para realização de um ensaio. Já quando realizou-se um segundo ensaio, aplicou-se +2% para fase B e, ao mesmo tempo, -2% para a fase C.

Outra consideração fundamental a ser feita é que as simulações de falha de curto-circuito no estator foram realizadas apenas na fase A, ou seja, nas fases B e C não foram aplicados nenhum nível de curto-circuito.

Assim, considerando-se os níveis de falha combinados aos níveis de conjugado de carga e desequilíbrio de tensão, a Tabela 6 apresenta a quantidade de situações diferentes, por motor, analisadas nesse trabalho.

Tabela 6: Condições de operação dos MIT utilizados

Condições de operação por motor			
Quantidade de níveis	Motor 1	Motor 2	Motor 3
Falha	6	4	4
Conjugado de carga	6	6	6
Desequilíbrio de tensão	10	10	10
Total	360	240	240

A partir do banco de dados, o processo para identificação da falha se divide em três partes: tratamento do sinal, utilização do DE e análise dos parâmetros estimados, que serão descritas nas Subseções 4.4.1, 4.4.2 e 4.4.3.

4.4.1 TRATAMENTO DE DADOS

O primeiro passo para iniciar a identificação da falha é o tratamento do sinal. Como descrito na Seção 4.3, foi utilizada uma taxa de aquisição de 25000 pontos por segundo de amostragem, caracterizando um sinal discreto.

No Capítulo 2, a modelagem utilizada nesse trabalho descreve o comportamento do motor de indução trifásico a partir da análise do circuito equivalente monofásico. Assim, conectando-se os três circuitos monofásicos em estrela, tem-se um motor de indução trifásico.

Entretanto, os experimentos para criação do banco de dados foram realizados com o motor em configuração delta. Dessa forma, o primeiro tratamento do sinal é transformar a corrente de estator de linha para fase.

Na sequência, por tratar-se de um sinal em regime permanente com comportamento constante, optou-se por extrair apenas um período dos sinais, a fim de acelerar o processo para identificação da falha, uma vez que o número de pontos de cada amostra ficaria bastante reduzido, porém não prejudicaria o resultado.

O ponto de corte do sinal foi definido pelo máximo da tensão da fase A, uma vez que a alimentação não é influenciada pela falha, mas pelo desequilíbrio, quando aplicado.

A Figura 13 apresenta um fluxograma do tratamento de sinais descrito, ou seja, a transformação da corrente de linha para corrente de fase e a extração de dois períodos do sinal para estimação de parâmetros.

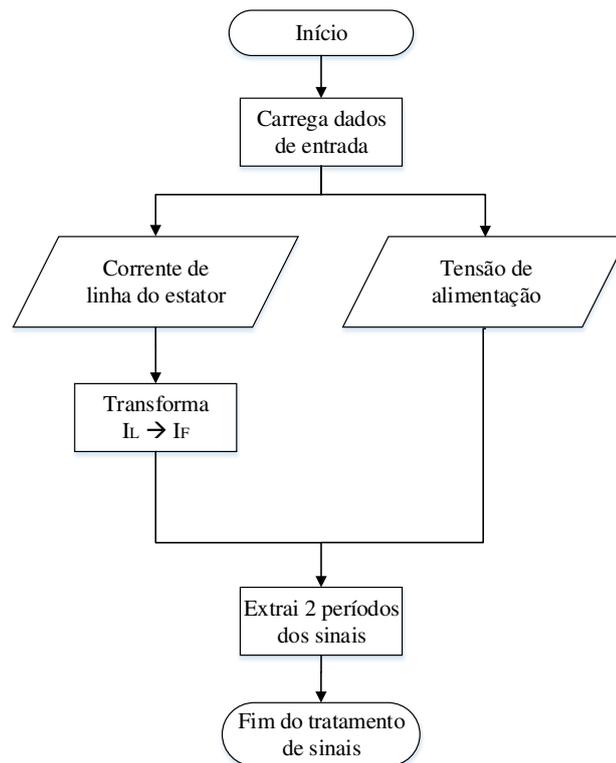


Figura 13: Fluxograma de tratamento do sinal

Fonte: Autoria própria

4.4.2 APLICAÇÃO DO DE

Finalizado o tratamento dos dados, inicia-se o processo com o DE.

Como as falhas estudadas nesse trabalho são as de curto-circuito de estator, optou-se por analisar e estimar os parâmetros de estator e do ramo de magnetização, ou seja, R_1 , L_1 e L_M . Dessa forma, os parâmetros do rotor, R_2 e L_2 , foram fixados de acordo com os valores estimados para o motor operando com tensões equilibradas e sem falhas.

Para que fosse possível fixar os valores dos parâmetros do rotor foi necessário, primeiramente, a utilização do DE para estimar todos os parâmetros do MIT, com dados experimentais. Então, foram utilizados os 6 sinais sem falhas, com tensões equilibradas, variando-se somente o conjugado de carga para estimação de todos os parâmetros do circuito elétrico equivalente do MIT, a fim de criar uma tabela de referência de vetores para cada motor, possibilitando fixar então os parâmetros do rotor. Assim, na Tabela 7 são apresentados os parâmetros de referência para o Motor 1.

Tabela 7: Parâmetros estimados por meio do DE para o Motor 1

Torque	Parâmetros Motor 1					
	R_1	L_1	R_2	L_2	L_M	ω_m
10%	14,2732	0,1142	3,3634	0,2905	0,3580	187,4518
25%	11,4201	0,0731	2,5599	0,3310	0,5024	186,7695
50%	9,5709	0,0512	2,2317	0,2702	0,9738	185,4723
75%	10,5151	0,1121	2,1006	0,1331	3,1087	184,1083
100%	13,1744	0,0902	2,7152	0,0875	3,0791	182,4320
150%	11,2809	0,0599	3,1435	0,07184	2,9956	180,9347

Do mesmo modo, a Tabela 8 apresenta os parâmetros de referência para o Motor 2.

Tabela 8: Parâmetros estimados por meio do DE para o Motor 2

Torque	Parâmetros Motor 2					
	R_1	L_1	R_2	L_2	L_M	ω_m
10%	14,2454	0,0146	2,0286	0,2826	0,4714	187,5357
25%	12,0294	0,0245	2,1134	0,2979	0,6222	186,5701
50%	8,6228	0,0369	2,1108	0,2085	1,3727	185,1559
75%	14,7967	0,0956	2,1474	0,0964	3,3126	183,4765
100%	12,0767	0,0661	2,8674	0,0755	3,0447	181,7095
150%	11,3192	0,0478	3,2827	0,0596	3,0507	179,7583

Por fim, a Tabela 9 os valores de referência para o Motor 3.

Tabela 9: Parâmetros estimados por meio do DE para o Motor 3

Torque	Parâmetros Motor 3					
	R_1	L_1	R_2	L_2	L_M	ω_m
10%	17,4656	0,1632	9,3718	0,2870	0,1426	187,7449
25%	15,2660	0,0419	2,2402	0,2734	0,2923	186,8433
50%	12,0092	0,0116	2,0648	0,1414	0,3653	185,5636
75%	6,9886	0,0054	2,0170	0,0835	0,4424	184,2214
100%	4,1174	0,0049	2,0067	0,0581	0,5448	182,7553
150%	3,0198	0,0058	2,0056	0,0557	0,6432	181,8633

Observa-se que há uma diferença paramétrica para as situações de torque, que ocorre pois os parâmetros são estimados de acordo com o modelo elétrico equivalente do MIT, ou seja, sem considerar o período de transitório e, portanto, sem o seu comportamento completo, como explicado na Seção 2.3.

Para utilização do DE foi necessário estabelecer alguns critérios, tais como intervalo de busca, fator de ponderação da mutação, taxa de cruzamento e critério de parada.

A população é formada pelos vetores de parâmetros que serão estimados. Então, cada um desses é limitado por um espaço de busca, como apresentado na Tabela 10. Conforme descrito no início do capítulo, após a criação da tabela de referência, os parâmetros do rotor são fixados, o que concentra a busca dos demais parâmetros em uma região, permitindo assim a identificação da falha pela análise da variação de parâmetro. Dessa forma, o espaço de busca dos parâmetros do rotor só são utilizados para a criação da tabela de referência.

Tabela 10: Espaço de busca utilizado no DE

Parâmetro	Espaço de busca
R_1 (Ω)	[2 20]
R_2 (Ω)	[2 20]
L_1 (H)	[0,001 0,5]
L_2 (H)	[0,001 0,5]
L_M (H)	[0,01 5]

O fator de ponderação aplicado a mutação é, geralmente, um valor entre 0 e 1. Quanto mais próximo de 1, maior é a perturbação que acontecerá com a população, evitando que o algoritmo prenda-se a uma região local de busca. Para o trabalho foram utilizados dois valores para F . O primeiro valor para F foi 0,9 para que ocorresse grande perturbação na população, a fim de encontrar várias regiões de busca inicialmente. Quando o erro atingiu um valor inferior a 0,1 (10%), o valor de F foi reduzido a 0,2 para concentrar a busca na região em que os parâmetros geram um erro inferior a 10%.

Do mesmo modo que o fator de ponderação, a taxa de cruzamento tipicamente assume um valor entre 0 e 1, e corresponde a probabilidade de selecionar o gene do cromossomo mutado ou do *target vector*. Nesse caso, quanto mais próximo de 1, maior será a probabilidade de selecionar genes mutados e, quanto mais próximo a 0, maior a probabilidade de selecionar genes do *target vector*. Assim, optou-se por definir uma taxa de cruzamento fixa, no valor de 0,5 para garantir a mesma probabilidade de selecionar genes do cromossomo mutado e do *target vector*.

Finalmente, estabeleceu-se o critério de parada. A fim de criar um método rápido e eficiente, foram estabelecidos 3 critérios de parada. O primeiro critério estabelecido foi um erro inferior a 0,01 (1%), ou seja, quando o valor da FO é inferior a 1%. O segundo critério estabelecido foi um erro inferior a 0,08 (8%). Nesse caso, quando o erro atinge um valor inferior a 0,08 inicia-se um contador, incrementado quando o erro anterior e o atual são o mesmo, ou seja, a diferença entre ambos é 0. Caso o contador chegue a 10 antes de o primeiro critério ser atingido o algoritmo é encerrado. Por fim, o terceiro e último critério

determina a parada do algoritmo pelo número de iterações. Se o DE atingir 1000 iterações antes de satisfazer qualquer um dos dois primeiros critérios, encerra-se o algoritmo.

O objetivo de estabelecer três formas para encerrar o algoritmo é acelerar o processo do DE, mas visando um resultado satisfatório, exceto para o terceiro caso (parada por número de iterações) que foi estabelecido para evitar que o programa entrasse em um ciclo infinito. Quando o algoritmo é encerrado, o valor dos parâmetros do MIT que são armazenados correspondem a corrente estimada, cuja diferença com a corrente experimental satisfaz a um critério de parada. A Figura 14 apresenta um fluxograma da criação da tabela de referência.

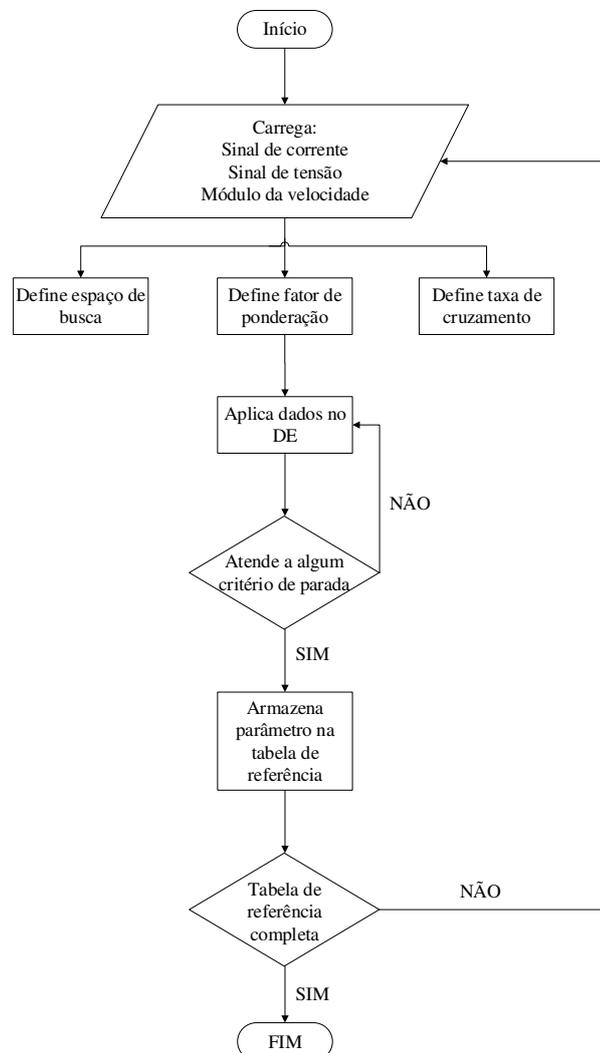


Figura 14: Fluxograma da utilização do DE para criação da tabela de referência

Fonte: Autoria própria

O processo apresentado de utilização do DE é o mesmo para a criação da tabela de referência e para a estimação dos parâmetros na fase de identificação da falha. Após obter a tabela de referência, começa o processo de estimação de parâmetros do MIT para análise de sua situação de operação - com ou sem falha.

A escolha do vetor referência é feita por meio da velocidade. Dado o módulo da velocidade do sinal que será classificado, calcula-se a diferença com os valores de velocidade da tabela de referências. O vetor cuja velocidade apresentar menor diferença será escolhido, conforme apresentado na Figura 15. O exemplo apresenta que a velocidade de entrada relacionada ao sinal que será analisado possui a mesma magnitude que o vetor 3, logo, o vetor utilizado para fixar os parâmetros do rotor será o vetor 3 da tabela de referência do motor correspondente.

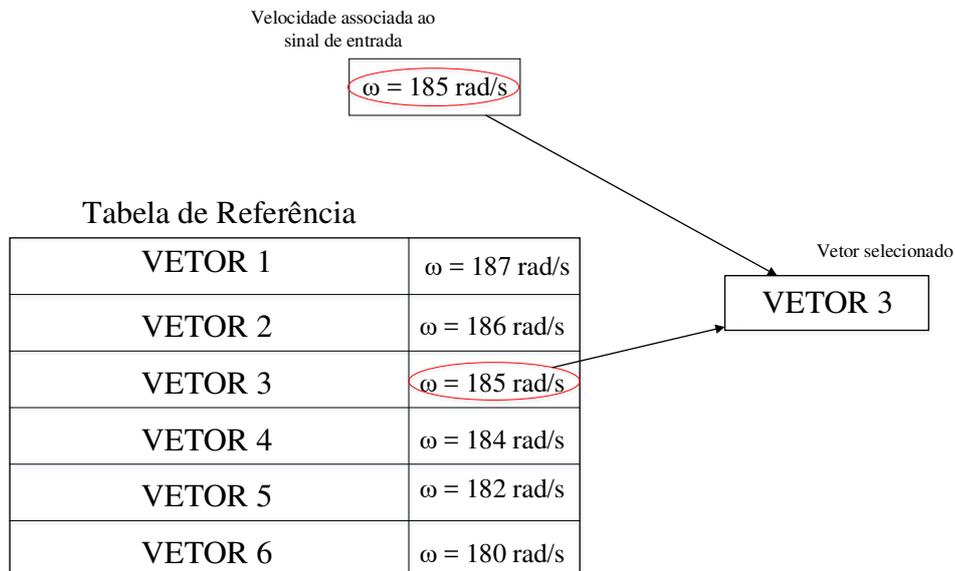


Figura 15: Processo de seleção do vetor referência

Fonte: Autoria própria

A Figura 16 apresenta a utilização do DE para estimação dos parâmetros, a fim de realizar o diagnóstico de falha.

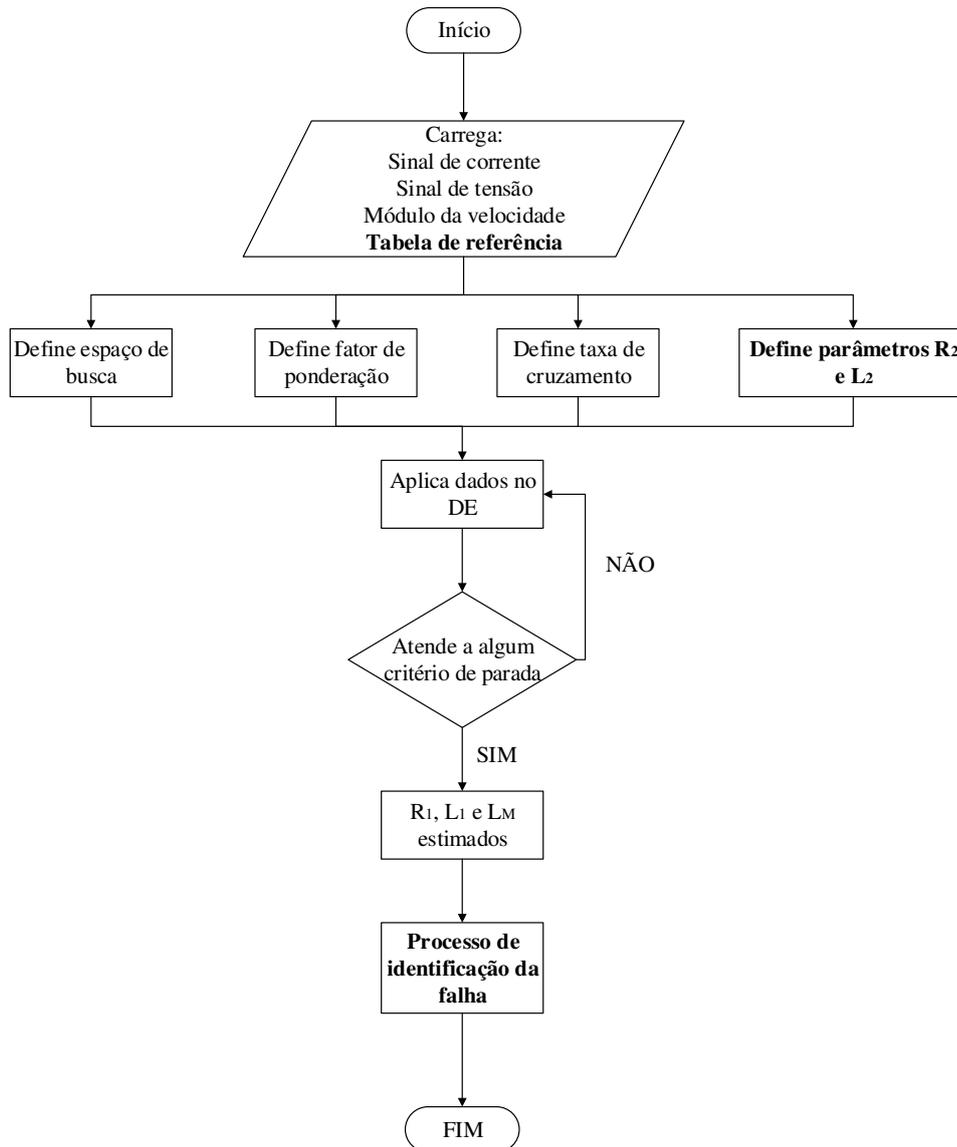


Figura 16: Fluxograma da utilização do DE para identificação de falha

Fonte: Autoria própria

4.4.3 IDENTIFICAÇÃO DA FALHA

Para identificar o melhor método para identificação da falha por meio dos parâmetros estimados a partir do DE, inicialmente foi realizada a estimação dos parâmetros de estator e magnetização para todas as situações de falha do Motor 1, com variação de conjugado de carga e tensões equilibradas, totalizando 36 sinais.

Com isso, observou-se que a indutância de magnetização apresentou um comportamento característico em todas as situações, que permitiu realizar a identificação da falha

por meio da análise de um único parâmetro. A Tabela 11 apresenta o comportamento da indutância para o Motor 2, onde é possível observar um decréscimo com o aumento da falha e um acréscimo com o aumento do conjugado de carga.

Tabela 11: Variação da indutância de magnetização (L_M) do Motor 2

Variação do parâmetro L_M								
Torque (Nm)	Sem falha		3%		5%		7%	
10%	0,4928	0,4835	0,3676	0,3465	0,3273	0,3038	0,3102	0,2860
25%	0,6854	0,6570	0,4522	0,4411	0,4007	0,3784	0,3677	0,3419
50%	1,3345	1,2249	0,8378	0,7847	0,6480	0,5661	0,5242	0,4659
75%	3,6252	3,2920	2,0307	1,7573	1,1706	0,9240	1,0156	0,7826
100%	3,6803	3,1389	1,4284	1,2416	0,9868	0,7612	0,6852	0,5903
150%	3,7557	3,1969	1,7830	1,5123	1,0814	0,7492	0,8117	0,6520

A partir dessa definição, o método para diagnosticar a falha dá-se por meio da análise do desvio percentual da indutância de magnetização em relação ao valor da mesma em condição sem falha, para cada uma das condições de operação de conjugado de carga.

Inicialmente criou-se uma tabela de desvio percentual para cada motor, o que tornou o método muito restrito. Então, com a finalidade de deixá-lo mais robusto, analisou-se o comportamento do desvio para os três motores para chegar a uma única tabela de desvio percentual. Dessa forma, foram estabelecidas quatro faixas para o diagnóstico da falha, conforme apresentado na Tabela 12.

Tabela 12: Desvio percentual de L_M para identificação de falha no MIT

Níveis para identificação da falha				
Torque	Nível de falha			
	Sem falha	até 5%	até 10%	acima de 10%
10%	0 - 11	11 - 37	37 - 55	55 - 100
25%	0 - 11	11 - 47	47 - 55	55 - 100
50%	0 - 14	14 - 60	60 - 80	80 - 100
75%	0 - 14	14 - 72	72 - 91	91 - 100
100%	0 - 14	14 - 78	72 - 91	91 - 100
150%	0 - 14	14 - 77	77 - 90	90 - 100

A partir dos valores da Tabela 12, criou-se um espectro de falha, conforme apresentado na Figura 17, com os valores do desvio percentual por falha como limitantes dos níveis de falha.



Figura 17: Espectro para identificação de falha no MIT

Fonte: Autoria própria

Com esse processo finalizado, passa-se a fase da validação. Dado o sinal de entrada, esse passará pelo DE para que os parâmetros do MIT sejam determinados. Então, o valor da indutância de magnetização é separado para determinar o seu desvio percentual em relação a indutância do vetor selecionado na tabela de referência e, a partir desse valor, indicar no espectro aonde a falha se encontra. A Figura 18 apresenta um diagrama geral do sistema de diagnóstico de falha.

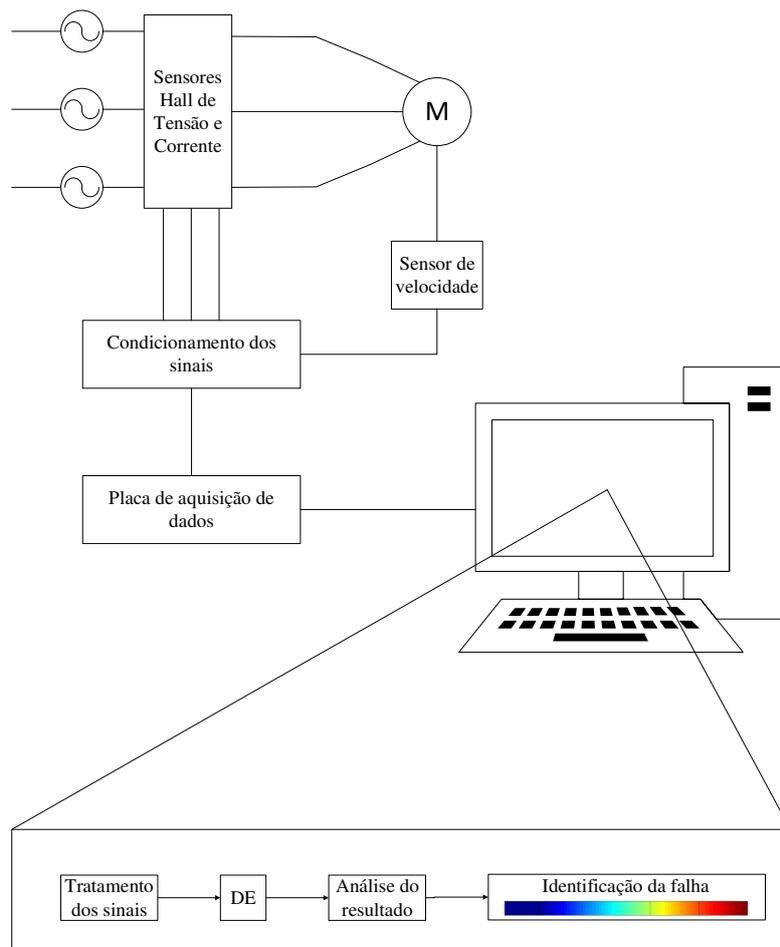


Figura 18: Diagrama do sistema de identificação de falha

Fonte: Autoria própria

4.5 CONCLUSÃO DO CAPÍTULO

Neste capítulo foi apresentada a metodologia para o desenvolvimento desse trabalho, descrevendo os procedimentos de reprodução dos defeitos, bem como o laboratório em que foram desenvolvidos, além da descrição detalhada do procedimento de diagnóstico da falha. O objetivo principal da metodologia abordada é proporcionar uma abordagem alternativa de detecção e classificação de falhas em máquinas elétricas utilizando evolução diferencial. No Capítulo 5 são apresentados os resultados obtidos.

5 RESULTADOS OBTIDOS

5.1 INTRODUÇÃO

O presente capítulo apresenta os resultados computacionais, fundamentados por dados experimentais, obtidos por meio da operação dos MIT em ambiente laboratorial. Os aspectos metodológicos foram apresentados no Capítulo 4.

O DE utilizado, apresentado na Seção 4.4.2, foi implementado no ambiente MATLAB[®]. As configurações do computador utilizado para desenvolvimento do DE, apresentado na Seção 3.3, e validação do mesmo consiste em um processador Intel[®] Core[™] i7-6700 3,41 GHz, memória RAM de 16GB e HD de 1TB.

5.2 IDENTIFICAÇÃO DE FALHAS DE ESTATOR

Após o tratamento dos sinais de corrente e tensão, inicia-se o processo de identificação dos parâmetros por meio do DE.

Conforme apresentado na Subseção 4.4.2, primeiramente são estimados os parâmetros referentes as situações sem falhas, com tensões equilibradas para seis níveis de carga diferentes. A Figura 19 apresenta a comparação entre os sinais de corrente estimados e experimentais referente aos parâmetros da tabela de referência do Motor 1.

Analisando os gráficos com os parâmetros de referência, pode-se observar uma aproximação entre os sinais experimentais e estimados, obtidos por meio do DE. Para todos os casos, o erro entre as curvas foi inferior a 0,08 - atendendo, no máximo, ao segundo critério de parada apresentado na Subseção 4.4.2.

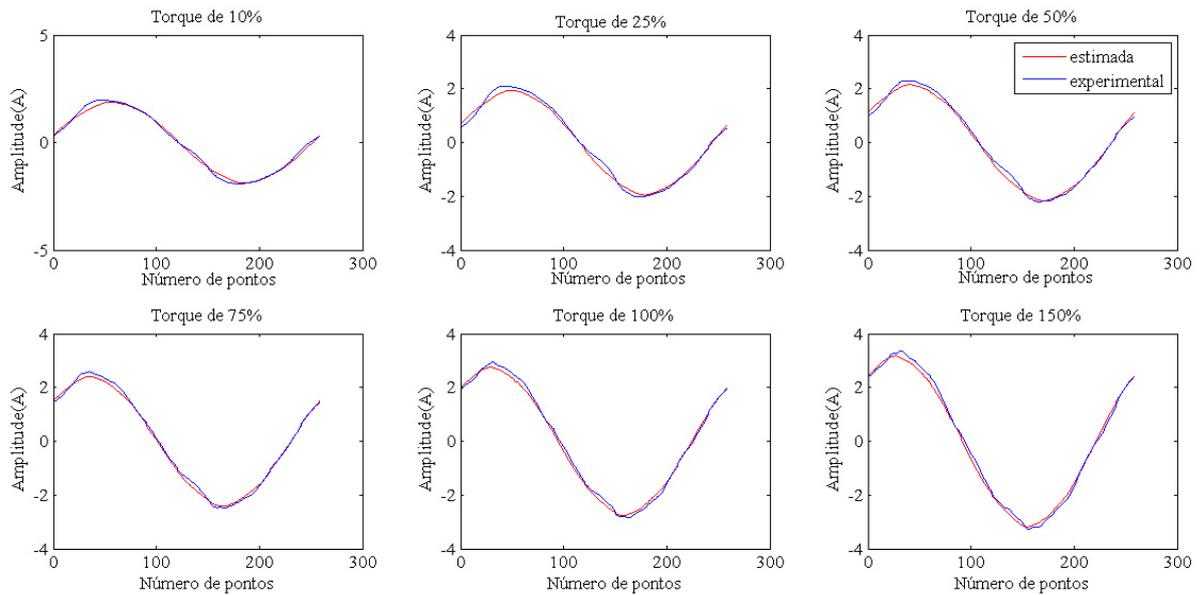


Figura 19: Comparação entre as correntes da tabela de referência do Motor 1

Fonte: Autoria própria

Do mesmo modo, as Figuras 20 e 21 apresentam a comparação entre os sinais de corrente experimental e estimado, a fim de apresentar graficamente a aproximação obtida com a utilização do DE.

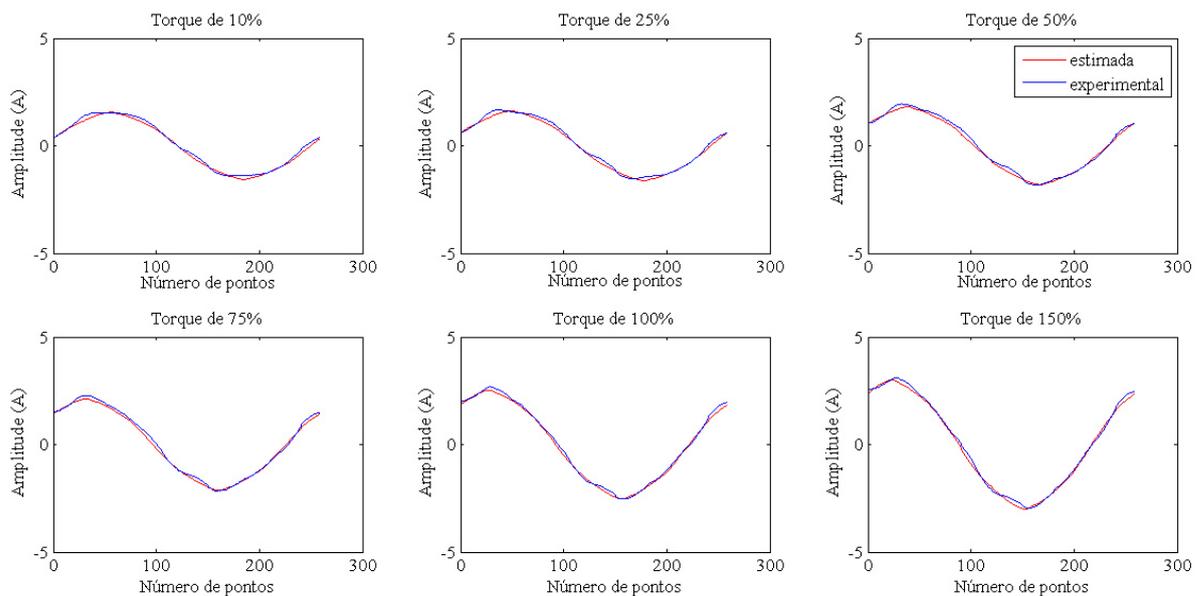


Figura 20: Comparação entre as correntes da tabela de referência do Motor 2

Fonte: Autoria própria

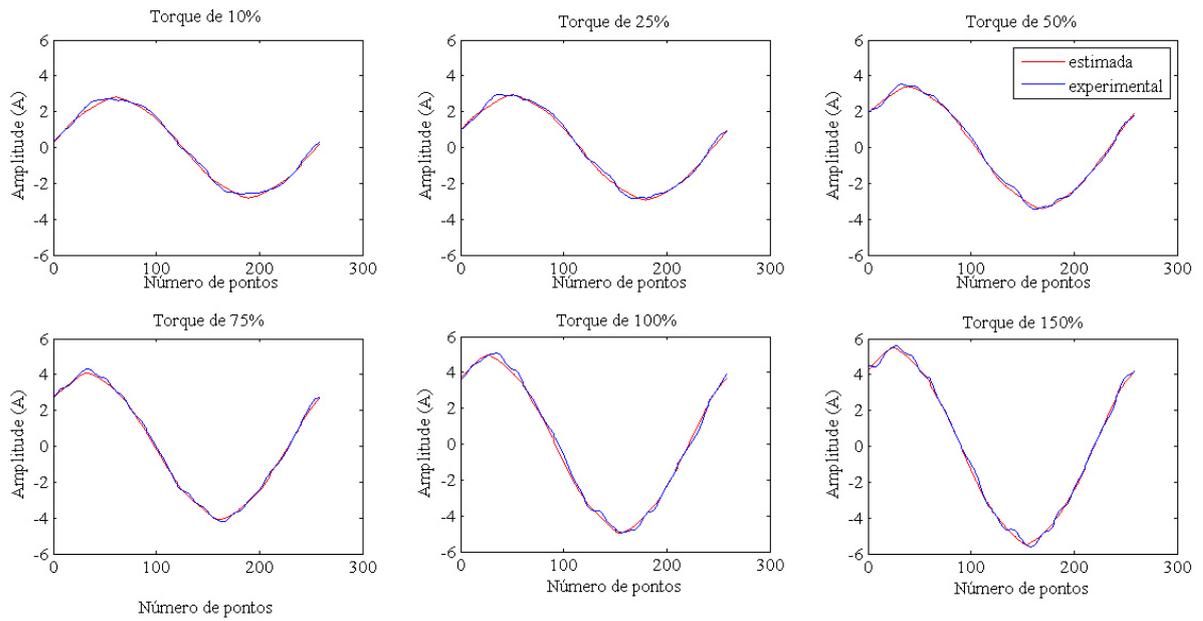


Figura 21: Comparação entre as correntes da tabela de referência do Motor 3

Fonte: Autoria própria

Assim como no caso do Motor 1, a diferença máxima entre as curvas apresentadas para o Motor 2 e para o Motor 3 foi de 0,08, também atendendo, no máximo, ao segundo critério de parada estabelecido.

Após criada a tabela de referência, os parâmetros de rotor foram fixados para que os parâmetros de estator e magnetização (R_1 , L_1 e L_M , respectivamente) fossem estimados para iniciar o processo de detecção de falha. A estimação de parâmetros ocorreu da mesma forma que para a construção da tabela de referência, tendo como função objetivo a minimização do erro entre as curvas de corrente experimental e estimada, apresentada em (15), no Capítulo 3.3.

Na sequência da estimação dos parâmetros realizou-se a análise de L_M , a fim de calcular o desvio percentual em relação ao mesmo parâmetro na mesma condição e operação de conjugado de carga, para então iniciar o processo de classificação da falha. A classificação ocorreu utilizando-se apenas a Tabela 12, para todos os casos de desequilíbrio de tensão, nos três motores

Para possibilitar uma análise detalhada, a validação foi dividida em subseções, uma para cada motor, conforme será apresentado a seguir.

5.2.1 RESULTADOS OBTIDOS PARA O MOTOR 1

As análises para a validação foram separadas por níveis de desequilíbrio de tensão. A Tabela 13 apresenta o resultado da validação para o Motor 1, com tensões equilibradas e com desequilíbrio de 2%, tanto para a fase A quanto para as fases B e C somadas.

Tabela 13: Resultado da validação do Motor 1 para tensões equilibradas e com 2% de desequilíbrio

Validação do Motor 1		
Tensões	equilibradas	desequilíbrio de 2%
Ensaio	180	180
Classificações corretas	144	149
Classificações incorretas	36	31
Falsos positivos	8	7
Falsos negativos	28	24
Total de acertos (%)	80	82,78

Analisando os resultados da validação do Motor 1, observa-se que o maior número de erros são falsos negativos, correspondentes, na maioria dos casos, as falhas de 3%, que são classificadas como sem falha. Isso acontece devido ao fato de que, para o Motor 1, tanto as correntes sem falha quanto as que possuem falha de 3% ficarem próximas e, por isso, acabarem sendo confundidas pelo DE. Já os falsos positivos correspondem aos sinais sem falha que foram classificados como falha de até 5%.

É possível observar ainda que o desequilíbrio de tensão de 2%, nesse caso, não interferiu significativamente na classificação das falhas e apresentou, inclusive, um resultado melhor, ou seja, 4 classificações corretas a mais que no caso de tensões equilibradas.

Em relação a identificação de falha utilizando o espectro de falha, serão apresentados 2 casos. A Figura 22 apresenta uma classificação correta, onde o sinal indica que o motor não apresenta falha. A circunferência e a seta indicam a localização da falha, mostrando corretamente que esta encontra-se no intervalo sem falha.

A Figura 23 apresenta uma classificação errada, de falso positivo no espectro, onde o sinal sem a falha foi classificado com falha de até 5%. Nesse caso, observa-se que o espectro aponta uma falha em seu estágio inicial, muito próxima do limite entre os intervalos sem falha e com falha até de 5%.

A partir da análise dessas situações observa-se a importância do espectro para o auxílio da classificação de falha, pois com este é possível observar além da classificação da falha o quão próximo de mudar de estágio esta se encontra.



Figura 22: Identificação da falha corretamente no espectro

Fonte: Autoria própria

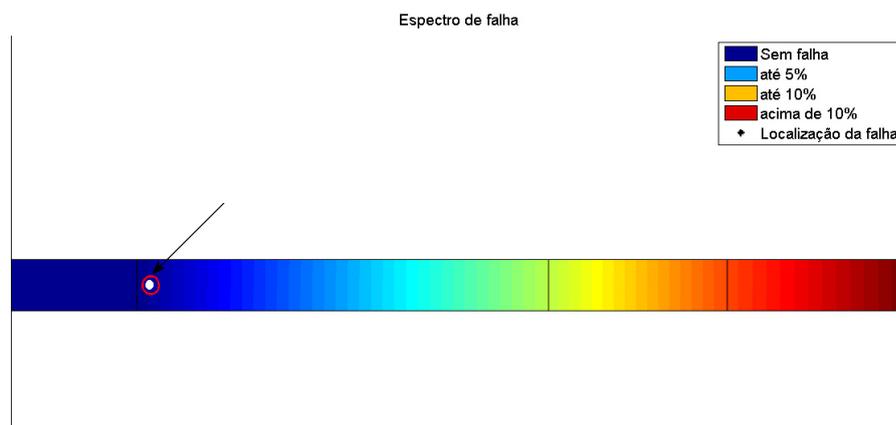


Figura 23: Identificação da falha indicando um falso positivo no espectro

Fonte: Autoria própria

Além das situações de desequilíbrio de 2% de tensão, o método também foi testado para desequilíbrios de 4%, 6%, 8% e 10%, como apresentado na Tabela 5. Para esses casos o resultado obtido não foi satisfatório. A classificação correta das falhas ficou inferior a 50%. Esperava-se que o desequilíbrio de tensão fosse refletido proporcionalmente à corrente. Porém, como isso não ocorreu, os parâmetros estimados, embora se aproximassem da corrente, não se encaixaram nos intervalos apresentados na Tabela 5.

A Figura 24 apresenta um caso de desequilíbrio de tensão de 10%, comparando a tensão e a corrente com o sinal equilibrado, somente da fase A, e, por último, a estimação dos parâmetros para a situação em desequilíbrio.

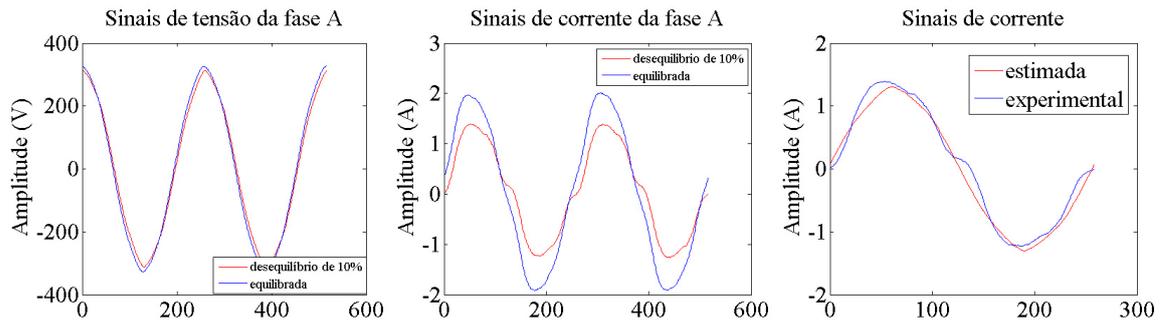


Figura 24: Análise do desequilíbrio de tensão na estimativa de parâmetros

Fonte: Autoria própria

A partir da Figura 24, observa-se que graficamente há uma pequena diferença entre os sinais equilibrado em com o desequilíbrio de 10%. No entanto, esse desequilíbrio reflete significativamente na corrente. Nesse caso, o módulo da impedância equivalente será maior, o que levará a um conjunto de parâmetros diferente.

Ainda assim, no terceiro gráfico é possível observar que o DE ainda é capaz de estimar os parâmetros, seguindo exatamente os mesmos critérios para os outros, porém, atendendo ao terceiro critério de parada (número de iterações). Isso acontece porque os parâmetros do rotor estão fixos de acordo com a situação de equilíbrio de tensão, e o DE não consegue encontrar um conjunto de parâmetros de estator e magnetização que atenda ao primeiro ou segundo critério antes do número máximo de iterações permitidos.

A subseção 5.2.2 apresenta a validação para o Motor 2.

5.2.2 RESULTADOS OBTIDOS PARA O MOTOR 2

O processo de validação do Motor 2 ocorreu da mesma forma que para o Motor 1, a fim de permitir uma comparação detalhada entre os três motores, ao final do presente trabalho. A Tabela 14 apresenta o resultado da validação para o Motor 2, com tensões equilibradas e com desequilíbrio de 2%, tanto para a fase A quanto para as fases B e C somadas.

Analisando os resultados da validação do Motor 2, observa-se que para esse caso, os maiores erros ocorrem para falsos positivos. No caso de equilíbrio de tensão não houve nenhum falso negativo, o que indica que as falhas de 3% nesse caso não foram confundidas com as situações sem falha. No entanto, alguns sinais sem falha indicaram falha de até 5%.

Tabela 14: Resultado da validação do Motor 2 para tensões equilibradas e com 2% de desequilíbrio

Validação do Motor 2		
Tensões	equilibradas	desequilíbrio de 2%
Ensaios	120	120
Classificações corretas	114	108
Classificações incorretas	6	12
Falsos positivos	6	10
Falsos negativos	0	2
Total de acertos (%)	95,00	90,00

Assim como no primeiro caso, Motor 1, o desequilíbrio de tensão não apresentou grande influência para identificação da falha no Motor 2, embora o número de classificações incorretas tenha sido inferior com o desequilíbrio.

Utilizando o espectro também serão apresentados 2 casos. A Figura 25 apresenta uma classificação correta, onde o sinal indica que o motor apresenta falha de 5 %. A circunferência e a seta indicam o a localização da falha, mostrando corretamente que esta encontra-se com falha de até 5%.

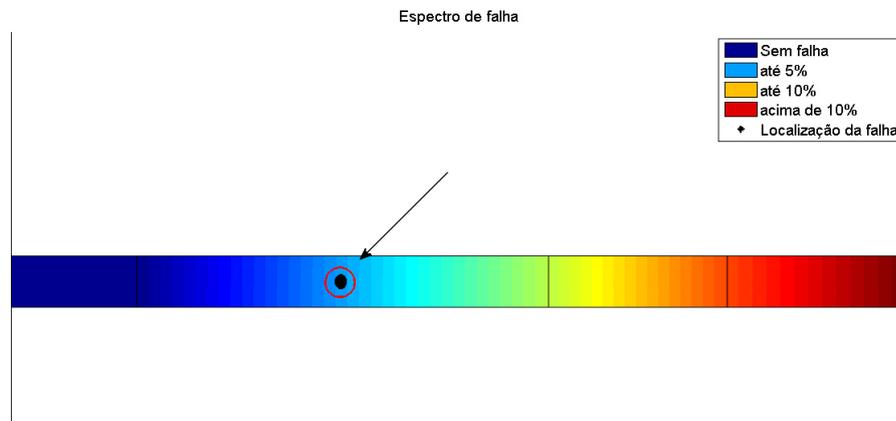


Figura 25: Identificação da falha corretamente no espectro

Fonte: Autoria própria

Na Figura 26 apresenta uma classificação errada, de falso positivo no espectro, onde o sinal sem falha foi classificado com falha de até 5%, para uma situação com desequilíbrio de 2%. Nesse caso, observa-se que o espectro aponta um início da falha, porém muito próximo do limite com o nível sem falha.



Figura 26: Identificação da falha indicando um falso positivo no espectro

Fonte: Autoria própria

Assim como para o Motor 1, além das situações de desequilíbrio de 2% de tensão, o método também foi testado para desequilíbrios de 4%, 6%, 8% e 10%. Novamente, para essas situações os resultados obtidos não foram satisfatórios, com a classificação correta das falhas inferior a 50%. Do mesmo modo que para o Motor 1, o desequilíbrio de tensão não refletiu proporcionalmente à corrente, logo, a impedância equivalente do sistema aumentou, levando a um conjunto de parâmetros diferente dos estimados para a situação de equilíbrio de tensão.

A Figura 27 também apresenta um caso de desequilíbrio de tensão de 10%, comparando a tensão e a corrente com o sinal equilibrado, somente da fase A, e, por último, a estimação dos parâmetros para a situação em desequilíbrio.

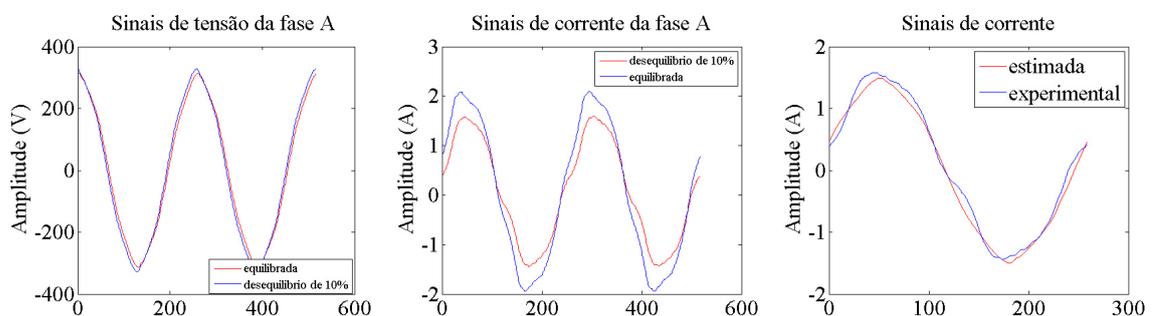


Figura 27: Análise do desequilíbrio de tensão na estimativa de parâmetros

Fonte: Autoria própria

Graficamente há uma pequena diferença entre os sinais equilibrado em com o

desequilíbrio de 10%, porém com uma diferença significativa na corrente.

Igualmente, no terceiro gráfico é possível observar que o DE foi capaz de estimar os parâmetros, com os mesmos critérios para os outros, porém, também atendendo ao terceiro critério de parada (número de iterações), pelo mesmo motivo que para o Motor 1.

A Subseção 5.2.3 apresenta a validação para o Motor 3.

5.2.3 RESULTADOS OBTIDOS PARA O MOTOR 3

Finalizando as validações, para o Motor 3 o banco de dados também foi separado de acordo com o nível de desequilíbrio de tensão. Os resultados com tensões equilibradas e com desequilíbrio de 2% são apresentados na Tabela 15.

Tabela 15: Resultado da validação do Motor 3 para tensões equilibradas e com 2% de desequilíbrio

Validação do Motor 3		
Tensões	equilibradas	desequilíbrio de 2%
Ensaios	120	120
Classificações corretas	105	98
Classificações incorretas	15	22
Falsos positivos	5	9
Falsos negativos	10	13
Total de acertos (%)	87,50	81,67

Analisando os resultados da validação do Motor 3, observa-se que o maior número de erros são falsos negativos, assim como no caso do Motor 1, correspondentes também as falhas de 3%, que são classificadas como sem falha. A classificação incorreta acontece pois os sinais de corrente sem falha e com falha de 3% são próximos e acabam possuindo parâmetros semelhantes, o que pode levar o método ao erro. Da mesma forma, os sinais sem falha acabam sendo confundidos e classificados como falha de até 5%, gerando-se os falsos positivos.

Estudando agora a falha pelo espectro, 2 casos foram separados. Na Figura 28 é apresentada uma classificação correta, onde o sinal indica que o motor está com uma falha de até 5%. A circunferência e a seta indicam a localização da falha, mostrando corretamente que esta encontra-se no intervalo de até 5% de falha.

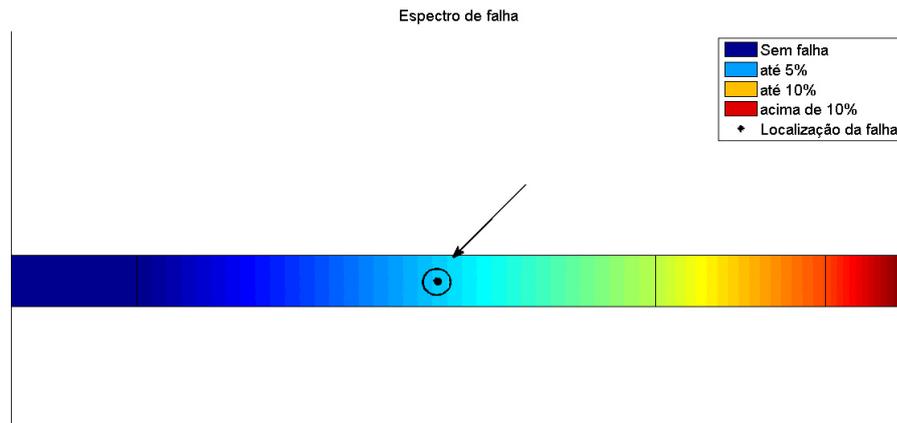


Figura 28: Identificação da falha corretamente no espectro

Fonte: Autoria própria

A Figura 29 apresenta uma classificação errada, de falso negativo no espectro, onde o sinal com falha de 3% foi classificado sem falha. Nesse caso, observa-se que o espectro aponta que não há falha, porém esta encontra-se muito próxima do limite entre os intervalos sem falha e com falha até de 5%.



Figura 29: Identificação da falha indicando um falso negativo no espectro

Fonte: Autoria própria

O método também foi testado para as outras situações de desequilíbrio apresentada na Tabela 5, com o mesmo resultado obtido para os Motores 1 e 2, classificação correta das falhas inferior a 50 %.

A Figura 30 apresenta o mesmo caso de desequilíbrio de tensão de 10%, agora para o Motor 3, comparando a tensão e a corrente com o sinal equilibrado, somente da

fase A, e, por último, a estimação dos parâmetros para a situação em desequilíbrio.

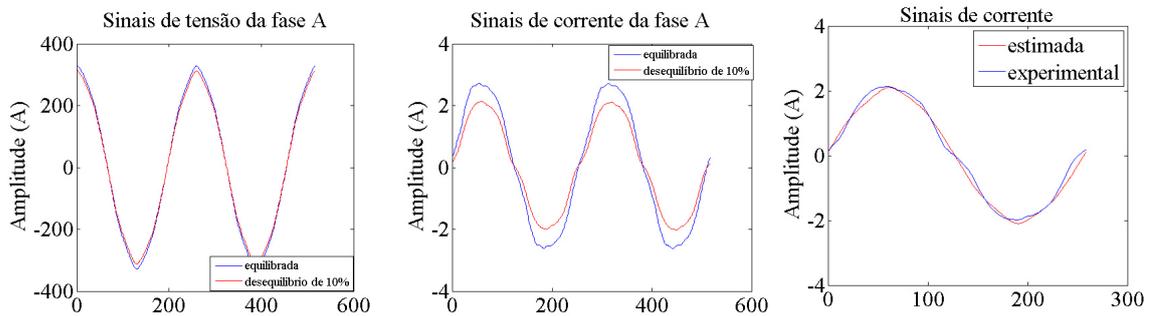


Figura 30: Análise do desequilíbrio de tensão na estimativa de parâmetros

Fonte: Autoria própria

Mais uma vez é possível observar que uma pequena alteração na tensão reflete em uma mudança significativa na corrente, aumentando conseqüentemente a impedância e modificando seus parâmetros.

O terceiro gráfico mostra o funcionamento do DE, pois houve a aproximação da corrente, atendendo ao terceiro critério.

Na Seção 5.3 são apresentadas as conclusões do capítulo.

5.3 CONCLUSÃO DO CAPÍTULO

Este capítulo apresentou os resultados experimentais para classificação de falhas de curto-circuito de estator, por meio do DE. A identificação da falha ocorreu pela análise da indutância de magnetização, onde a partir do desvio percentual entre o parâmetro estimado e o de referência, verifica-se o intervalo da falha em que o sinal se encontra.

A Tabela 16 apresenta um comparativo dos resultados para tensão equilibrada entre os três motores.

Da mesma forma, a Tabela 17 apresenta uma comparação entre os três motores para um desequilíbrio de tensão de 2%.

Observa-se que o Motor 2 apresentou melhor resultado para ambos os casos, com e sem desequilíbrio de tensão. Ainda assim, os Motores 1 e 3 apresentaram taxas de acerto superior a 80%, um bom resultado. Em todos os casos observou-se que o desequilíbrio de tensão de até 2% não influenciou significativamente para identificação da falha.

Tabela 16: Comparação de resultados entre motores estudados

	Resultado geral para tensões equilibradas		
	Motor 1	Motor 2	Motor 3
Ensaio	180	120	120
Classificações corretas	144	114	105
Classificações incorretas	36	6	15
Falsos positivos	8	6	5
Falsos negativos	28	0	10
Total de acertos (%)	80,00	95,00	87,50

Tabela 17: Comparação de resultados entre motores estudados

	Resultado geral para desequilíbrio de tensão de 2%		
	Motor 1	Motor 2	Motor 3
Ensaio	180	120	120
Classificações corretas	149	108	98
Classificações incorretas	31	12	22
Falsos positivos	7	10	9
Falsos negativos	24	2	13
Intensidade incorreta	4	19	9
Total de acertos (%)	82,78	90,00	81,67

A Tabela 18 apresenta um comparativo do trabalho desenvolvido com trabalhos recentes que utilizaram o AG e RNA para a identificação de falhas de curto-circuito de estator.

Tabela 18: Comparativo entre os resultados desta pesquisa e trabalhos recentes para identificação de falhas de estator

Referência	1	2	Este estudo
Motores utilizados	4 kW	1 CV* e 2 CV	1 CV* e 2 CV
Dados de entrada	Correntes - Tensões - Velocidade - Frequência	1 Corrente	Correntes - Tensões Módulo da velocidade
Método utilizado	GA	RNA	DE
Desequilíbrio de tensão	NI	$\pm 8\%$	$\pm 2\%$
Variação de carga	100% somente	10% - 150%	10% - 150%
Nível de falha	0, 5, 10 e 15 voltas de cc	3%, 5% e 10%	0% até acima de 10%
Taxa de acerto	Análise Gráfica	76,3% - 89,7%	80% - 95%
	1 -(TREETRONG et al., 2012)		2 -(LOPES, 2016) * 2 motores de 1 CV

Por meio da análise dos dados apresentados é possível observar que os resultados

percentuais obtidos utilizando-se RNA e DE foram próximos, com o DE apresentando resultados melhores. A comparação percentual com o AG não foi possível, pois os resultados foram apresentados em gráficos.

Em relação aos dados de entrada, observa-se que utilizando RNA é necessário apenas uma corrente para identificação da falha, enquanto que para DE também é necessário o módulo da velocidade e as tensões. Já com o AG, além dos dados de corrente, velocidade e tensão, também é necessária a utilização da frequência.

Outras observações importantes são relacionadas aos níveis de desequilíbrio de tensão e variação de carga. No caso do AG, os testes foram realizados com o motor operando somente na condição nominal e sem desequilíbrio de tensão. Já com o uso da RNA foi possível aplicar a mesma variação de carga que para o DE, no entanto com a vantagem de um desequilíbrio de até $\pm 8\%$.

O Capítulo 6 apresenta as conclusões deste trabalho, bem como suas perspectivas futuras.

6 CONCLUSÃO

Este trabalho apresentou um método de diagnóstico de falha de curto-circuito de estator, baseado em dados experimentais de três motores de indução trifásicos, operando com condições de variação de conjugado de carga e desequilíbrio de tensão, emulando o ambiente industrial.

Conforme apresentado no Capítulo 4, a detecção e diagnóstico da falha ocorre por meio da análise do parâmetro de magnetização, estimado pelo DE, a partir de sinais de tensão e corrente e módulo da velocidade da máquina. Observou-se que quanto maior o nível de falha maior o desvio percentual em relação ao parâmetro de referência, o que permitiu a classificação da mesma.

Os resultados mostraram que o método é satisfatório para detecção e classificação de falhas de curto-circuito de estator, com desequilíbrio de tensão de até 2%. No entanto, para níveis de desequilíbrios superiores a 2% não é possível realizar a identificação da falha de modo satisfatório, pois o desequilíbrio da tensão não reflete proporcionalmente na corrente, conforme explicado na Subseções 5.2.1, 5.2.2 e 5.2.3.

Por utilizar os sinais de tensão, corrente e módulo da velocidade em regime permanente, é possível realizar o monitoramento *online* ou *offline* da máquina. Outra vantagem do método é a utilização do espectro de falha para monitorar seu comportamento - inclusive sua evolução em um mesmo nível. Isso permite a avaliação da velocidade de evolução da falha, possibilitando, então, programar o melhor momento para manutenção.

6.1 PERSPECTIVAS PARA TRABALHOS FUTUROS

Os trabalhos futuros associados a esta pesquisa são baseados no aperfeiçoamento do método proposto para identificação de falha. Logo, a partir dos resultados obtidos para este trabalho são sugeridas as seguintes perspectivas:

- Aplicar a proposta desse trabalho para identificação de outros tipos de falhas pre-

sentes em MIT;

- Aplicar a técnica desenvolvida para acionamento com inversor de frequência.
- Implementar o sistema de diagnóstico em *hardware*;

6.2 PRODUÇÃO CIENTÍFICA

- Trabalhos correlatos - Autor principal

GUEDES, Jacqueline Jordan; CASTOLDI, Marcelo Favoretto; GOEDTEL, Alessandro. Temperature Influence Analysis on Parameter Estimation of Induction Motors Using Differential Evolution. IEEE Latin América. Aceito para publicação.

- Participação em trabalhos como colaborador

RODRIGUES, Ana Beatriz; GUEDES, Jacqueline Jordan; CASTOLDI, Marcelo Favoretto; GOEDTEL, Alessandro. Otimização Do Fluxo De Entreferro Para Aumento Da Eficiência De Um Motor De Indução Trifásico. 12th IEEE/IAS International Conference On Industry Application, 2016, Curitiba - Brasil.

BOSCO, Maycon Chimini; GUEDES, Jacqueline Jordan; CASTOLDI, Marcelo Favoretto; GOEDTEL, Alessandro; SILVA, Emerson Ravazzi Pires; BUZACHERO, Luiz Francisco Sanches. Estimação De Parâmetros e Sintonia De Um PI De Velocidade De Um Motor CC De Ímã Permanente Utilizando Evolução Diferencial. 12th IEEE/IAS International Conference On Industry Application, 2016, Curitiba - Brasil.

REFERÊNCIAS

- AHAMED, S. K.; SAKAR, A.; MITRA, M.; SENGUPTA, S.; Novel approach for detection of inter-turn short circuit of induction motor's stator winding through envelope analysis. In: IEEE. **Electrical and Computer Engineering: Advancing Technology for a Better Tomorrow (ICECE) 2014, 8th International Conference on**. [S.l.], 2014. p. 457–460.
- ALAMYAL, M.; GADOUE, S. M.; ZAHAWI, B. Detection of induction machine winding faults using genetic algorithm. In: IEEE. **Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED), 2013 9th IEEE International Symposium on**. [S.l.], 2013. p. 157–161.
- ALTHOBIANI, F.; BALL, A.; CHOI, B. An application to transient current signal based induction motor fault diagnosis of fourier–bessel expansion and simplified fuzzy artmap. **Expert Systems with Applications**, Elsevier, v. 40, n. 13, p. 5372–5384, 2013.
- ASFANI, D.; SYAFARUDDIN, M.; PURNOMO, T. H. Neural network based real time detection of temporary short circuit fault on induction motor winding through wavelet transformation. **International Journal of Innovative Computing, Information and Control**, v. 10, n. 6, p. 2277–2293, 2014.
- 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**, IEEE, v. 28, n. 4, p. 1064–1071, 2013.
- BAYRAM, D.; ŞEKER, S. Anfis model for vibration signals based on aging process in electric motors. **Soft Computing**, Springer, v. 19, n. 4, p. 1107–1114, 2015.
- 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.
- BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G. Advances in diagnostic techniques for induction machines. **IEEE Transactions on Industrial Electronics**, IEEE, v. 55, n. 12, p. 4109–4126, 2008.
- BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. **ACM Computing Surveys (CSUR)**, ACM, v. 35, n. 3, p. 268–308, 2003.
- BOUDISSA, E.; BOUNEKHLA, M. Genetic algorithm with dynamic selection based on quadratic ranking applied to induction machine parameters estimation. **Electric Power Components and Systems**, Taylor & Francis, v. 40, n. 10, p. 1089–1104, 2012.

BRITO, J. N. **Desenvolvimento de um sistema inteligente híbrido para diagnóstico de falhas em motores de indução trifásicos**. Tese (Doutorado), 2002.

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.

CHUDASAMA, K.; SHAH, V.; SHAH, S. Induction motor relaying scheme for external faults detection and classification using subtractive clustering based sugeno fuzzy inference system. **Electric Power Components and Systems**, Taylor & Francis, v. 44, n. 10, p. 1149–1162, 2016.

DAS, S.; KOLEY, C.; PURKAIT, P.; CHAKRAVORTI, S. Wavelet aided svm classifier for stator inter-turn fault monitoring in induction motors. In: IEEE. **IEEE PES General Meeting, 2010**. [S.l.], 2010. p. 1–6.

DAS, S.; SUGANTHAN, P. N. Differential evolution: A survey of the state-of-the-art. **IEEE Transactions on Evolutionary Computation**, IEEE, v. 15, n. 1, p. 4–31, 2011.

DEHGHANI, M.; KHOOBAN, M.; NIKNAM, T. Fast fault detection and classification based on a combination of wavelet singular entropy theory and fuzzy logic in distribution lines in the presence of distributed generations. **International Journal of Electrical Power and Energy Systems**, Elsevier, v. 78, p. 455–462, 2016.

DLAMINI, M.; BARENDSE, P. The detection of inter-turn stator faults on inverter fed induction motors. In: IEEE. **Power Engineering Society Conference and Exposition in Africa (PowerAfrica), 2012 IEEE**. [S.l.], 2012. p. 1–8.

DRIF, M.; CARDOSO, A. Stator fault diagnostics in squirrel cage three-phase induction motor drives using the instantaneous active and reactive power signature analyses. **IEEE Transactions on Industrial Informatics**, IEEE, v. 10, n. 2, p. 1348–1360, 2014.

DUAN, F.; ŽIVANOVIĆ, R. Induction motor stator fault detection by a condition monitoring scheme based on parameter estimation algorithms. **Electric Power Components and Systems**, Taylor & Francis, v. 44, n. 10, p. 1138–1148, 2016.

DUAN, F.; ŽIVANOVIĆ, R. Induction motor fault diagnostics using global optimization algorithm. In: IEEE. **Power Engineering Conference: Sustainable Energy Technologies and Systems (AUPEC) 2009, 19th Australasian Universities**. [S.l.], 2009. p. 1–5.

DUAN, F.; ŽIVANOVIĆ, R. Induction motor stator faults diagnosis by using parameter estimation algorithms. In: IEEE. **Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED), 2013 9th IEEE International Symposium on**. [S.l.], 2013. p. 274–280.

EBERHART, R.; SHI, Y. Particle swarm optimization: Developments, applications and resources. In: . [S.l.: s.n.], 2001. v. 1, p. 81–86.

EFTEKHARI, M.; MOALLEM, M.; SADRI, S.; HSIEH, M. Online detection of induction motor's stator winding short-circuit faults. **IEEE Systems Journal**, IEEE, v. 8, n. 4, p. 1272–1282, 2014.

EPE, . Balanço energético nacional 2016 - ano base 2015 - relatório final. **Empresa de Pesquisa Energetica - Ministério de Minas e Energia**, p. 291, 2016.

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**, Elsevier, v. 42, n. 1, p. 377–387, 2014.

GARCIA-PEREZ, A.; ROMERO-TRONCOSO, R.; CABAL-YEPEZ, E.; OSORNIO-RIOS, R. A.; LUCIO-MARTINEZ, J. A. Application of high-resolution spectral analysis for identifying faults in induction motors by means of sound. **Journal of Vibration and Control**, Sage Publications, v. 18, n. 11, p. 1585–1594, 2012.

GARCIA-RAMIREZ, A. G.; MORALES-HERNANDEZ, L. A.; OSORNIO-RIOS, R. A.; BENITEZ-RANGEL, J. P.; GARCIA-PEREZ, A.; ROMERO-TRONCOSO, R. Fault detection in induction motors and the impact on the kinematic chain through thermographic analysis. **Electric Power Systems Research**, Elsevier, v. 114, p. 1–9, 2014.

GHATE, V.; DUDUL, S. Optimal mlp neural network classifier for fault detection of three phase induction motor. **Expert Systems with Applications**, Elsevier, v. 37, n. 4, p. 3468–3481, 2010.

GNANAPRAKASAM, C.; CHITRA, K. S-transform and anfis for detecting and classifying the vibration signals of induction motor. **Journal of Intelligent and Fuzzy Systems**, IOS Press, v. 29, n. 5, p. 2073–2085, 2015.

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

GODOY, W. F. **Multiclassificador inteligente de falhas no domínio do tempo em motores de indução trifásicos alimentados por inversores de frequência**. Tese (Doutorado), 2016.

GODOY, W. F.; DA SILVA, I. N.; GOEDEL, A.; PALÁCIOS, R. H. C.; LOPES, T. D. Application of intelligent tools to detect and classify broken rotor bars in three-phase induction motors fed by an inverter. **IET Electric Power Applications**, IET, v. 10, n. 5, p. 430–439, 2016.

GOEDEL, A. **Estimador neural de velocidade para motores de indução trifásicos**. Tese (Doutorado) — Universidade de São Paulo, 2007.

GRACIOLA, C. L.; GOEDEL, A.; SUETAKE, M.; SUMAR, R. R. Neural speed estimator for line-connected induction motor embedded in a digital processor. **Applied Soft Computing**, Elsevier, v. 40, p. 616 – 623, 2016.

GUEDES, J. J. **Estimação de parâmetros de motores de indução trifásicos utilizando evolução diferencial**. Trabalho de Conclusão de Curso — Universidade Tecnológica Federal do Paraná, 2015.

HAYKIN, S. **Neural Network: A comprehensive foundation**. [S.l.]: Prentice Hall, 1998.

HENAO, H.; CAPOLINO, G.; FERNANDEZ-CABANAS, M.; FILIPPETTI, F.; BRUZZESE, C.; STRANGAS, E.; PUSCA, R.; ESTIMA, J.; RIERA-GUASP, M.; HEDAYATI-KIA, S. Trends in fault diagnosis for electrical machines: a review of diagnostic techniques. **IEEE industrial electronics magazine**, IEEE, v. 8, n. 2, p. 31–42, 2014.

KARABOGA, D.; GORKEMLI, B.; OZTURK, C. KARABOGA, N. A comprehensive survey: Artificial bee colony (abc) algorithm and applications. **Artificial Intelligence Review**, Springer, v. 42, n. 1, p. 21–57, 2014.

KONAR, P.; CHATTOPADHYAY, P. Multi-class fault diagnosis of induction motor using hilbert and wavelet transform. **Applied Soft Computing**, Elsevier, v. 30, p. 341–352, 2015.

KRAUSE, P. C.; WASYNCZUK, O.; SUDHOFF, S. D.; PEKAREK, S. **Analysis of electric machinery and drive systems**. [S.l.]: John Wiley & Sons, 2013.

LAALA, W.; ZOUZOU, S.-E.; GUEDIDI, S. Induction motor broken rotor bars detection using fuzzy logic: Experimental research. **International Journal of Systems Assurance Engineering and Management**, Springer, v. 5, n. 3, p. 329–336, 2014.

LOPES, T. D. **Aplicação de redes perceptron multicamadas na detecção de falhas em motores elétricos**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2016.

LOPES, T. D.; GOEDEL, A.; PALÁCIOS, R. H. C.; GODOY, W. F.; MOLINA, R. Bearing fault identification of three-phase induction motors bases on two current sensor strategy. **Soft Computing**, Springer, p. 1–13, 2016.

MEDOUED, A.; LEBAROUD, A.; LAIFA, A.; SAYAD, D. Classification of induction machine faults using time frequency representation and particle swarm optimization. **Journal of Electrical Engineering and Technology**, The Korean Institute of Electrical Engineers, v. 9, n. 1, p. 170–177, 2014.

MINI, V. P.; USHAKUMARI, S. Electrical fault detection and diagnosis of induction motor using fuzzy logic. **Advances in Modelling and Analysis B**, v. 55, n. 1-2, 2012.

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

ONG, C.-M. **Dynamic simulation of electric machinery: using MATLAB/SIMULINK**. [S.l.]: Prentice Hall PTR Upper Saddle River, NJ, 1998.

OUYANG, P.; PANO, V. Comparative study of de, pso and ga for position domain pid controller tuning. **Algorithms**, Multidisciplinary Digital Publishing Institute, v. 8, n. 3, p. 697–711, 2015.

PALÁCIOS, R. H. C. **Aplicação de técnicas inteligentes com análise no domínio do tempo para reconhecimento de defeitos em motores de indução trifásicos**. Tese (Doutorado), 2016.

- PALÁCIOS, R. H. C.; GOEDEL, 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**, Springer, p. 1–13, 2016.
- PALÁCIOS, R.; DA SILVA, I. N.; GOEDEL, A.; GODOY, W. F. A novel multi-agent approach to identify faults in line connected three-phase induction motors. **Applied Soft Computing Journal**, Elsevier, v. 45, p. 1–10, 2016.
- PALÁCIOS, R. H. C.; DA SILVA, I. N.; GOEDEL, A.; GODOY, W. F. A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. **Electric Power Systems Research**, Elsevier, v. 127, p. 249 – 258, 2015.
- PANDYA, D.; UPADHYAY, S.; HARSHA, S. Fault diagnosis of rolling element bearing by using multinomial logistic regression and wavelet packet transform. **Soft Computing**, Springer, v. 18, n. 2, p. 255–266, 2014.
- PRICE, K.; STORN, R. M.; LAMPINEN, J. A. **Differential evolution: a practical approach to global optimization**. [S.l.]: Springer Science & Business Media, 2006.
- RAMOS, A. R.; ACOSTA, C. D.; TORES, P. J. R.; MERCADO, E. I. S; BAEZ, G. B.; RIFÓN, L. A.; LLANES-SANTIAGO, O. An approach to multiple fault diagnosis using fuzzy logic. **Journal of Intelligent Manufacturing**, Springer, p. 1–11, 2016.
- RAO, S. S. **Engineering optimization: theory and practice**. [S.l.]: John Wiley & Sons, 2009.
- RASHTCHI, V.; RAHIMPOUR, E.; FAZLI, S. Genetic algorithm application to detect broken rotor bar in three phase squirrel cage induction motors. **International Review of Electrical Engineering**, Praise Worthy Prize, v. 6, n. 5, p. 2286–2292, 2011.
- 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**, IEEE, v. 62, n. 3, p. 1746–1759, 2015.
- ROSHANFEKR, R.; JALILIAN, A. Analysis of rotor and stator winding inter-turn faults in wim using simulated mec model and experimental results. **Electric Power Systems Research**, Elsevier, v. 119, p. 418–424, 2015.
- ROSS, T. J. **Fuzzy logic with engineering applications**. [S.l.]: John Wiley & Sons, 2009.
- RUTKOWSKI, L. **Computational intelligence: methods and techniques**. [S.l.]: Springer Science & Business Media, 2008.
- SANCHES, D. S. **Algoritmos Evolutivos Multi-Objetivo para Reconfiguração de Redes em Sistemas de Distribuição de Energia Elétrica**. Tese (Doutorado) — Universidade de Sao Paulo, 2013.
- SANTOS, T. H. D. et al. Scalar control of an induction motor using a neural sensorless technique. **Electric Power Systems Research**, Elsevier, v. 108, p. 322–330, 2014.

- SAUER, I. L.; TATIZAWA, H.; SALOTTI, F. A. M.; MERCEDES, S. S. A comparative assessment of brazilian electric motors performance with minimum efficiency standards. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 41, p. 308 – 318, 2015.
- SEERA, M.; LIM, C. P.; ISHAK, D.; SINGH, H. Offline and online fault detection and diagnosis of induction motors using a hybrid soft computing model. **Applied Soft Computing**, Elsevier, v. 13, n. 12, p. 4493–4507, 2013.
- SESHADRINATH, J.; SINGH, B.; PANIGRAHI, B. K. Investigation of vibration signatures for multiple fault diagnosis in variable frequency drives using complex wavelets. **IEEE Transactions on Power Electronics**, IEEE, v. 29, n. 2, p. 936–945, 2014.
- SHAUKAT, S.; BHATTI, R. A.; QURESHI, K. I.; SHAD, S. A. Ant colony optimization: A review and comparison. **Research Journal of Applied Sciences, Engineering and Technology**, Maxwell Science Publishing, v. 8, n. 3, p. 435–438, 2014.
- SINGH, A.; GRANT, B.; DEFOUR, R.; SHARMA, C.; BAHADOORSINGH, S. A review of induction motor fault modeling. **Electric Power Systems Research**, Elsevier, v. 133, p. 191–197, 2016.
- SIVAKUMAR, M.; PARVATHI, R. Particle swarm and neural network approach for fault clearing of multilevel inverters. **American Journal of Applied Sciences**, Science Publications, v. 10, n. 6, p. 579–595, 2013.
- SUETAKE, M. **Sistemas inteligentes para monitoramento e diagnósticos de falhas em motores de indução trifásicos**. Tese (Doutorado) — Universidade de São Paulo, 2012.
- TALBI, E.-G. **Metaheuristics: from design to implementation**. [S.l.]: John Wiley & Sons, 2009.
- TREETRONG, J.; SINHA, J. K.; GU, F.; BALL, A. Parameter estimation for electric motor condition monitoring. **Advances in Vibration Engineering**, The Vibration Institute of India, v. 11, n. 1, p. 75–84, 2012.
- TRIGEASSOU, J.-C. **Electrical Machines Diagnosis**. [S.l.]: John Wiley & Sons, 2013.
- VAIMANN, T.; BELAHCEN, A.; KALLASTE, A. Necessity for implementation of inverse problem theory in electric machine fault diagnosis. In: IEEE. **Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED), 2015 IEEE 10th International Symposium on**. [S.l.], 2015. p. 380–385.
- VAKHARIA, V.; GUPTA, V.; KANKAR, P. A comparison of feature ranking techniques for fault diagnosis of ball bearing. **Soft Computing**, Springer, v. 20, n. 4, p. 1601–1619, 2016.
- YANG, X.-S. Firefly algorithm, stochastic test functions and design optimization. **International Journal of Bio-Inspired Computation**, Inderscience Publishers, v. 2, n. 2, p. 78–84, 2010.
- YANG, X.-S.; CUI, Z.; XIAO, R.; GANDOMI, A. H.; KARAMANOGLU, M. **Swarm intelligence and bio-inspired computation: theory and applications**. [S.l.]: Newnes, 2013.

ZAREI, J.; TAJEDDINI, M. A.; KARIMI, H. R. Vibration analysis for bearing fault detection and classification using an intelligent filter. **Mechatronics**, Elsevier, v. 24, n. 2, p. 151–157, 2014.