

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

JACQUELINE JORDAN GUEDES

**IDENTIFICAÇÃO DE FALHAS EM MOTORES DE INDUÇÃO  
TRIFÁSICOS UTILIZANDO ALGORITMOS DE  
OTIMIZAÇÃO E SISTEMAS INTELIGENTES**

TESE

CORNÉLIO PROCÓPIO

2019

JACQUELINE JORDAN GUEDES

**IDENTIFICAÇÃO DE FALHAS EM MOTORES DE INDUÇÃO  
TRIFÁSICOS UTILIZANDO ALGORITMOS DE  
OTIMIZAÇÃO E SISTEMAS INTELIGENTES**

Tese apresentada ao Programa de Pós-Graduação associado em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Doutor em Engenharia Elétrica” – Área de Concentração: Sistemas Eletroeletrônicos.

Orientador: Alessandro Goedtel

**CORNÉLIO PROCÓPIO**

**2019**

---

### Dados Internacionais de Catalogação na Publicação

---

G924 Guedes, Jacqueline Jordan

Identificação de falhas em motores de indução trifásicos utilizando algoritmos de otimização e sistemas inteligentes / Jacqueline Jordan Guedes. – 2019.  
144 p. : il. color. ; 31 cm.

Orientador: Alessandro Goedel.

Tese (Doutorado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação Associado em Engenharia Elétrica. Cornélio Procópio, 2019.

Bibliografia: p. 133-144.

1. Motores elétricos de indução. 2. Algoritmos. 3. Percepção de padrões. 4. Localização de falhas (Engenharia) 5. Engenharia Elétrica – Teses. I. Goedel, Alessandro, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação Associado em Engenharia Elétrica. III. Título.

CDD (22. ed.) 621.3

---

### Biblioteca da UTFPR - Câmpus Cornélio Procópio

Bibliotecário/Documentalista responsável:  
Romeu Righetti de Araujo – CRB-9/1676

## TERMO DE APROVAÇÃO

Título da Tese N° 001:

**“Identificação de Falhas em Motores de Indução Trifásicos Utilizando Algoritmos de Otimização e Sistemas Inteligentes”.**

por

**Jacqueline Jordan Guedes**

Orientador: Prof. Dr. Alessandro Goedtel

Coorientador:

Esta tese foi apresentada como requisito parcial à obtenção do grau de DOUTOR EM ENGENHARIA ELÉTRICA – Área de Concentração: Sistemas Eletrônicos, pelo Programa de Pós-Graduação Associado em Engenharia Elétrica – PPGAEE – da Universidade Tecnológica Federal do Paraná – UTFPR – Câmpus Cornélio Procópio, às 08 horas do dia 17 de dezembro de 2019. O trabalho foi \_\_\_\_\_ pela Banca Examinadora, composta pelos professores:

\_\_\_\_\_  
Prof. Dr. Alessandro Goedtel  
Presidente

\_\_\_\_\_  
Prof. Dr. Paulo José Amaral Serni  
UNESP

\_\_\_\_\_  
Prof. Dr. Francisco de Assis dos Santos Neves  
UFPE

\_\_\_\_\_  
Prof. Dr. Marcelo Favoretto Castoldi  
UTFPR-CP

\_\_\_\_\_  
Prof. Dr. Danilo Sipoli Sanches  
UTFPR-CP

Visto da coordenação:

\_\_\_\_\_  
Prof. Dr. Sérgio Augusto Oliveira da Silva  
Coordenador do Programa de Pós-Graduação Associado em  
Engenharia Elétrica  
UTFPR Câmpus Cornélio Procópio

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

À minha família, 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. Vocês são minha base e inspiração para seguir em frente. Agradeço ao meu irmão, minha cunhada e aos meus sobrinhos, por alegrarem os dias em que tive oportunidade de estar com eles e por serem compreensivos em minha ausência.

Aos meus familiares por me apoiarem na decisão de fazer o doutorado, especialmente minha tia que esteve ao meu lado me auxiliando no desenvolvimento desta Tese. Ao meu namorado pela paciência e apoio, pois estava presente para me animar e encorajar em todos os momentos de dificuldade, mostrando que eu seria capaz.

Aos amigos que estiveram sempre presentes e me ajudaram a encarar os problemas de maneira mais leve. À minha professora e amiga que se dedicou por muito tempo para me auxiliar em desafios do meu doutorado, sendo vital para que eu pudesse cumprir uma importante etapa.

A todos os membros do Laboratório de Sistemas Inteligentes (LSI) pela parceria e amizade. Vocês tornaram este laboratório minha segunda casa, onde vivi com muita harmonia e diversão. Somos uma time que só tende a crescer vencer juntos.

Aos meus alunos que pude orientar de uma certa forma e pudemos trocar muitas experiências, sem as quais parte do meu trabalho não poderia ser concretizada.

Ao meu orientador, Prof. Dr. Alessandro Goedtel, pela sua orientação excepcional e por todos os anos de trabalhos que desenvolvemos juntos. Agradeço também ao meu coorientador Prof. Dr. Marcelo Castoldi, por me incentivar e auxiliar em minhas pesquisas quando precisei.

Ao Programa de Pós-Graduação Associado em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná, Cornélio Procópio, pela oportunidade a mim concedida.

Acredite-se

## RESUMO

GUEDES, Jacqueline Jordan. IDENTIFICAÇÃO DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO ALGORITMOS DE OTIMIZAÇÃO E SISTEMAS INTELIGENTES. 145 f. Tese – Programa de Pós-Graduação associado em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2019.

Motores de indução trifásicos são essenciais ao processo produtivo, pois suas características de construção permitem ampla aplicação, incluindo a operação em ambientes hostis. Embora robusto, seu uso contínuo gera desgastes que podem levar a falhas. Dessa forma, pesquisas na área de identificação de falhas são realizadas constantemente visando reduzir taxas de manutenções corretivas e paradas indesejadas, permitindo que seja realizada a manutenção da máquina. Com esse propósito, o presente trabalho propõe o estudo e o desenvolvimento de uma estratégia que utiliza algoritmos de otimização combinados a classificadores inteligentes de padrões para identificação de falhas de curto-circuito nas espiras do estator, barras quebradas de rotor e desgastes de rolamentos em motores de indução trifásicos, utilizando sinais de tensão e corrente de fase, aquisitados no domínio do tempo, bem como o módulo da velocidade. Neste trabalho são utilizados os algoritmos de Evolução Diferencial, *Particle Swarm Optimization* e *Simulated Annealing* para estimar os parâmetros elétricos do motor de indução no modelo do circuito elétrico equivalente. Assim, a identificação da falha ocorre a partir da variação dos parâmetros do circuito elétrico equivalente. A identificação da presença de falha bem como sua classificação é feita por meio dos classificadores de padrões Redes Neurais Artificiais, *Support Vector Machine* e *k-Nearest Neighbor*. A base de dados utilizada para o trabalho foi obtida por meio de experimentos laboratoriais realizados com um motor de 1 CV e um motor de 2 CV, sob condições de variação de conjugado e acionamentos senoidal equilibrado e desequilibrado.

**Palavras-chave:** Motores de Indução Trifásicos, Algoritmos de Otimização, Classificadores de Padrões, Identificação de Falhas, Falhas de Estator, Falhas de Rotor, Falhas de Rolamento.



## ABSTRACT

GUEDES, Jacqueline Jordan. THREE-PHASE INDUCTION MOTOR FAULT IDENTIFICATION USING OPTIMIZATION ALGORITHM AND INTELLIGENT SYSTEMS. 145 f. Tese – Programa de Pós-Graduação associado em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2019.

Three-phase induction motors are essential to the production process, as their construction features allow for wide application, including operation in hostile environments. Although robust, its continuous use generates wear that can lead to failures. Thus, researches in the area of identification of failures are carried out constantly aiming to reduce rates of corrective maintenance and unwanted stops, allowing the machine maintenance. For this purpose, the present work proposes the study and development of a strategy that uses optimization algorithm combined with pattern classifiers to identify short-circuit stator failures, broken bars of rotor and bearing wear in three-phase induction motors, using voltage and phase current signals obtained in the time domain, and the speed module. The algorithms Differential Evolution, Particle Swarm Optimization and Simulated Annealing are used to estimate the electrical parameters of the induction motor using the model of the equivalent electrical circuit and the identification of the failure occurs by variation of these parameters with the evolution of each fault. The classification of each type of failure or its presence is made by pattern classifiers Artificial Neural Network, Support Vector Machine and k-Nearest Neighbor. The database used for the work was obtained through laboratory experiments performed with a motor of 1 HP and 2 HP, under conditions of variation of conjugate of line-connection, including unbalance voltages.

**Keywords:** Three-Phase Induction Motor, Optimization Algorithm, Pattern Classifiers, Fault Identification, Stator Fault, Broken Bars Fault, Bearing Fault.

## LISTA DE FIGURAS

FIGURA 1	– Processo de estimação dos parâmetros do MIT .....	34
FIGURA 2	– Modelo de transformador do motor de indução trifásico .....	35
FIGURA 3	– Circuito elétrico equivalente final do MIT .....	37
FIGURA 4	– Circuito simplificado do MIT .....	38
FIGURA 5	– Processo de <i>crossover</i> do DE .....	43
FIGURA 6	– Processo de mutação, cruzamento e seleção do <i>target vector</i> .....	43
FIGURA 7	– Processo de convergência do PSO .....	45
FIGURA 8	– Funcionamento de busca do SA .....	47
FIGURA 9	– Funcionamento de um neurônio artificial .....	50
FIGURA 10	– Hiperplanos separadores aplicados no SVM .....	52
FIGURA 11	– Exemplo de classificação do k-NN com dois rótulos de classe .....	54
FIGURA 12	– Funcionamento dos algoritmos de otimização DE, PSO e SA .....	55
FIGURA 13	– Organização geral da metodologia proposta .....	57
FIGURA 14	– Bancada experimental: LSI - UTFPR .....	58
FIGURA 15	– Imagem ilustrativa dos <i>taps</i> de derivação .....	61
FIGURA 16	– Imagem representativa da criação de barras quebradas no rotor ...	62
FIGURA 17	– Imagem representativa da criação de barras quebradas no rotor ...	63
FIGURA 18	– Processamento do sinal da corrente .....	64
FIGURA 19	– Fluxograma da utilização dos algoritmos de otimização para identificação de falha .....	68
FIGURA 20	– Classificações realizadas para identificação de múltiplas falhas ....	70
FIGURA 21	– Distribuição do capítulo de resultados .....	74
FIGURA 22	– Caso 1, sem $R_1$ fixo, com erro de 0,49%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado .....	75
FIGURA 23	– Caso 1, sem $R_1$ fixo, com erro de 0,95%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado .....	76
FIGURA 24	– Caso 1, com $R_1$ fixo, ensaio de rotor bloqueado: (a)Erro de 0,56%, (b)Erro de 0,97% .....	77
FIGURA 25	– Caso 2, sem $R_1$ fixo, com erro de 0,47%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado .....	78
FIGURA 26	– Caso 2, sem $R_1$ fixo, com erro de 1,2%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado .....	78
FIGURA 27	– Caso 2, com $R_1$ fixo, ensaio com 0,5Tn: (a)Erro de 2,15%, (b)Erro de 2,93% .....	79
FIGURA 28	– Caso 2, com $R_1$ fixo, ensaio com Tn: (a)Erro de 2,15%, (b)Erro de 2,93% .....	80
FIGURA 29	– Caso 3, sem $R_1$ fixo, com erro de 0,51%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado .....	81
FIGURA 30	– Caso 3, sem $R_1$ fixo, com erro de 0,97%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado .....	81
FIGURA 31	– Caso 3, com $R_1$ fixo, ensaio com rotor bloqueado: (a)Erro de 2,78%, (b)Erro de 3,15% .....	82

FIGURA 32 – Comportamento da corrente com falha de curto-circuito no estator, para o Motor 1 .....	93
FIGURA 33 – Evolução da corrente e indutância com falha de curto-circuito no estator .....	94
FIGURA 34 – Comportamento da corrente com falha de desgaste de rolamento ..	96
FIGURA 35 – Evolução da corrente de estator e indutância de magnetização com falha de rolamento no MIT 1 com tensões equilibradas .....	97
FIGURA 36 – Comportamento da corrente com falha de barras quebradas de rotor	98
FIGURA 37 – Evolução da corrente de estator e indutância de magnetização com falha de rotor no MIT 1, com tensões equilibradas .....	99
FIGURA 38 – Comportamento da indutância de magnetização para identificação geral de presença de falha - operação a vazio .....	100
FIGURA 39 – Amostra do conjunto de dados com todos os tipos de falhas .....	102
FIGURA 40 – Classificação por tipo de combinação AO/Classificador .....	125

## LISTA DE TABELAS

TABELA 1	– Dados de placa dos MITs utilizados nos experimentos, considerando operação com conjugado nominal .....	59
TABELA 2	– Variações de operação impostas ao MIT com acionamento direto .	60
TABELA 3	– Conjuntos de parâmetros estimados para a identificação da falha .	66
TABELA 4	– Espaço de busca utilizado para a estimação de parâmetros .....	67
TABELA 5	– Informações dos Algoritmos de Otimização .....	67
TABELA 6	– Parâmetros do MIT de 1 CV .....	75
TABELA 7	– Testes realizados para estimação de parâmetros .....	83
TABELA 8	– Informações do DE .....	84
TABELA 9	– Médias dos valores de referência para o MIT de 1 CV, utilizando DE .....	84
TABELA 10	– Médias dos valores de referência para o MIT de 2 CV, utilizando DE .....	85
TABELA 11	– Vetores de referência para identificação da falha utilizando o DE .	85
TABELA 12	– Informações do PSO .....	86
TABELA 13	– Médias dos valores de referência para o MIT de 1 CV, utilizando PSO .....	86
TABELA 14	– Médias dos valores de referência para o MIT de 2 CV, utilizando PSO .....	87
TABELA 15	– Vetores de referência para identificação da falha utilizando o PSO	87
TABELA 16	– Informações do SA .....	88
TABELA 17	– Médias dos valores de referência para o MIT de 1 CV, utilizando SA .....	89
TABELA 18	– Médias dos valores de referência para o MIT de 2 CV, utilizando SA .....	89
TABELA 19	– Vetores de referência para identificação da falha utilizando o SA ..	90
TABELA 20	– Vetores de referência para identificação da falhas utilizando os algoritmos de otimização: DE, PSO e SA .....	90
TABELA 21	– Classificação de falhas individuais do Motor 1 utilizando DE/RNA	103
TABELA 22	– Classificação de falhas individuais do Motor 2 utilizando DE/RNA	103
TABELA 23	– Multiclassificação de falhas do Motor 1 utilizando DE/RNA .....	104
TABELA 24	– Multiclassificação de falhas do Motor 2 utilizando DE/RNA .....	105
TABELA 25	– Classificação de falhas individuais do Motor 1 utilizando DE/SVM	106
TABELA 26	– Classificação de falhas individuais do Motor 2 utilizando DE/SVM	106
TABELA 27	– Multiclassificação de falhas do Motor 1 utilizando DE/SVM .....	107
TABELA 28	– Multiclassificação de falhas do Motor 2 utilizando DE/SVM .....	107
TABELA 29	– Classificação de falhas individuais do Motor 1 utilizando DE/k-NN	108
TABELA 30	– Classificação de falhas individuais do Motor 2 utilizando DE/k-NN	108
TABELA 31	– Multiclassificação de falhas do Motor 1 utilizando DE/k-NN .....	109
TABELA 32	– Multiclassificação de falhas do Motor 2 utilizando DE/k-NN .....	109
TABELA 33	– Classificação de falhas individuais do Motor 1 utilizando PSO/RNA	110
TABELA 34	– Classificação de falhas individuais do Motor 2 utilizando PSO/RNA	110

TABELA 35 –	Multiclassificação de falhas do Motor 1 utilizando PSO/RNA	111
TABELA 36 –	Multiclassificação de falhas do Motor 2 utilizando PSO/RNA	111
TABELA 37 –	Classificação de falhas individuais do Motor 1 utilizando PSO/SVM	112
TABELA 38 –	Classificação de falhas individuais do Motor 2 utilizando PSO/SVM	112
TABELA 39 –	Multiclassificação de falhas do Motor 1 utilizando PSO/SVM	112
TABELA 40 –	Multiclassificação de falhas do Motor 2 utilizando PSO/SVM	113
TABELA 41 –	Classificação de falhas individuais do Motor 1 utilizando PSO/k-NN	114
TABELA 42 –	Classificação de falhas individuais do Motor 2 utilizando PSO/k-NN	114
TABELA 43 –	Multiclassificação de falhas do Motor 1 utilizando PSO/k-NN	114
TABELA 44 –	Multiclassificação de falhas do Motor 2 utilizando PSO/k-NN	115
TABELA 45 –	Classificação de falhas individuais do Motor 1 utilizando SA/RNA	116
TABELA 46 –	Classificação de falhas individuais do Motor 2 utilizando SA/RNA	116
TABELA 47 –	Multiclassificação de falhas do Motor 1 utilizando SA/RNA	117
TABELA 48 –	Multiclassificação de falhas do Motor 2 utilizando SA/RNA	117
TABELA 49 –	Classificação de falhas individuais do Motor 1 utilizando SA/SVM	118
TABELA 50 –	Classificação de falhas individuais do Motor 2 utilizando SA/SVM	118
TABELA 51 –	Multiclassificação de falhas do Motor 1 utilizando SA/SVM	118
TABELA 52 –	Multiclassificação de falhas do Motor 2 utilizando SA/SVM	119
TABELA 53 –	Classificação de falhas individuais do Motor 1 utilizando SA/k-NN	119
TABELA 54 –	Classificação de falhas individuais do Motor 2 utilizando SA/k-NN	119
TABELA 55 –	Multiclassificação de falhas do Motor 1 utilizando SA/k-NN	120
TABELA 56 –	Multiclassificação de falhas do Motor 2 utilizando SA/k-NN	120
TABELA 57 –	Acurácia das falhas de estator, considerando o conjunto AO/ Classificador	121
TABELA 58 –	Acurácia das falhas de rotor, considerando o conjunto AO/ Classificador	121
TABELA 59 –	Acurácia das falhas de rolamento, considerando o conjunto AO/ Classificador	122
TABELA 60 –	Acurácia da Multiclassificação 1 (MC), considerando o conjunto AO/ Classificador	122
TABELA 61 –	Acurácia da presença de falha (FNF), considerando o conjunto AO/ Classificador	123
TABELA 62 –	Acurácia da classificação das falhas de estator, rotor e rolamento (E R R), considerando o conjunto AO/ Classificador	123
TABELA 63 –	Acurácia da classificação das falhas de estator ou rotor e rolamento (E RR), considerando o conjunto AO/ Classificador	124
TABELA 64 –	Acurácia da classificação das falhas de rotor e rolamento (R R), considerando o conjunto AO/ Classificador	124
TABELA 65 –	Desempenho dos conjuntos AO/ Classificador	125
TABELA 66 –	Valores de referência para o MIT de 1 CV, utilizando o DE embarcado na DSP	127
TABELA 67 –	Valores de referência para o MIT de 2 CV, utilizando o DE embarcado na DSP	127
TABELA 68 –	Vetores de referência para identificação da falha utilizando o DE embarcado na DSP	127
TABELA 69 –	Classificação da falha de estator utilizando a RNA embarcada na DSP	128

## LISTA DE SIGLAS

AE	Algoritmo Evolutivos
AG	Algoritmos Genéticos
AOs	Algoritmos de Otimização
DE	Evolução Diferencial, do inglês <i>Differential Evolution</i>
DFOC	Controle Direto de Campo Orientado, do inglês <i>Direct Field-Oriented Control</i>
DSP	Processador Digital de Sinais, do inglês <i>Digital Signal Processor</i>
FA	Algoritmo dos Vagalumes, do inglês <i>Firefly Algorithm</i>
FD	Fração dimensional, do inglês <i>Fractal Dimensions</i>
FO	Função Objetivo
FFT	Transformada Rápida de Fourier, do inglês <i>Fast Fourier Transform</i>
k-NN	<i>k-Nearest Neighbour</i>
LSI	Laboratório de Sistemas Inteligentes
MITs	Motores de Indução Trifásicos
MUSIC	Algoritmo de classificação multisinais, do inglês <i>Multiple-Signal Classification</i>
NA	Não se aplica
PMC	<i>Perceptron</i> Multicamadas
PSO	Otimização por Enxame de Partículas, do inglês <i>Particle Swarm Optimization</i>
RBF	Função de Base Radial, do inglês <i>Radial Basis Function</i>
RNAs	Redes Neurais Artificiais
SA	Recozimento Simulado, do inglês <i>Simulated Annealing</i>
SIs	Sistemas Inteligentes
SMO	Otimização Mínima Sequencial, do inglês <i>Sequential Minimal Optimization</i>
SVM	Máquinas de Vetores de Suporte, do inglês <i>Support Vector Machines</i>
TH	Transformada Hilbert
TWC	Transformada Wavelet Contínua
TWD	Transformada Wavelet Discreta
Tn	Torque nominal

## LISTA DE SÍMBOLOS

$V_p$	Tensão de fase de terminal do estator
$I_1$	Corrente do estator
$R_1$	Resistência efetiva do estator
$X_1$	Reatância de dispersão do estator
$L_1$	Indutância de dispersão do estator
$I_M$	Corrente do ramo de magnetização
$X_M$	Reatância do ramo de magnetização
$L_M$	Indutância de magnetização
$I_2$	Corrente do rotor referida ao primário
$E_1$	Tensão induzida do rotor referida ao primário
$a_{ef}$	Relação de espiras do transformador ideal
$E_R$	Tensão induzida do rotor
$I_R$	Corrente do rotor
$R_R$	Resistência efetiva do rotor
$X_R$	Reatância de dispersão do rotor
$s$	Escorregamento do rotor
$\omega_{sinc}$	Velocidade angular síncrona
$\omega_m$	Velocidade angular mecânica
$E_{R0}$	Tensão induzida no rotor bloqueado
$X_{R0}$	Reatância de dispersão no rotor bloqueado
$R_2$	Resistência refletida do rotor
$X_2$	Reatância de dispersão refletida do rotor
$L_2$	Indutância de dispersão refletida do rotor
$Z_{eq}$	Impedância equivalente do MIT
$R_b$	Resistência de estator corrigida pela temperatura
$R_a$	Resistência de estator medida a 25°C
$t_b$	Temperatura de operação atual do ambiente no qual o motor está operando
$t_a$	Temperatura ambiente de referência a 25°C
$k_1$	Constante de proporcionalidade referente ao material (234,5 para o cobre)
$R_{2s}$	Resistência de rotor corrigida pelo efeito pelicular
$R_{21}$	Resistência de rotor medida quando $s = 1$
$R_{22}$	Resistência de rotor medida quando $s = 0$
$L_{2s}$	Indutância de dispersão do rotor corrigida pelo efeito pelicular
$L_{21}$	Indutância de dispersão do rotor medida quando $s = 1$
$L_{22}$	Indutância de dispersão do rotor medida quando $s = 0$
$v_{i,G+1}$	Elemento $i$ da população mutada do DE
$F$	Fator de Ponderação aplicado à diferença vetorial no DE
$x_{r_n,G}$	Cromossomos sorteados no processo de mutação do DE
$Cr$	Taxa de cruzamento do DE
$z_i$	Posição da partícula no espaço de busca do PSO
$p_i$	Posição individual da partícula no PSO

$v_i$	Velocidade da partícula no PSO
$c_1, c_2$	Constantes de ponderação da velocidade no PSO
$p_{bestj}^*$	Melhor posição encontrada por qualquer vizinho da partícula, no PSO
$p_{ij}^*$	Melhor solução encontrada pela partícula que está em movimento, no PSO
$w$	Coefficiente de inércia no PSO
$\chi$	Coefficiente de constrição no PSO
$p$	Probabilidade de aceitação de solução no SA
$T$	Temperatura atribuída ao problema no uso do SA
$\alpha$	Taxa de resfriamento do SA
$\sum$	Combinador linear da RNA
$\theta$	Limiar de ativação da RNA
$u$	Potencial de ativação da RNA
$g$	Função de ativação da RNA
$y_j(k)$	$k - simo$ neurônio da saída da RNA
$d_j(k)$	$k - simo$ resposta desejada na saída da RNA
$E_k$	Erro quadrático da $k - sima$ amostra
$E_M$	Erro médio quadrático da RNA
$\xi$	Variável de folga de redução de erro do SVM
$C$	Parâmetro de custo do SVM
$\varphi(x_i)$	Função de transformação do SVM
$\alpha_i$	Multiplicador de Lagrange do SVM
$I_{estimada}$	corrente obtida por meio dos parâmetros estimados com o AO
$I_{experimental}$	Corrente de referência extraída do MIT
$n$	Dimensão do vetor das correntes analisadas na Função Objetivo



## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>16</b>
1.1 JUSTIFICATIVA .....	20
1.2 OBJETIVOS .....	22
1.3 CONTRIBUIÇÕES .....	23
1.4 ORGANIZAÇÃO DO TRABALHO .....	23
<b>2 FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS</b> .....	<b>25</b>
2.1 INTRODUÇÃO .....	25
2.2 FALHAS DE ESTATOR EM MITS .....	26
2.3 FALHAS DE ROTOR EM MITS .....	28
2.4 FALHAS DE ROLAMENTO EM MITS .....	30
2.5 CONCLUSÃO DO CAPÍTULO .....	32
<b>3 ESTRATÉGIA PARA MONITORAMENTO E DIAGNÓSTICO DE FALHA</b> .....	<b>33</b>
3.1 INTRODUÇÃO .....	33
3.2 MODELAGEM DO MOTOR DE INDUÇÃO TRIFÁSICO .....	34
3.3 ALGORITMOS DE OTIMIZAÇÃO .....	40
3.3.1 Evolução diferencial .....	41
3.3.2 <i>Particle Swarm Optimization</i> .....	44
3.3.3 <i>Simulated Annealing</i> .....	46
3.4 CLASSIFICADORES DE PADRÕES .....	48
3.4.1 Redes Neurais Artificiais .....	49
3.4.2 <i>Support Vector Machines</i> .....	51
3.4.3 <i>k-Nearest Neighbor</i> .....	53
3.5 CONCLUSÃO DO CAPÍTULO .....	54
<b>4 METODOLOGIA</b> .....	<b>57</b>
4.1 INTRODUÇÃO .....	57
4.2 ASPECTOS RELACIONADOS AO CONJUNTO DE DADOS .....	58
4.3 IDENTIFICAÇÃO DOS PARÂMETROS UTILIZANDO ALGORITMOS DE OTIMIZAÇÃO .....	63
4.4 IDENTIFICAÇÃO DA FALHA UTILIZANDO SISTEMAS INTELIGENTES ..	69
4.5 IMPLEMENTAÇÃO DA METODOLOGIA EM <i>HARDWARE</i> .....	71
4.6 CONCLUSÃO DO CAPÍTULO .....	71
<b>5 RESULTADOS EXPERIMENTAIS</b> .....	<b>73</b>
5.1 INTRODUÇÃO .....	73
5.2 IDENTIFICAÇÃO DOS PARÂMETROS DO MIT .....	74
5.2.1 Estimação de Parâmetros utilizando Evolução Diferencial .....	83
5.2.2 Estimação de parâmetros utilizando <i>Particle Swarm Optimization</i> .....	85
5.2.3 Estimação de parâmetros utilizando <i>Simulated Annealing</i> .....	88
5.2.3.1 Resumo da Seção de Estimação de Parâmetros .....	90
5.3 IDENTIFICAÇÃO DE FALHAS .....	91
5.3.1 Comportamento do MIT sob falhas de estator, rotor e rolamento .....	92

5.3.1.1 Falha de Estator .....	93
5.3.1.2 Falhas de Rolamento .....	95
5.3.1.3 Falhas de Rotor .....	98
5.3.1.4 Análise de múltiplas falhas .....	99
5.3.2 Identificação de falhas utilizando os parâmetros estimados com DE .....	103
5.3.2.1 Classificação das falhas utilizando RNA .....	103
5.3.2.2 Classificação das falhas utilizando SVM .....	106
5.3.2.3 Classificação das falhas utilizando k-NN .....	107
5.3.3 Identificação de falhas utilizando os parâmetros estimados com PSO .....	109
5.3.3.1 Classificação das falhas utilizando RNA .....	110
5.3.3.2 Classificação das falhas utilizando SVM .....	111
5.3.3.3 Classificação das falhas utilizando k-NN .....	113
5.3.4 Identificação de falhas utilizando os parâmetros estimados com SA .....	115
5.3.4.1 Classificação das falhas utilizando RNA .....	116
5.3.4.2 Classificação das falhas utilizando SVM .....	118
5.3.4.3 Classificação das falhas utilizando k-NN .....	119
5.3.4.4 Resumo dos Resultados .....	120
5.3.5 Implementação da metodologia proposta em <i>hardware</i> .....	126
5.3.6 Conclusão do capítulo .....	128
<b>6 CONCLUSÃO .....</b>	<b>130</b>
6.1 TRABALHOS FUTUROS .....	131
6.2 PRODUÇÃO CIENTÍFICA .....	131
<b>REFERÊNCIAS .....</b>	<b>133</b>

## 1 INTRODUÇÃO

A utilização de motores de indução trifásicos (MITs) representa 70% do consumo energético industrial, percentual este que corresponde a 30% da energia elétrica total consumida no mundo (SOLEIMANI et al., 2018). A justificativa para sua ampla utilização, está principalmente, em suas características atrativas como a robustez e o baixo custo. Entretanto, o MIT sofre desgastes naturais e, por vezes, pode operar em condições inadequadas, tais como, sobrecarga mecânica, ambientes com excesso de umidade e elevada temperatura. 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; SAUER et al., 2015; LIU; BAZZI, 2017a; YETGIN, 2019).

Dentre os diversos tipos de defeitos aos quais os MITs estão sujeitos, pode-se realizar uma divisão em dois grandes grupos, a saber: falhas elétricas e falhas mecânicas (SINGH et al., 2016). Nas falhas elétricas destacam-se os problemas de estator e rotor, e no grupo de falhas mecânicas podem-se citar os defeitos envolvendo rolamentos, excentricidade, desalinhamento e desgaste de acoplamento. 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; YETGIN, 2019).

A presença de uma falha, ainda que incipiente, pode afetar o desempenho da máquina, gerando prejuízos para o processo produtivo. 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, quando há assimetria nos enrolamentos, a máquina continua em funcionamento com o conjugado reduzido. Embora em operação, quando há uma falha de curto-circuito entre espiras do estator, existe a possibilidade de rápida evolução,

causando um dano irreparável (DRIF; CARDOSO, 2014; BELLINI et al., 2008). Por outro lado, as falhas de rolamento podem evoluir mais lentamente quando comparadas às de estator, mas estudos apontam que esse tipo de anomalia contribui com uma taxa que pode ser superior a 50% das paradas indesejadas (LEITE et al., 2015). Os defeitos de rolamento, na maioria das vezes, estão relacionados à lubrificação inadequada ou problemas de instalação que levam ao desalinhamento e sobrecarga (SINGH; KUMAR, 2017; RIERA-GUASP et al., 2015). Ainda, os defeitos relacionados às barras quebradas de rotor estão em cerca de 10% das falhas ocorridas nas máquinas de indução, cujas causas podem ser relacionadas com condições inadequadas de trabalho ou fissuras mecânicas (HOU et al., 2016).

Essas circunstâncias mostram a necessidade de realizar o 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 em suas características, apresentadas ao longo de seu funcionamento (GHATE; DUDUL, 2010), como a variação da temperatura (GARCIA-RAMIREZ et al., 2014; RESENDIZ-OCHOA et al., 2018), vibrações mecânicas (KONAR; CHATTOPADHYAY, 2015; FILHO et al., 2014; MARTÍNEZ-MORALES et al., 2018), ruídos (GARCIA-PEREZ et al., 2012; GLOWACZ, 2018) ou alterações eletromagnéticas (BARZEGARAN et al., 2013; RAMIREZ-NUNEZ et al., 2018a; VINOOTHRAJ et al., 2018).

Quando se analisa a extração de características, o trabalho de Garcia-Ramirez et al. (2014) apresenta uma forma de usar imagens termográficas para realizar o diagnóstico de falhas em rolamentos, barras quebradas de rotor e desalinhamento, incluindo a realização de testes com variação de carga mecânica e desequilíbrio de tensão de 5%. Já o trabalho de Garcia-Perez et al. (2012) propõe a análise de informações de forma acústica, onde realiza-se posteriormente uma análise espectral de alta resolução baseada no algoritmo de classificação multi-sinais (MUSIC), para a identificação da frequência relacionada ao defeito.

O uso das características presentes nos sinais de corrente, tem sido largamente implementada, pois permitem a identificação de falhas no estator, rotor, rolamento e excentricidade. Os referidos sinais podem ser medidos mediante a utilização de transformadores de corrente ou transdutores de efeito Hall, dispensando a instalação de sensores adicionais, como no caso da temperatura e vibração (DAS et al., 2010; ALTHOBIANI et al., 2013; AHAMED et al., 2014; GARCIA-RAMIREZ et al., 2014; GODOY et al., 2015; BAYRAM; ŞEKER, 2015; ROSHANFEKR; JALILIAN, 2015; PALÁCIOS et al., 2016;

GODOY et al., 2016; SINGH; NAIKAN, 2018; YEKTANIROUMAND et al., 2018).

Com relação ao processamento das características extraídas da máquina, ou seja, a forma como estas são interpretadas, artigos recentes na literatura indicam que o uso de sistemas inteligentes e de otimização têm apresentado resultados promissores. As Redes Neurais Artificiais (RNAs) são utilizadas como classificador de padrões para auxiliar no diagnóstico de falhas, conforme estudos de Palácios et al. (2015), Godoy et al. (2015), Vakharia et al. (2016), Moosavian et al. (2018) e Jigyasu et al. (2019). A Lógica *Fuzzy* também está sendo bastante utilizada para identificação de falhas em máquinas elétricas (RAMOS et al., 2016; CHUDASAMA et al., 2016; DEHGHANI et al., 2016; LAALA et al., 2014; MINI; USHAKUMARI, 2012), assim como os sistemas híbridos (SEERA et al., 2013; BRITO et al., 2002; GNANAPRAKASAM; CHITRA, 2015; SIVAKUMAR; PARVATHI, 2013).

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

O trabalho de Yektaniroumand et al. (2018) aplica Transformada Hilbert (TH) em sinais de corrente para serem utilizados como dados de entrada de uma rede neural de Função de Base Radial (RBF - do inglês *Radial Basis Function*), combinado com um algoritmo de otimização para aprimorar a matriz de pesos sinápticos, a fim de realizar a identificação de barras quebradas do rotor. O método proposto é aplicado a situações de baixo conjugado de carga e são apresentados resultados gráficos que indicam a eficiência da metodologia.

Os Algoritmos de Otimização (AOs) também têm se destacado na literatura para a análise das características extraídas das máquinas, como é o caso dos Algoritmos Evolutivos (AEs) e de Otimização por Enxame de Partículas (PSO - do inglês *Particle Swarm Optimization*), que realizam o monitoramento de falhas por meio da análise de parâmetros do MIT (MEDOUED et al., 2014; DUAN; ŽIVANOVIĆ, 2016; JÚNIOR et al., 2018; YEKTANIROUMAND et al., 2018; GUEDES et al., 2018a).

O artigo de Tretrong et al. (2012) apresenta uma técnica de identificação de parâmetros do motor por meio de Algoritmos Genéticos (AG), com o intuito de diagnosticar falhas em máquinas elétricas. Para a estimativa dos parâmetros de resistência e indutância de estator foram utilizados os dados de velocidade, correntes e tensões trifásicas, aplicados ao modelo de sequência zero. Já no trabalho de Duan e Živanović (2013) são

utilizados dados de corrente (em regime transitório e permanente) para o diagnóstico de falha do estator a partir da análise de parâmetros estimados.

Tendo em vista a atualidade do tema e a necessidade de estudo e monitoramento do diagnóstico de falhas em motores de indução, a proposta deste trabalho consiste em apresentar uma estratégia para o diagnóstico de falhas de curto-circuito entre as espiras do estator, desgastes de rolamento e barras quebradas de rotor.

A análise da situação de operação do motor será investigada a partir das características fornecidas pelos sinais de tensão e corrente de fase, no domínio do tempo, bem como o módulo da velocidade. Para esta Tese será utilizado o acionamento senoidal, com tensões equilibradas e desequilibradas, para diferentes níveis de conjugado de carga, variando de 10% a 120% do Torque nominal ( $T_n$ ).

A estratégia para o diagnóstico da falha é centrada na estimação de parâmetros do circuito elétrico equivalente, em regime permanente, linearizado, do motor de indução trifásico e na análise da variação da indutância de magnetização, parâmetro que representa a interação estator/rotor da máquina.

O processo para a identificação da falha e classificação da mesma pode ser dividido em três etapas, a saber: estimação de um conjunto de parâmetros de referência para o MIT, estimação da variação da indutância de magnetização para cada situação de operação e classificação da falha, considerando os parâmetros estimados e o pico das correntes como entrada ao classificador.

A primeira etapa consiste na utilização de três diferentes algoritmos de otimização para estimar os parâmetros do circuito elétrico equivalente do MIT. Nessa etapa, são utilizados como dados de entrada os sinais adquiridos com o motor operando sem falha. Assim, um vetor de referência é determinado, indicando os parâmetros do circuito elétrico equivalente do MIT - resistência do estator ( $R_1$ ), resistência do rotor ( $R_2$ ), indutância de dispersão do estator ( $L_1$ ), indutância de dispersão do rotor ( $L_2$ ) e indutância de magnetização ( $L_M$ ) - quando este opera em condições saudáveis.

Na segunda etapa, é estimada somente a indutância de magnetização do MIT, utilizando-se todos os dados coletados para que possam ser estabelecidos os parâmetros da máquina em todas as situações de operação. Conforme disposto na Seção 4, a variação da indutância de magnetização apresenta um comportamento característico para cada tipo de falha, possibilitando o diagnóstico da situação de operação da máquina mediante o auxílio de um classificador.

Nessas duas primeiras etapas, ambos os processos são realizados com os algoritmos de otimização DE, PSO e SA, a fim de comparar meta-heurísticas de segmentos diferentes, uma vez que o DE é baseado nos algoritmos evolutivos, o PSO é um algoritmo de comportamento populacional e o SA é baseado no funcionamento da cristalização de materiais metálicos.

Por fim, na última etapa, são utilizados os parâmetros estimados nas etapas anteriores, junto ao valor de pico das respectivas correntes de fase, como dados de entrada para um classificador de padrões, que possibilita apresentar o diagnóstico da operação da máquina. Nessa fase, são analisados o uso de três diferentes classificadores de padrões, a saber: RNA (do tipo Perceptron Múltiplas Camadas), SVM e k-NN. É válido ressaltar ainda, que a estratégia proposta fará a classificação binária para as três falhas estudadas, estator, rotor e rolamento, e a multiclassificação, englobando as amostras sem falha e com falha, totalizando quatro classes distintas. Ainda, é importante frisar que não será realizada a análise de severidade de cada falha.

O uso de diferentes algoritmos de otimização e classificadores de padrões permitirá a combinação de metodologias distintas, a fim de identificar o comportamento de cada conjunto e qual destes apresentam melhor desempenho. O sistema que apresentar melhores resultados será implementado em um Processador Digital de Sinais (DSP, do inglês *Digital Signal Processor*) permitindo o monitoramento *online* da máquina.

## 1.1 JUSTIFICATIVA

O consumo do setor industrial nacional corresponde a, aproximadamente, um terço da energia elétrica produzida pela matriz energética do Brasil. Deste montante, cerca de dois terços estão relacionados a sistemas motrizes (EPE, 2018). Em nível mundial, a utilização dos motores de indução trifásicos sobe para 70% do consumo industrial, consolidando a sua importância (SOLEIMANI et al., 2018).

A manutenção adequada contribui para o aumento da vida útil do motor e também para o processo produtivo, pois com o monitoramento regular dessas máquinas evitam-se paradas não programadas. Ainda, o diagnóstico de falhas incipientes permite a realização de um reparo previamente agendado.

Na maior parte dos casos, as falhas apresentam assinaturas características em sinais como corrente e vibração (BAYRAM; ŞEKER, 2015). Há ainda, os casos em que a medida da temperatura, por exemplo, auxilia o monitoramento da máquina. (GARCIA-

RAMIREZ et al., 2014). Assim, o estudo de métodos que utilizam técnicas de processamento de sinais 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 a possibilidade de aplicação industrial.

Nesse aspecto, os Sistemas Inteligentes (SIs) 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 SIs destacam-se as RNAs, lógica *Fuzzy* e os Algoritmos de Otimização, dentre eles, os bio-inspirados. Com base nestas ferramentas, esse trabalho estuda a identificação de falhas no MIT envolvendo curto-circuito entre espiras do estator, desgaste de rolamento e barras quebradas de rotor. O diagnóstico da falha é realizado por meio dos parâmetros elétricos do circuito equivalente do MIT, que são estimados por três diferentes algoritmos de otimização e os resultados são inseridos em classificadores de padrões distintos, a fim de se estabelecer o *status* de operação da máquina.

Os AOs utilizados foram DE, PSO e SA (Método de Recozimento Simulado - do inglês *Simulated Annealing*). O DE é um método bio-inspirado baseado na teoria da evolução de Darwin, onde há a seleção natural dos mais fortes. Já o PSO, também bio-inspirado, é um algoritmo desenvolvido com base no comportamento de bandos. Por fim, o SA tem como fundamento o processo de recozimento dos metais em busca da criação de cristais perfeitos formados pela partícula do material.

O objetivo de utilizar três algoritmos, de vertentes distintas, é desenvolver uma comparação entre cada um, a fim de identificar qual destes é mais adequado ao problema proposto. Além disso, os três algoritmos citados têm sido explorados na literatura para auxiliar no diagnóstico da falha, foco desta Tese (MEDOUED et al., 2014; ARAUJO et al., 2017; GUEDES et al., 2018a; YEKTANIROUMAND et al., 2018; RODRIGUEZ-GUERRERO et al., 2018; YANG; LI, 2019; TIAN et al., 2019).

Além dos AOs aplicados para a estimação de parâmetros, são utilizados três classificadores de padrões para realizar a detecção identificação do tipo da falha. Foram escolhidos os classificadores RNA, SVM e k-NN, pois possuem características distintas no processo de classificação e também, têm sido aplicados atualmente para o diagnóstico de falhas (RAJAMANY; SRINIVASAN, 2017; PANDARAKONE et al., 2017; SHARMA et al., 2018; JIGYASU et al., 2019).



As técnicas para diagnóstico de falhas e monitoramento *online* evoluíram significativamente. O tipo de manutenção mais utilizado nas indústrias inicialmente era a corretiva, que levava a paradas inesperadas no processo de produção e, conseqüentemente, em perdas financeiras. Entretanto, a manutenção preditiva e centrada na confiabilidade, onde técnicas de monitoramento são aplicadas às máquinas, tem ganhado destaque por possibilitar o monitoramento de um equipamento para que uma manutenção programada ocorra. Desta forma, para que haja um diagnóstico eficiente, é essencial o estudo detalhado do comportamento das falhas que possam ocorrer, bem como suas conseqüências. Além disso, tendo sido desenvolvida uma metodologia eficiente e robusta, a implementação da mesma em um sistema embarcado proporciona o monitoramento da máquina de forma *online* e *in loco*, aumentando sua confiabilidade para operação.

## 1.2 OBJETIVOS

Os objetivos gerais do presente trabalho, consistem em desenvolver um método de diagnóstico de múltiplas falhas em motores de indução trifásicos, incluindo curto-circuito entre as espiras do enrolamento do estator, desgaste de rolamentos e barras quebradas de rotor, acionados diretamente da rede de alimentação, baseado no uso de três algoritmos de otimização (DE, PSO e SA) para estimação de parâmetros elétricos do MIT combinado a um método classificador de padrões para a identificação das falhas.

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

- Estudar na literatura as metodologias aplicadas ao diagnóstico de falhas em MIT com alimentação direta da rede;
- Utilizar e ampliar o banco de dados desenvolvido no Laboratório de Sistemas Inteligentes (LSI) que contém sinais de correntes e tensões de linha dos motores de indução operando em condições sem falhas e com falhas, além de variações de conjugado de carga e desequilíbrio de tensão de alimentação;
- Desenvolver três algoritmos de otimização capazes de estimar os parâmetros reais do MIT, em regime permanente, para criação de uma referência, a fim de compará-los quanto ao seu desempenho para o problema proposto;
- Estudar o comportamento de cada falha com relação à variação dos parâmetros para traçar uma estratégia de detecção de anomalias;

- Utilizar três classificadores de padrões para a identificação de cada falha, além de fazer a multiclassificação das falhas em estudo, com o intuito de comparar qual o melhor método para a identificação de falhas;

### 1.3 CONTRIBUIÇÕES

A proposta deste trabalho, visa contribuir com a literatura na área de monitoramento, diagnóstico e multiclassificação de falhas em motores de indução trifásicos acionados diretamente da rede. O acompanhamento de uma máquina permite a identificação de uma falha incipiente, o que leva à manutenção programada e, conseqüentemente a redução dos custos de produção nas indústrias. Assim, o monitoramento da falha com a metodologia proposta poderá contribuir para:

- Monitorar e diagnosticar um MIT alimentado diretamente da rede baseado em algoritmos de otimização e sistemas inteligentes, que sejam capazes de identificar o estado de operação da máquina, numa ampla faixa de carga mecânica;
- Investigar a robustez da metodologia proposta, para identificação e classificação de falha em motores operando em regime senoidal, inicialmente com tensões equilibradas e, na seqüência, com tensões desequilibradas em até 2%;
- Identificar o estimador de parâmetros e classificador de padrões mais adequados ao conjunto de dados estudados, de forma a buscar o melhor método de diagnóstico e monitoramento da falha.

### 1.4 ORGANIZAÇÃO DO TRABALHO

A seqüência deste trabalho está organizada em 6 capítulos; a saber: no Capítulo 2 é apresentado o estado da arte sobre as principais falhas em MIT, com destaque para falhas de estator, rolamento e rotor, bem como as estratégias presentes na literatura para o monitoramento e diagnóstico destes tipos de defeitos.

No Capítulo 3 são expostos os conceitos fundamentais que serão implementados na metodologia para a estimação dos parâmetros e classificador de padrões.

O Capítulo 4 apresenta a metodologia proposta para identificação de classificação de falhas, bem como a criação dos dados de entrada do classificador, que será obtida a partir dos resultados da estimação dos parâmetros da máquina de indução.

Ainda, o Capítulo 5 apresenta e discute os resultados experimentais dos testes realizados com a metodologia estudada, com o intuito de validar o método. Por fim, o Capítulo 6 descreve as conclusões relativas a esta Tese e as perspectivas para trabalhos futuros após a defesa.

## 2 FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

### 2.1 INTRODUÇÃO

As técnicas de monitoramento e diagnóstico de falhas em motores de indução são temas de pesquisas recentes apresentadas na literatura. Assim, este capítulo apresenta alguns estudos relacionados às áreas que propõem estratégias para identificar falhas em máquinas elétricas, tendo como motivação a redução de gastos com manutenções desnecessárias e o aumento da confiabilidade no processo produtivo.

As principais falhas relacionadas aos MITs são divididas em mecânicas e elétricas (HENAO et al., 2014), sendo os defeitos em rolamentos, a principal falha mecânica (SUTAKE, 2012; LOPES et al., 2016; BAZAN et al., 2019). Já para as falhas elétricas, os defeitos relacionados a estator são os mais frequentes, representando 37% das falhas totais em MITs (DRIF; CARDOSO, 2014; EFTEKHARI et al., 2014), seguido pelas falhas de rotor com 10% do total (ANTONINO-DAVIU et al., 2013; BESSAM et al., 2016).

O monitoramento e o diagnóstico de um MIT é baseado em informações extraídas da máquina, que são devidamente tratadas, para que suas características permitam uma análise confiável. Existem diversos sinais que podem ser coletados para estudo, dentre os quais podem-se destacar os sinais de vibração (KONAR; CHATTOPADHYAY, 2015; AMEZQUITA-SANCHEZ et al., 2017), temperatura (PICAZO-RÓDENAS et al., 2015), fluxo de dispersão eletromagnético (MIRZAEVA et al., 2017; VINOThRAJ et al., 2018), acústicos (DELGADO-ARREDONDO et al., 2017), tensão e corrente (HOU et al., 2016; GARCIA-CALVA et al., 2017; TREJO-CABALLERO et al., 2017; MONFARED et al., 2019).

A extração correta das características dos sinais coletados, tem igual importância à aquisição, pois é a partir de informações específicas que se torna possível um diagnóstico eficiente do MIT. Um processo matemático que tem grande destaque na extração de características são as transformadas, como é o caso da Transformada Rápida de Fourier (FFT - do inglês *Fast Fourier Transform*) (DRIF; CARDOSO, 2014), TH (YEKTANI-

ROUMAND et al., 2018), Transformada Walvetet Discreta (TWD) (AHAMED et al., 2014) ou Transformada Walvetet Contínua (TWC) (MONFARED et al., 2019). Além dos métodos que utilizam transformadas, outras técnicas de extração podem ser destacadas, como a teoria da informação (BAZAN et al., 2019) e os algoritmos meta-heurísticos (GNANAPRAKASAM; CHITRA, 2017; YEKTANIROUMAND et al., 2018; GUEDES et al., 2018a).

Na busca pela automatização da identificação de falhas em máquinas elétricas, os SIs têm se destacado na utilização como classificadores de padrões, os quais contribuem significativamente para o diagnóstico eficiente de anomalias. Dentre estes, podem ser mencionadas as RNAs, como a *Perceptron* Multicamadas (PMC) (GODOY et al., 2016; BESSAM et al., 2016; JIGYASU et al., 2019), RBF (YEKTANIROUMAND et al., 2018) e, ainda, as técnicas SVM (DAS et al., 2010; PANDARAKONE et al., 2017) e k-NN (GODOY et al., 2018).

Nas seções a seguir são apresentadas algumas formas de identificação e diagnóstico de falhas, com ênfase para falhas de estator, rolamento e rotor, as quais são estudadas neste trabalho.

## 2.2 FALHAS DE ESTATOR EM MITS

As falhas de curto-circuito no enrolamento do estator resultam do dano causado à isolação dos condutores da bobina, as quais são originadas principalmente devido ao sobreaquecimento, vibração ou sobretensão. A evolução desse tipo de dano leva ao rompimento da isolação dos condutores, o que gera 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, consideravelmente maior do que a corrente de condições normais de operação, o isolamento se degrada progressivamente, podendo levar a uma falha irreparável rapidamente (RIERA-GUASP et al., 2015).

Pelo fato da falha de estator interferir diretamente na sua corrente, o uso desse tipo de sinal se torna atrativo para a identificação dessa anomalia. Entretanto, também existem outras componentes que permitem o diagnóstico eficiente relacionado à falha de estator.

No trabalho de Filho et al. (2014), o diagnóstico da falha de estator ocorre por meio de uma combinação entre 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.

Recentemente em Mirzaeva et al. (2017), é discutido o uso de um sistema *online* para diagnosticar as principais falhas elétricas por meio de medições da densidade de fluxo do entreferro de um MIT. Tais medidas são obtidas por meio de sensores de fluxo de efeito Hall. O sistema proposto mostrou ser adequado para aplicações de MITs, pois apresentou ter alta sensibilidade às falhas, imunidade a ruído e tolerância às variações de carga do motor.

Utilizando a TH e a TWD, Ahamed et al. (2014) propõem 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 numa bancada de ensaios, onde as referidas correntes de linha 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) propõe o diagnóstico da falha de estator com alimentação direta da rede ou por inversor de frequência, comparando 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 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.

Utilizando a técnica SVM, 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.

Considerando o modelo em regime permanente do MIT, o trabalho de Berzoy et al. (2017) propõe a utilização de uma indutância de dispersão no estator e uma resistência que modele a falta de curto-circuito no mesmo. Dessa forma, a detecção da falha é dada pela análise da variação do fluxo eletromagnético. Para o desenvolvimento do método, o circuito proposto foi simulado com variações de carga e de níveis de falha e a validação ocorreu, experimentalmente, com um motor de iguais características. Os resultados mostraram, graficamente, que é possível a identificação da falta por meio da variação dos parâmetros.

Artigos recentes na literatura, apontam que o uso de sistemas inteligentes, dos quais pode-se citar os classificadores de padrões, têm apresentado resultados promissores. No trabalho de Konar e Chattopadhyay (2015) houve a combinação da TWC e TH com AG para extrair as características de sinais de vibração não estacionários. Ainda o referido trabalho, combinou a utilização de algoritmos de otimização com sistemas inteligentes quando fez o uso de classificadores PMC, RBF e SVM para o diagnóstico das falhas.

Também fazendo o uso da RNA, Godoy et al. (2015) apresentam 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.

Utilizando algoritmos de otimização, no trabalho de Duan e Živanović (2016) são utilizados dados de corrente (em regime transitório e permanente) para diagnóstico de falha do estator a partir da análise de parâmetros estimados por algoritmos genéticos combinada a algoritmos de reconhecimento de padrões.

Ainda, o trabalho de Guedes et al. (2018a) propõe uma estratégia para identificação e classificação de falha de curto-circuito de estator, a partir da estimação dos parâmetros elétricos do MIT e análise do desvio percentual da indutância de magnetização, tendo como referência, os valores estimados em situação de operação saudável e equilibrada. O estudo é realizado com três motores diferentes e o acionamento é feito diretamente da rede elétrica.

### 2.3 FALHAS DE ROTOR EM MITS

As falhas em rotores do tipo gaiola de esquilo podem ocorrer em forma de trincas ou rompimento das barras que decorrem de esforços, como vibrações provenientes de rolamentos danificados ou ainda por defeitos em conexões, entre outros (HENAO et al., 2014; RIERA-GUASP et al., 2015; YEKTANIROUMAND et al., 2018). Como consequência, pode haver oscilação no conjugado, aumento de vibração e redução na dinâmica da máquina, incluindo também, frequências adicionais que geram não-linearidades no sinal da corrente e é repassado ao estator como uma carga desequilibrada (GODOY et al., 2018). Além disso, as falhas de rotor correspondem ao segundo maior índice de falhas elétricas em MITs, e por esse motivo têm sido bastante exploradas, uma vez que o diagnóstico precoce da mesma contribui para manter o bom desempenho da máquina.

O trabalho de Monfared et al. (2019) propõe o uso da TWC para criar um espectro da corrente de estator no domínio da frequência que seja capaz de identificar falhas de

barras quebradas de rotor. Ainda, o algoritmo é capaz de distinguir um motor saudável de um motor com falha, baseado em um sistema próprio, envolvendo elementos finitos. Os dados utilizados foram coletados em regime permanente para diferentes condições de conjugados de carga.

Também utilizando transformadas, o trabalho de Ramirez-Nunez et al. (2018b) analisa o transitório do fluxo de dispersão eletromagnético medido por sensores, para identificar falhas de rotor por meio de FFT e TWD, com o motor acionado por diversas frequências. Os resultados apresentados mostraram graficamente a possibilidade de identificar a presença dessa anomalia.

Já em Gyftakis et al. (2016) foi apresentada uma estratégia para identificação de barras quebradas de rotor de MITs, utilizando a decomposição espectral da sequência zero da corrente. Foram aplicados diferentes níveis de conjugado de carga e de desequilíbrio de tensão, além de dois níveis de falhas - 1 ou 2 barras quebradas. Os resultados comprovaram que a metodologia proposta se destaca para a identificação de falhas, pois esse tipo de assinatura é mais expressiva do que os espectros de corrente de linha dos motores.

Ainda, o trabalho de Garcia-Calva et al. (2017) utiliza a ferramenta MUSIC para obter o espectro da frequência-espacial dos sinais de tensão e corrente amostrados no domínio do tempo. A ferramenta permite identificar as componentes características de falhas de barras quebradas de rotor. A utilização dessa abordagem apresentou-se satisfatória por ter produzido um padrão das assinaturas dessas falhas. Também utilizando MUSIC, o trabalho Trejo-Caballero et al. (2017) propõe um método de otimização multi-objetivo que permite detectar a frequência de falha no sinal de corrente. Foram realizados testes envolvendo a operação em regime permanente, com acionamento direto da rede com apenas um nível de conjugado de carga.

Em Ramirez-Nunez et al. (2018a), os autores analisaram o fluxo de dispersão no momento da partida para a identificação de falhas de rotor e desalinhamento simultâneas. Para isso, são aplicadas ferramentas avançadas de processamento de sinais e ainda utilizadas as transformadas de Fourier e TWD. Os resultados mostraram que a técnica é eficaz, principalmente para complementar o diagnóstico de tais falhas.

As técnicas envolvendo sistemas inteligentes para a detecção de falhas em rotores também têm se mostrado promissoras, em avanços recentemente apresentados na literatura. Em Bessam et al. (2016) é feito o uso da TH para diagnosticar falhas de barras quebradas no rotor, onde a referida ferramenta serve para analisar os envoltórios dos sinais correntes em uma RNA. Os resultados mostraram a capacidade de identificar



a quantidade de barras quebradas no rotor (0, 1 ou 2) para diferentes níveis de torque.

No trabalho de Amezquita-Sanchez et al. (2017) é utilizado um sistema de detecção de falhas que necessita das características de vibração informadas no momento da partida e em regime estacionário. O método para a detecção é dividido em duas etapas, onde a análise preliminar é realizada a partir dos sinais de vibração coletados em três pontos distintos, usando a técnica de Fração Dimensional (FD). Após a aplicação da FD, utiliza-se um sistema baseado em lógica *Fuzzy* para analisar as duas situações de operação e identificar automaticamente o nível da falha. Para esse trabalho, foram testados três níveis de falhas distintos e a taxa de acerto para o diagnóstico correto ficou entre 95% e 100%.

Dias e Sousa (2018) propuseram uma estratégia para identificação e classificação de falhas de barras quebradas de rotor. Para isso, foi utilizado um sistema neuro-*fuzzy*, que realiza a identificação da falha a partir das características extraídas da variação de densidade de fluxo, medida com o uso de um sensor de efeito Hall entre os enrolamentos do estator. A extensão de análises considerou as operações a vazio e nominal em um motor de 1 CV.

Considerando um sistema de monitoramento *online*, no artigo de Hou et al. (2016) foi proposto um método embarcado num Processador Digital de Sinais (DSP - do inglês *Digital Signal Processor*) capaz de diagnosticar barras quebradas de rotor, incluindo sua severidade. Tal análise se torna possível por meio do comportamento das componentes fundamentais e de bandas laterais dos sinais de correntes e de tensões das máquinas.

Também utilizando uma técnica *online*, o trabalho de Bednarz e Dybkowski (2018) propõe a modelagem da falha de rotor como uma resistência adicional no circuito elétrico equivalente da máquina, na qual opera com um Controle Direto de Campo Orientado (DFOC - do inglês, *Direct Field Oriented Control*). Para a investigação da falha, a variação do fluxo estimado foi analisada em casos experimentais e simulados, onde constatou-se graficamente que o valor da resistência de rotor aumenta proporcionalmente à quantidade de barras quebradas.

## 2.4 FALHAS DE ROLAMENTO EM MITS

Os defeitos em rolamentos são inicialmente distribuídos com rugosidades e ondulações que podem evoluir para desgastes de pista interna ou externa, defeitos nos elementos rolantes ou na gaiola do rolamento. O surgimento desse tipo de falha pode ocorrer mesmo

com o uso adequado da máquina, por fadiga ou desgaste, mas pode ser agravado por situações externas como lubrificação inadequada, excesso de carga mecânica e temperaturas elevadas (LIU; BAZZI, 2017b; CERRADA et al., 2018).

As falhas de rolamentos são a maior causa de manutenção corretiva no ambiente industrial. Por esse fator, são amplamente estudados no meio acadêmico. Uma forma usual de detecção desse tipo de falha é por meio de análise de vibração mecânica, onde a falha pode ser identificada em um espectro de frequência com a FFT do sinal adquirido. Outra forma de aquisição que tem crescido no meio de identificação de falhas de rolamento é o uso das correntes de estator, principalmente sua análise no domínio da frequência (NGUYEN et al., 2008; LEITE et al., 2015).

No trabalho de Picazo-Ródenas et al. (2015) é proposta uma forma que combina o uso de dados de correntes de linha e de temperatura para monitorar falhas, inclusive de rolamentos. O diagnóstico ocorre em dois estágios, sendo o primeiro baseado na aquisição dos sinais de corrente por meio de amperímetro e posterior análise no domínio da frequência. Em caso de diagnóstico inconclusivo, o segundo estágio realiza a análise das imagens termográficas obtidas por meio de uma câmera infravermelha. Embora possa apresentar custo elevado devido à medição de temperatura, comprovou-se que a metodologia pode ser aplicada independente da potência do motor.

Utilizando sinais de vibrações, em Nguyen et al. (2008) é apresentado o desenvolvimento de uma técnica baseada em AG para a classificação de defeitos relacionados às falhas de rolamento, como folga e desgaste. Para o trabalho, foram coletados os sinais de vibrações nos três sentidos (axial, horizontal e vertical) e, a partir da extração de suas características, utilizou-se uma estratégia baseada no critério de distâncias junto com o AG, para combinar os dados da melhor forma possível e contribuir para que o sistema de diagnóstico proposto se torne mais rápido e efetivo.

Em Leite et al. (2015), foram utilizados algoritmos baseados na metodologia *kurtosis* espectrais, como a kurtograma rápida e a kurtograma *Wavelet* dos sinais de corrente para identificar a severidade de desgaste na pista externa do rolamento. Ainda, utilizando a técnica de *kurtosis* espectrais, Dalvand et al. (2016) utilizaram a técnica para obter a frequência instantânea da tensão para a detecção de defeitos em rolamentos. Os resultados experimentais, indicaram a capacidade da metodologia proposta em revelar a existência de falhas de rolamentos.

Também com o intuito de identificar defeitos de pista externa em rolamentos, o artigo de Pandarakone et al. (2017) sugere a identificação destes defeitos por meio da

seleção de frequências de falhas no espectro de corrente do estator. Os autores utilizaram essas frequências como matriz de entrada das SVM para a classificação das falhas. Ainda utilizando a técnica SVM, o trabalho de Martínez-Morales et al. (2018) extrai características dos sinais de corrente e vibração, incluindo variações de frequência e torque, para identificar falhas mecânicas, com ênfase para rolamentos. Os testes foram realizados experimentalmente e apresentaram uma taxa de acerto entre 84% e 100%.

Em Delgado-Arredondo et al. (2017), os pesquisadores utilizaram os sinais acústicos para a detecção de falhas de rolamentos e barras quebradas do rotor dos MITs. As análises realizadas nos sinais acústicos, demonstraram a capacidade na identificação das frequências associadas às falhas, quando comparada às análises realizadas por meio de sinais de vibração.

## 2.5 CONCLUSÃO DO CAPÍTULO

Este capítulo apresentou o estado da arte do tema trabalhado, ou seja, as recentes pesquisas que estão presentes na literatura sobre falhas de máquinas elétricas. Os defeitos relacionados ao estator, rotor e rolamento somam mais de 80% de todas as falhas apresentadas por um MIT, principal máquina do setor industrial. Com a revisão destacada, é possível concluir que o tema abordado é crescente e inclui sistemas inteligentes e de otimização na sua solução. Além disso, verifica-se o aumento da busca por métodos que utilizam sensores não-invasivos e de baixo custo, possibilitando o adequado funcionamento e uma operação confiável desses motores. O próximo capítulo descreve a modelagem do motor de indução trifásico, a qual é essencial para o desenvolvimento deste trabalho.

### 3 ESTRATÉGIA PARA MONITORAMENTO E DIAGNÓSTICO DE FALHA

#### 3.1 INTRODUÇÃO

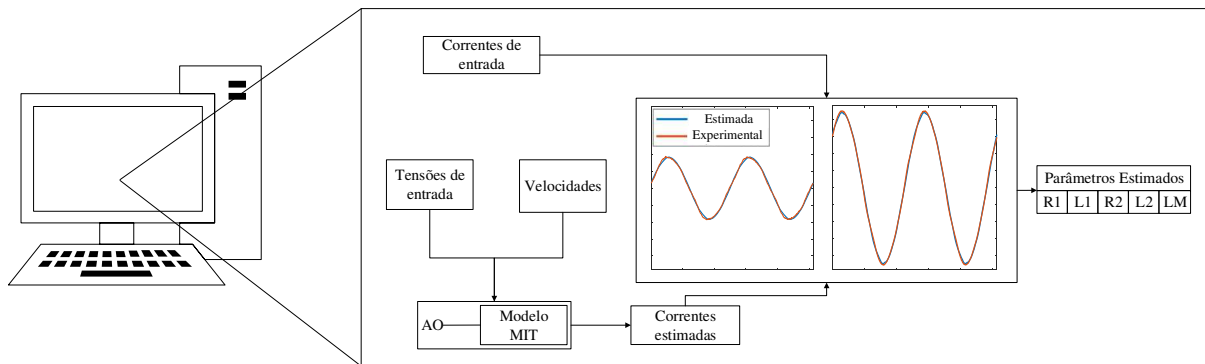
A busca por metodologias que possibilitem a identificação de falhas em máquinas elétricas, ainda que incipientes, é um tema amplamente estudado na literatura, pois o diagnóstico precoce de uma falha pode evitar grandes danos ao processo industrial (BELLINI et al., 2008; CAPOLINO et al., 2015; SINGH; KUMAR, 2017; ABDALLAH; BENATMAN, 2017; MOOSAVIAN et al., 2018; BAZAN et al., 2019; JIGYASU et al., 2019).

Dessa forma, este trabalho visa apresentar uma metodologia para o monitoramento e o diagnóstico das principais falhas de um MIT - estator, rotor e rolamento - por meio da estimação de parâmetros elétricos do mesmo com algoritmos de otimização, combinada a classificadores de padrões inteligentes para a identificação da falha.

Os dados experimentais utilizados foram coletados de modo a contemplar o maior número de situações que podem ser encontradas no ambiente industrial, incluindo ampla variação de conjugado de carga. Todos os dados foram coletados com a máquina operando em regime permanente e com acionamentos diretamente da rede. Vale ainda ressaltar que para a aquisição de dados com acionamento senoidal, foram aplicados níveis de desequilíbrio de tensão de até 2%. Assim, este capítulo aborda o princípio de funcionamento dos algoritmos de otimização e classificadores de padrões que foram implementados no desenvolvimento da metodologia proposta, para a identificação e multiclassificação de falhas a partir de alimentação direta da rede.

Mais especificamente, no presente trabalho, objetiva-se a identificação das falhas de estator, rotor e rolamento por meio dos sinais de corrente e de tensão da máquina além do valor, em módulo, da velocidade de operação no instante da aquisição do sinal. Tais medidas serão utilizadas como dados de entrada para uso dos algoritmos otimização: DE, PSO e SA. Estes algoritmos têm por objetivo identificar os valores dos parâmetros

elétricos da máquina, como as 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 e o módulo da velocidade serão utilizados como entrada do circuito elétrico equivalente, o qual determina os parâmetros estimados por meio das medidas de corrente. Os dados de corrente servem então para comparação com os sinais gerados a partir dos parâmetros estimados. A Figura 1 ilustra o processo de estimação.



**Figura 1:** Processo de estimação dos parâmetros do MIT

**Fonte:** Autoria própria

### 3.2 MODELAGEM DO MOTOR DE INDUÇÃO TRIFÁSICO

Esta seção descreve o comportamento do motor de indução trifásico a partir da análise do circuito elétrico equivalente monofásico de sequência positiva. Este circuito permite o estudo das características eletromecânicas do MIT, bem como o efeito da carga apresentado para a fonte de energia em regime permanente. Tem-se assim, informações suficientes para a estimação de parâmetros do MIT. O circuito elétrico equivalente, em regime permanente, é empregado na simulação de falhas em motores de indução trifásicos, principalmente para falhas de curto-circuito de estator (SIDDIQUE et al., 2005; BELLINI et al., 2008; DEVI et al., 2015; ABDALLAH; BENATMAN, 2017; GUEDES et al., 2018a; MAJUMDAR et al., 2019).


O motor de indução trifásico é composto por um estator e um rotor, que pode ser do tipo bobinado ou gaiola de esquilo. O estator é constituído de um enrolamento trifásico, com defasagem de  $120^\circ$  entre as fases. Já o rotor do MIT em gaiola de esquilo apresenta como principais vantagens sua simplicidade e robustez de construção em relação ao rotor bobinado, o que faz com que este seja o tipo de motor mais utilizado nas indústrias e, por

isso, alvo de estudo nesse trabalho (KRAUSE et al., 2013).

A principal diferença entre um motor de indução e um motor de corrente contínua ou síncrono é a ausência da corrente contínua (CC) no campo 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). O enrolamento trifásico distribuído uniformemente em torno do corpo do MIT, faz com que o fluxo magnético resultante da aplicação de tensão alternada no enrolamento do estator produza uma forma de onda espacialmente senoidal e, por consequência, a onda eletromagnética torna-se uma função senoidal no tempo.

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 da 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 de rotor, sendo ambos conectados por meio de um transformador ideal, conforme Figura 2.



**Figura 2:** Modelo de transformador do motor de indução trifásico

**Fonte:** Adaptado de Krause et al. (2013)

Na Figura 2,

$V_p$  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. Aplicando-se a lei das malhas para o circuito do estator, a tensão de fase de terminal pode ser descrita por (1).

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

Considerando a lei das malhas ao circuito do rotor, tem-se (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 rotor;

$\omega_{sinc}$  é a velocidade angular síncrona;

$\omega_m$  é a velocidade angular mecânica.

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

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

Em outra forma, pode-se representar (5) por (6),

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

onde:

$E_{R0}$  é tensão induzida no rotor bloqueado;

$X_{R0}$  é a reatância de dispersão no rotor bloqueado.

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 para o primário, conforme (7), (8), (9) e (10).


$$I_2 = \frac{I_R}{a_{ef}} \quad (7)$$

$$E_1 = a_{ef} E_{R0} \quad (8)$$

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

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

A Figura 3 apresenta o circuito elétrico equivalente final do motor de indução trifásico, por fase, formado pelos cinco parâmetros elétricos da máquina.



**Figura 3:** 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 4 mostra o circuito elétrico equivalente em sua forma mais simplificada, representado matematicamente em (12).

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

evidenciando a corrente

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



**Figura 4:** Circuito simplificado do MIT

**Fonte:** Autoria própria

A modelagem apresentada nesta seção, considera a operação da máquina somente em regime permanente e em condições ideais. Entretanto, há dois efeitos que devem ser discutidos, pois alteram os parâmetros da máquina, sendo eles: a temperatura e o efeito pelicular. A temperatura tem sua principal influência na resistência de estator, conforme apresentado em IEEE (2018), e essa variação é dada por (14):

$$R_b = \frac{R_a(t_b + k_1)}{t_a + k_1} \quad (14)$$

onde:

$R_b$  é resistência de estator corrigida pela temperatura;

$R_a$  é resistência de estator medida a 25°C;

$t_b$  é a temperatura de operação atual do ambiente no qual o motor está operando;

$t_a$  é a temperatura ambiente de referência a 25°C;

$k_1$  é a constante de proporcionalidade referente ao material (234,5 para o cobre).

Considerando uma resistência de estator para um motor de 1 CV na ordem de  $12\Omega$ , a variação da temperatura ocasiona o aumento na resistência aproximado de  $0,38\%/^{\circ}\text{C}$ . Essa variação da resistência devido ao aumento da temperatura pode ser estimada mesmo sem a modelagem apresentada em (14). O artigo de Guedes et al. (2016) apresenta um estudo demonstrando que a variação da resistência decorrente da temperatura é refletida na estimação dos parâmetros da máquina, quando o método de otimização DE foi utilizado.

Do mesmo modo, o efeito pelicular influencia na resistência de rotor, bem como na indutância de dispersão do rotor e pode ser calculado por (15) e (16), conforme Akbaba e Fakhro (1992):

$$R_{2s} = R_{22} + s.(R_{21} - R_{22}) \quad (15)$$

$$L_{2s} = L_{22} + s.(L_{21} - L_{22}) \quad (16)$$

onde:

$R_{2s}$  é a resistência de rotor corrigida pelo efeito pelicular;

$R_{21}$  é a resistência de rotor medida quando  $s = 1$ ;

$R_{22}$  é a resistência de rotor medida quando  $s = 0$ ;

$L_{2s}$  é a indutância de dispersão do rotor corrigida pelo efeito pelicular;

$L_{21}$  é a indutância de dispersão do rotor medida quando  $s = 1$ ;

$L_{22}$  é a indutância de dispersão do rotor medida quando  $s = 0$ .

Ainda, em Akbaba e Fakhro (1992) são apresentados os parâmetros descritos nas Equações (15) e (16) para motores de 100 a 2250 HP. Analisando os parâmetros apresentados e considerando a variação de escorregamento de 0,01 a 0,03 (valores aproximados aos dos motores utilizados nesta Tese), foi obtida a variação máxima de 0,8% para a indutância de dispersão do rotor e 2,0% para a resistência do rotor. Da mesma forma que a variação da resistência de estator devida à temperatura pode ser estimada sem a necessidade de uma modelagem específica, para a resistência e indutância de dispersão do rotor ocorre o mesmo, ou seja, os AOs são capazes de estimar os valores de  $R_2$  e  $L_2$  sem a modelagem do efeito pelicular.

Considerando uma situação hipotética de extrapolação, onde  $\Delta T = 50^{\circ}\text{C}$  com

um escorregamento de 5%, a alteração das resistências devido aos efeitos pelicular e de temperatura, representam uma variação de 5% quando aplicada ao cálculo da impedância equivalente, que será utilizada nesta Tese. Desta forma, considerando que ambos os efeitos podem ser refletidos na estimação dos parâmetros do circuito elétrico do MIT, não foram consideradas a modelagem de temperatura e do efeito pelicular nesta metodologia.

A seção a seguir apresenta o funcionamento dos algoritmos de otimização DE, PSO e SA, onde o modelo apresentado será utilizado para estabelecer a função objetivo.

### 3.3 ALGORITMOS DE OTIMIZAÇÃO

Esta seção apresenta o funcionamento dos algoritmos de otimização DE, PSO e SA. De uma forma geral, os algoritmos de otimização podem ser utilizados para auxiliar na resolução de problemas combinatórios complexos, cuja solução não pode ser obtida analiticamente ou o custo computacional para a tal, torna o método analítico inviável. Assim, o problema a ser tratado é transformado em um conjunto de objetivos que devem ser maximizados ou minimizados, de acordo com a necessidade do mesmo, considerando um conjunto de restrições (YANG, 2010; TALBI, 2009).

Nesta Tese, os algoritmos de otimização possuem a fundamental importância de estimar os parâmetros do circuito elétrico equivalente, do motor de indução trifásico. Os referidos parâmetros serão apresentados a classificadores de padrões para a identificação de diversos tipos de falhas que prejudicam o funcionamento da máquina.

A escolha de três algoritmos de otimização diferentes (DE, PSO e SA) tem o intuito de verificar qual destas metodologias melhor se encaixa na estimação de parâmetros, ou seja, se adapta ao problema proposto.

O algoritmo de Evolução Diferencial possui sua fundamentação na teoria da evolução e é considerado um algoritmo bio-inspirado, assim como o PSO, que por sua vez é baseado no comportamento de bandos presentes na natureza. A utilização de ambos na estimação de parâmetros elétricos e mecânicos dos motores de indução trifásicos, tem se consolidado e, em alguns casos, é comum a comparação entre os dois métodos para esse tipo de problema (GIRI et al., 2010; ÇANAKOĞLU et al., 2014; BHOWMICK et al., 2016; KHANG et al., 2017).

Já o *Simulated Annealing* é um algoritmo de otimização baseado no resfriamento de metais em busca da formação de cristais perfeitos de um conjunto de átomos aquecidos, e tem como uma de suas principais características, a possibilidade de aceitar soluções

piores dos que as encontradas para escapar de ótimos locais. A utilização deste algoritmo vem apresentando um aumento, conforme consta na literatura, e já é utilizado tanto na estimação de parâmetros referentes ao motor de indução quanto na identificação da falha, sendo também comparado com algoritmos como o PSO ou AG (XU et al., 2013; WANG; LIU, 2018; MARTIN-DIAZ et al., 2018).

Assim, no contexto desta Tese, as próximas seções apresentam os fundamentos do DE, PSO e SA.

### 3.3.1 EVOLUÇÃO DIFERENCIAL

O DE é um algoritmo inspirado na teoria da evolução de Darwin, que faz uso de conceitos como adaptação, aprendizado, auto-organização, competição e cooperação de um conjunto de soluções, a fim de selecionar qual delas melhor se adapta ao sistema (YANG et al., 2013). Além disso, o DE possui a característica de generalização para resolução de problemas, permitindo que um mesmo algoritmo seja utilizado em diversos sistemas, de diferentes áreas, apenas com pequenas adaptações aos objetivos das restrições desejadas (TOMASZEK; ZELINKA, 2019).

O princípio de funcionamento da Evolução Diferencial considera uma população que passa por um processo iterativo, tornando-a mais apta para sobreviver no ambiente em que habita. Essa população é composta por um conjunto de cromossomos que representam possíveis soluções, onde cada uma contém as variáveis que devem ser estimadas para solucionar um problema, que é denominado Função Objetivo (FO) (PRICE et al., 2006).

Cada cromossomo é testado na FO e o seu grau de aptidão para a resolução do problema é denominado *fitness*. Após testado o grau de aptidão de cada indivíduo separadamente, inicia-se um processo iterativo a partir de uma mutação, onde as características do cromossomo (material genético) podem sofrer alterações e passar a obter informações ainda não existentes na população. Um outro processo de modificação é dado pelo cruzamento, que combina diferentes cromossomos para a criação de uma nova solução candidata. Ao término do processo, os melhores indivíduos são selecionados (de acordo com os melhores *fitness*) até que se obtenha uma solução desejada (SHARMA et al., 2019).

A inicialização dos vetores é dada de forma aleatória, respeitando um conjunto de valores, que correspondem a um intervalo em que a solução pode ser encontrada. Assim, é necessário saber quais são as variáveis ou os parâmetros que se deseja estimar, e a

região em que os mesmos estão. Após a construção da população, cada cromossomo é avaliado individualmente para a obtenção do seu *fitness*. Os parâmetros do cromossomo são inseridos na Função Objetivo, que corresponde a representação do problema a ser otimizado, para que seja calculado o grau de aptidão de cada um dos vetores da população.


O processo de mutação é responsável por selecionar três indivíduos da população inicial aleatoriamente, onde determina-se a diferença vetorial entre dois cromossomos e aplica-se a essa resultante um fator de ponderação, seguido pela soma com o terceiro indivíduo selecionado, conforme apresentado em (17).

$$v_{i,G+1} = x_{r_1,G} + F.(x_{r_3,G} - x_{r_2,G}) \quad (17)$$

onde  $v_{i,G+1}$  é o elemento  $i$  da população mutada;  $F$  é o fator de ponderação aplicado à diferença vetorial;  $x_{r_1,G}$ ,  $x_{r_2,G}$  e  $x_{r_3,G}$  são os cromossomos sorteados aleatoriamente. O cromossomo que está sofrendo a mutação é denominado *target vector* e espera-se que todos os cromossomos sejam ao menos uma vez *target vector*.

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 1, maior será a perturbação, evitando que as soluções fiquem presas em regiões locais. Esse tipo de mutação é o mais comum no algoritmo DE, no entanto, há outras formas de realizar esse processo (ENGELBRECHT; PAMPARA, 2007; TANABE; ISHIBUCHI, 2019; SUN et al., 2019), que não serão abordadas por não serem utilizadas no presente trabalho .

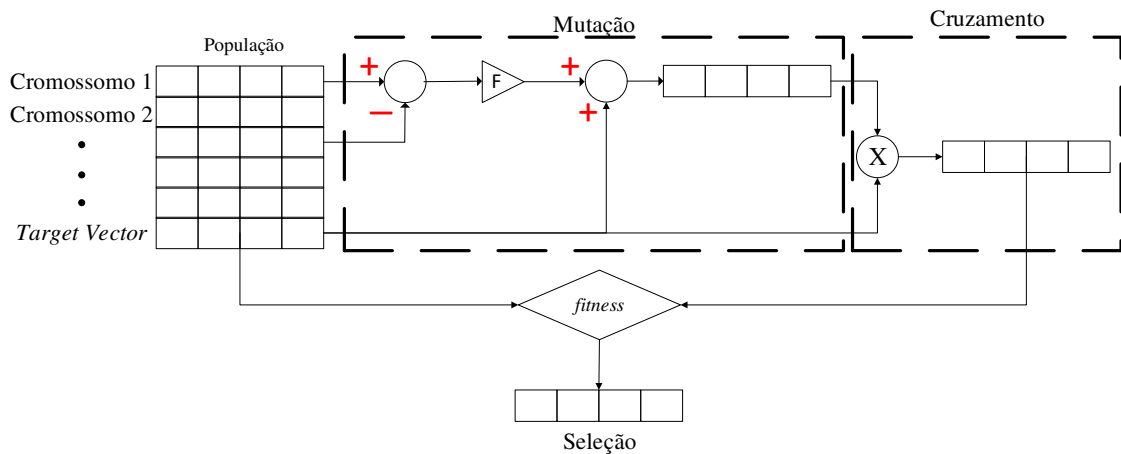
O processo seguinte à mutação é o cruzamento, que ocorre entre a população mutada e o população inicial. Nesta etapa, o *target vector* é cruzado com o seu vetor modificado para gerar um novo cromossomo na busca de melhorar sua aptidão. Desta forma, cria-se um vetor aleatório, entre 0 e 1, com o mesmo número de elementos dos cromossomos. Então, define-se a taxa de cruzamento, também um valor 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 à taxa de cruzamento, seleciona-se o elemento da população mutada, caso contrário, seleciona-se o do *target vector*, conforme apresentado na Figura 5.



**Figura 5:** Processo de *crossover* do DE

**Fonte:** Autoria própria

Ao término do processo de cruzamento, a nova população é aplicada na FO para análise do grau de aptidão de cada cromossomo. Esse processo não garante que o cromossomo, após sofrer a mutação e o cruzamento, seja melhor do que o *target vector*. Para isso, compara-se então ambos os *fitness* e seleciona-se, entre os dois, o que tiver maior grau de aptidão, conforme apresentado na Figura 6.



**Figura 6:** Processo de mutação, cruzamento e seleção do *target vector*

**Fonte:** Autoria própria

O processo apresentado ocorre de forma iterativa até que alguma resposta satisfaça o critério de parada para que o algoritmo seja finalizado e, então, a resposta fornecida ao usuário.

Uma outra abordagem utilizada para o DE é a utilização dos cromossomos de forma binária. Nesse caso, um único parâmetro pode ser escrito em um vetor de  $n$  posições para permitir uma melhor varredura no espaço de busca, a fim de buscar melhores soluções para o problema proposto (PAMPARA et al., 2006; WANG et al., 2012; ZHANG et al., 2020).

### 3.3.2 PARTICLE SWARM OPTMIZATION

O PSO é um algoritmo desenvolvido por Kennedy em 1995 e é inspirado no comportamento social de espécies que trabalham em conjunto, como o posicionamento dos pássaros durante um voo de migração ou busca de alimentos. O desenvolvimento do estudo desse comportamento pode ser aplicado à otimização de funções complexas, onde cada indivíduo representa uma potencial solução do problema e, em conjunto, buscam os melhores pontos, compartilhando informações sobre o espaço explorado (KENNEDY, 2010).

A movimentação de cada partícula ( $i$ ), de um enxame de  $N$  indivíduos, pode ser escrito com base em três informações postas em vetores, a saber: sua posição no espaço de busca ( $\mathbf{z}_i = [z_{i1} z_{i2} \dots z_{iD}]$ ), a melhor posição que cada indivíduo encontrou ( $\mathbf{p}_i = [p_{i1} p_{i2} \dots p_{iD}]$ ) e sua respectiva velocidade ( $\mathbf{v}_i = [v_{i1} v_{i2} \dots v_{iD}]$ ). As primeiras posições e velocidades são atribuídas aleatoriamente dentro de um intervalo de busca pré-definido e a atualização é calculada pelas Equações (18) e (19),

$$v_{ij}^{(it+1)} = v_{ij}^{(it)} + c_1 r_1 (p_{ij}^* - z_{ij}^{(it)}) + c_2 r_2 (p_{bestj}^* - z_{ij}^{(it)}) \quad (18)$$

$$z_{ij}^{(it+1)} = z_{ij}^{(it)} + v_{ij}^{(it+1)} \quad (19)$$


onde  $c_1$  e  $c_2$  são constantes de ponderação tipicamente ajustadas em 2,  $r_1$  e  $r_2$  são números aleatórios independentes no intervalo  $[0 1]$ , os quais são gerados a cada iteração para cada dimensão individual  $j$ ,  $p_{bestj}^*$  é a melhor posição encontrada por qualquer vizinho da partícula e  $p_{ij}^*$  é a melhor solução encontrada pela partícula que está em movimento (KENNEDY, 2010; JUNEJA; NAGAR, 2016; ELBES et al., 2019).

Após o processo de iteração apresentado, a atualização ocorre baseada no valor do *fitness* para cada vetor. Considerando que o problema abordado seja de minimização, a reconstrução do novo vetor é dada por (20),

$$p_i^{*(it+1)} = \begin{cases} p^{*(it)} & \text{se } F(p^{*(it)}) \leq F(z^{(it+1)}) \\ z^{(it+1)} & \text{se } F(p^{*(it)}) > F(z^{(it+1)}) \end{cases} \quad (20)$$

A última atualização a ser realizada é a do  $p_{best}^{*(it+1)}$  que assume o valor  $p^{*(it)}$  com melhor *fitness*. Em uma análise geral, a escolha do número de indivíduos encontra-se geralmente no intervalo  $[20 100]$  (BRATTON; KENNEDY, 2007). A Figura 7 apresenta

um exemplo da convergência do PSO.



**Figura 7:** Processo de convergência do PSO

**Fonte:** Autoria própria

Existem ainda melhorias que foram descobertas ao longo do estudo do PSO, que podem ser utilizadas para melhorar a convergência e evitar que a solução atinja os limites do espaço de busca ou ainda um mínimo global. Dentre essas melhorias podem-se destacar o coeficiente de inércia  $w$  e o coeficiente de constrição  $\chi$ .

O coeficiente de inércia influencia na velocidade das partículas anteriores durante o processo de otimização. Quanto maior seu valor, maior é a capacidade do algoritmo explorar novas regiões. Entretanto, se  $w$  for muito elevado a busca local pode não acontecer. Desta forma, deve ser estabelecido um valor que permita ambas as possibilidades (local e global), sem cair nos limites de busca (EBERHART; SHI, 2000; LEE; EL-SHARKAWI, 2008). O ajuste da velocidade com o coeficiente de inércia é descrito em (21),

$$v_{ij}^{(it+1)} = wv_{ij}^{(it)} + c_1r_1(p_{ij}^* - z_{ij}^{(it)}) + c_2r_2(p_{bestj}^* - z_{ij}^{(it)}) \quad (21)$$

Já o coeficiente de constrição influencia em todas as parcelas do cálculo da nova velocidade. A determinação deste parâmetro é dada com base no valor  $a$ , dependente de  $c_1$  e  $c_2$ . A descrição do coeficiente de constrição é dada por (22).

$$\chi = \frac{2}{|2 - a - \sqrt{a^2 - 4a}|}, a = c_1 + c_2 \quad (22)$$

A partir do estudo desse coeficiente, foi observado que para um valor de  $a < 4$ , o enxame gira lentamente em espiral sem garantir a convergência para uma solução satisfatória. Porém, quando  $a > 4$ , a convergência é rápida e garantida. Assim, por conveniência,



atribui-se  $c_1 = c_2 = 2,05$  para que haja uma conversão garantida (EBERHART; SHI, 2000; LEE; EL-SHARKAWI, 2008). Então, a nova velocidade é dada por (23),

$$v_{ij}^{(it+1)} = \chi[v_{ij}^{(it)} + c_1 r_1 (p_{ij}^* - z_{ij}^{(it)}) + c_2 r_2 (p_{bestj}^* - z_{ij}^{(it)})] \quad (23)$$

Como critério de parada para o algoritmo, geralmente é estabelecido um valor aceitável para a FO tratada ou, ainda, um número máximo de iterações (ELBES et al., 2019).

### 3.3.3 SIMULATED ANNEALING

O algoritmo SA é um método de otimização desenvolvido por Kirkpatrick et al. (1983) e Černý (1985). Após o estudo do modelo da mecânica estatística para simular processos de recozimento de metais, proposto em Metropolis et al. (1953), Kirkpatrick e Černý observaram que a mesma teoria poderia ser estendida para a resolução de problemas de otimização em geral, especialmente a combinatorial.

A explicação física para o processo de funcionamento do SA, baseia-se na busca pelo estado de energia mínima ou estado de energia fundamental de um sistema. Essa situação é obtida por um método de recozimento (*annealing*), onde um sólido, por exemplo, é aquecido até seu ponto de fusão e então resfriado gradual e vagarosamente até alcançar seu enrijecimento. O processo lento de resfriamento deve manter o equilíbrio térmico, para que os átomos consigam se reorganizar em uma estrutura uniforme com energia mínima. Em materiais líquidos, esse processo de resfriamento leva a um arranjo das partículas denominado cristal.

Uma grande vantagem do método SA é o fato de poder escapar de ótimos locais. Isso ocorre, pois o algoritmo analisa a vizinhança da solução, aceitando uma alternativa que traga melhoras, mas também admitindo soluções que piorem a atual. A condição de aceitação de um movimento que forneça uma resposta pior, é dada por uma sequência de números randômicos, envolvendo uma probabilidade controlada (KIRKPATRICK et al., 1983).


Diferente do DE e PSO, o SA é iniciado com apenas uma solução candidata aleatória, a partir da qual deseja-se minimizar a energia dos elementos do vetor que a compõe, por meio de uma FO. Os critérios para a aceitação de uma nova solução são dois, dados pelas Equações (24) e (25):

$$\Delta = f(i) - f(i - 1) < 0 \quad (24)$$

$$p = e^{-\Delta/T} > \text{random}(0, 1) \quad (25)$$

onde  $\Delta$  é a diferença entre o resultado da FO atual e anterior,  $p$  é a probabilidade de aceitação da nova solução e  $T$  é a temperatura atribuída ao problema.

O primeiro caso implica que se  $\Delta < 0$ , então a nova solução é melhor que a atual. Já para o segundo caso, somente será aceita uma solução pior se o valor de  $p$  for maior do que um valor aleatório obtido entre 0 e 1. Quanto maior for a temperatura atribuída inicialmente, maior é a chance de movimentos aceitos e à medida que  $T$  tende a 0, maior parte das soluções são rejeitadas. A Figura 8 apresenta o comportamento do algoritmo SA na busca de uma solução.



**Figura 8:** Funcionamento de busca do SA

Fonte: Autoria própria

O resfriamento ou a redução da temperatura é dada por (26),

$$T_{k+1} = \alpha T_k \quad (26)$$

onde  $\alpha$  é um parâmetro usualmente no intervalo  $[0,8 \ 0,99]$ . Quanto menor o valor de  $\alpha$ , mais rápido o resfriamento e a convergência, o que pode levar às soluções que não correspondem ao ótimo global. Por outro lado, se o valor do parâmetro for muito próximo de 1, a temperatura reduz lentamente, com melhores chances para uma solução de ótimo global, porém com maior tempo de execução (TSUZUKI; MARTINS, 2014).

A tendência de convergência do SA para um ótimo global ocorre quando não há limite de tempo para convergência. Entretanto, não é interessante um algoritmo com iterações e tempo tendendo para o infinito. Assim, estabelece-se que o algoritmo deve parar quando estiver congelado, ou seja, quando há uma possibilidade mínima ou nula de mudança da solução em que se encontra.

Uma alternativa a este problema, consiste em estabelecer um critério de parada para quando a solução mantém-se a mesma para  $x$  vezes, ou seja, se por  $x$  vezes consecutivas a solução for a mesma, o algoritmo é encerrado. Outra alternativa é estabelecer um tempo máximo de processamento, ou seja, um número máximo de iterações (TSUZUKI; MARTINS, 2014).

Nesta seção foi apresentado o fundamento dos algoritmos de otimização DE, PSO e SA. Estes algoritmos serão utilizados nesta Tese para a estimação dos parâmetros do circuito elétrico equivalente do MIT, a fim de que estes sejam utilizados para a detecção de falhas em máquinas elétricas. O processo de identificação da falha ocorrerá por meio da utilização dos classificadores de padrões RNA, SVM e k-NN. Assim, a seção a seguir apresenta a fundamentação teórica de cada classificador.

### 3.4 CLASSIFICADORES DE PADRÕES

Os classificadores de padrões são algoritmos desenvolvidos capazes de separar determinado conjunto de dados em um número de categorias ou classes, de modo que cada categoria tenha um padrão distinto. Essa separação ocorre a partir de informações de propriedades ou características fornecidas ao classificador.

O uso de classificadores de padrões vem sendo amplamente empregado na identificação de falhas em máquinas elétricas, dos quais podem-se destacar a RNA, SVM e k-NN (GODOY et al., 2015; PATEL; GIRI, 2017; PALÁCIOS et al., 2017; MARTÍNEZ-MORALES et al., 2018; BAZAN et al., 2019).

A escolha de três classificadores com características diferentes permitirá a identificação do melhor método para a classificação de falhas em motores de indução trifásicos a partir da metodologia proposta. Nessa seção são apresentados os princípios de funcionamento dos classificadores RNA, SVM e k-NN, respectivamente.

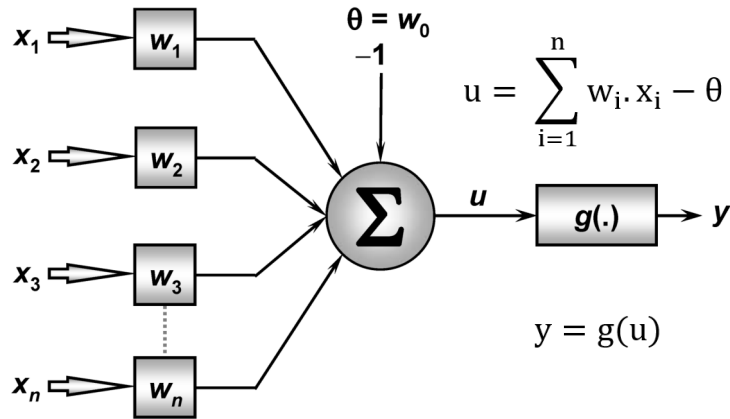
### 3.4.1 REDES NEURAIIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) constituem um modelo computacional inspirado no funcionamento do cérebro humano e sua capacidade de adquirir conhecimento por meio de experiências. Uma grande vantagem das RNAs, que permite ampla aplicação em problemas de engenharia, é o fato de não necessitar do modelo matemático específico de um problema (SILVA et al., 2017; HAYKIN, 2008).

Existem diversas topologias de RNAs, dentre as quais pode ser citada a rede *Perceptron* Multicamadas (PMC). As redes PMC possuem alta versatilidade, permitindo com que sejam aplicadas a diversos tipos de problemas, de diversas áreas, como a aproximação universal de funções e reconhecimento de padrões. Uma de suas características que deve ser destacada é a arquitetura *feedforward*, onde o fluxo de informações é unidirecional e vai da camada de entrada em direção à camada de saída. Além disso, deve-se evidenciar também que a RNA do tipo PMC possui ao menos uma camada neural escondida entre a entrada e a saída, além de permitir múltiplas saídas, o que amplia a gama de problemas que podem ser abordados (SILVA et al., 2017; CAMARENA-MARTINEZ et al., 2014; SEDIKI et al., 2013).

Uma RNA é composta por alguns elementos que proporcionam o seu funcionamento. Os dados apresentados a uma rede são as informações a serem classificadas (sinais de entrada). Em seguida, esses valores são ponderados por pesos sinápticos ( $w_i$ ), quantificando sua relevância em relação à funcionalidade do neurônio. Atribui-se inicialmente um peso sináptico, geralmente um valor aleatório entre 0 e 1, para cada conexão sináptica da rede.

Então, um combinador linear ( $\sum$ ) combina os pesos sinápticos com as respectivas entradas e um limiar de ativação ( $\theta$ ), que determina um valor apropriado para que o resultado do combinador linear gere um valor para a saída do neurônio. Esse processo gera um potencial de ativação ( $u$ ), que corresponde a diferença entre os valores do combinador linear e do limiar de ativação. Por fim, esse potencial é inserido em uma função de ativação ( $g$ ), a fim de limitar a saída ( $y$ ) do neurônio em um intervalo específico, adaptável ao problema estudado (HAYKIN, 2008). A Figura 9 apresenta o funcionamento de um neurônio artificial.



**Figura 9:** Funcionamento de um neurônio artificial

Fonte: Adaptado de Silva et al. (2017)

A determinação dos pesos ideais que devem ser aplicados na rede é realizada por meio de um processo de treinamento, denominado *backpropagation* ou retropropagação do erro. Neste algoritmo cada amostra de entrada possui uma resposta desejada, e pode ser dividida em duas fases, sendo a primeira responsável por apresentar as amostras às entradas na rede, que são propagadas, camada a camada, até a saída. Na segunda fase, comparam-se as respostas obtidas e desejadas para que seja possível alterar os pesos sinápticos e limiares, com base no valor do erro. Assim, há o ajuste de pesos e limiares a cada iteração, que implica a redução da soma dos erros progressivamente, até que o critério de parada com relação ao erro seja atingido (HAYKIN, 2008).

O valor do erro, em cada amostra, é obtido calculando-se o erro quadrático e o erro quadrático médio. O desempenho local associado aos resultados produzidos pelos neurônios de saída frente à referida amostra é dado por (27),

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_i} (d_j(k) - y_j(k))^2 \quad (27)$$

onde  $y_j(k)$  é o valor do  $j$ -ésimo neurônio de saída da rede, considerando a  $k$ -ésima amostra de treinamento e  $d_j(k)$  seu valor correspondente desejado. A resultante do desempenho global em um conjunto de treinamento composto por  $p$  amostras é dada pelo erro quadrático médio, definido em (28),

$$E_M = \frac{1}{p} \sum_{k=1}^p (E(k)) \quad (28)$$

No presente trabalho, a RNA será utilizada como classificadora de padrões para auxiliar na identificação de falhas de estator, rotor e rolamento em motores de indução trifásicos, devido à sua consolidada aplicação em problemas correlacionados (BELLINI et al., 2008; GODOY et al., 2016; RAJAMANY; SRINIVASAN, 2017; PALÁCIOS et al., 2017; PATEL; GIRI, 2017; GODOY et al., 2018; BAZAN et al., 2019).

### 3.4.2 SUPPORT VECTOR MACHINES

As Máquinas de Vetores de Suporte, do inglês, *Support Vector Machines* (SVMs) foram desenvolvidas por Vladimir Vapnik e baseiam-se em teorias estatísticas. Assim como a RNA, o SVM utilizado para esse trabalho também possui treinamento supervisionado, onde são apresentados exemplos para máquina com suas respectivas respostas, a fim de que esta seja capaz de classificar novas amostras com a mesma distribuição de probabilidade dos exemplos de treinamento (VAPNIK, 2013).

As SVMs mapeiam dados de treinamento, com suas respectivas respostas, a partir do espaço de entrada em um espaço maior de características dimensionais, via função Kernel, para que seja possível a construção de um hiperplano de separação com margem máxima do espaço de características (BERGMAN, 1970).

O treinamento desse método envolve a otimização de uma função quadrática convexa, a qual consiste num problema matemático com poucos parâmetros livres para ajuste por parte do usuário e sem dependência explícita na determinação da dimensão da entrada do problema. Nesse processo de otimização é encontrado um peso para os parâmetros  $w$  e *bias*  $b$ , pois a partir destes, obtém-se a maximização das margens de cada hiperplano, garantindo uma boa classificação para as amostras do conjunto. Dessa forma, o cálculo do hiperplano de separação ideal é dado pela resolução do seguinte problema das Equações (29) e (30):

$$\frac{\min \|w^2\|}{2} + C \sum_{i=1}^n \xi_i \quad (29)$$

sujeito a:

$$\begin{aligned} y_i(w^2 \varphi(x_i) + b) &\leq 1 - \xi_i \\ \xi &\geq 0, i = 1, \dots, N \end{aligned} \quad (30)$$

sendo  $\xi \geq 0, i = 1, \dots, N$  as variáveis de folga empregadas na redução do erro de clas-

sificação do conjunto de treinamento;  $C$  o parâmetro de custo utilizado no ajuste da compensação entre a quantidade de erros aceitos e  $\varphi(x_i)$  a função de transformação.

Para a resolução do problema de programação quadrática apresentado utiliza-se o Multiplicador de Lagrange,  $\alpha_i \geq 0, i = 1, \dots, N$ , obtendo-se um problema dual dado pelas Equações (31) e (32):

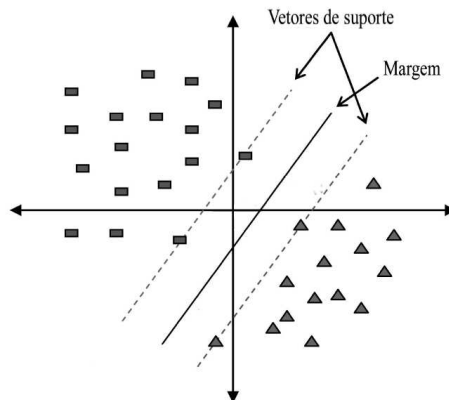
$$\frac{\max \sum_{i=1}^n \alpha_i - (\sum_{i=1}^n \sum_{j=1}^j \alpha_i \alpha_j y_i y_j k(x_i, y_j))}{2} \quad (31)$$

sujeito a:

$$\sum_{i=1}^j \alpha_i y_i = 0$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, N \quad (32)$$

Uma abordagem para treinamento do SVM é a Otimização Mínima Sequencial (SMO), que leva o conceito de segmentação para o limite extremo e considera dois multiplicadores de Lagrange por vez (PLATT, 1998). A Figura 10 apresenta o exemplo dos hiperplanos de suporte ótimo que separa o conjunto de amostras em duas classes distintas.



**Figura 10:** Hiperplanos separadores aplicados no SVM

**Fonte:** Autoria Própria

Como pode ser observado na Figura 10, o conjunto amostral do exemplo foi separado em dois hiperplanos lineares. No entanto, o SVM também pode ser aplicado a problemas não-lineares, e nesse caso, primeiro deve-se mapear os dados em um grande espaço de características dimensionais  $F$  (PLATT, 1998). Além disso, o SVM é considerado essencialmente um classificador de duas classes e a aplicação para multiclassificação vem sendo estudada por meio de combinações de múltiplas SVMs (BISHOP, 2006).

O uso do SVM/SMO tem se mostrado promissor na classificação de falhas em máquinas elétricas (PANDARAKONE et al., 2017; MARTÍNEZ-MORALES et al., 2018; SINGH; SHAIK, 2019). Neste trabalho, o SVM é um dos classificadores utilizados para a identificação de falhas individuais e múltiplas falhas no motor de indução trifásico.

### 3.4.3 *K-NEAREST NEIGHBOR*

O classificador k-NN é um método não-paramétrico que se fundamenta na análise de semelhança entre um conjunto de validação e seu respectivo conjunto de treinamento. A classificação por essa metodologia ocorre de acordo com as distâncias entre uma amostra desconhecida e outras amostras de treinamentos já pré-rotuladas. Quando a maioria dos dados mais próximos à amostra a ser classificada são de uma classe específica, então esta nova amostra também pertence à referida classe (DUDA et al., 2012).

Os conjuntos de treinamento desse algoritmo possuem  $n$  atributos e localizam-se em determinado ponto de um espaço  $n$ -dimensional. Dessa forma, na presença de uma amostra desconhecida, o classificador busca o espaço padrão para os  $k$  conjuntos estabelecidos no treinamento que encontram-se mais próximos da amostra a ser classificada. Essa proximidade é dada pela distância Euclidiana entre esses conjuntos ( $X_1$  e  $X_2$ ), conforme (33):


$$dist(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (33)$$

Na classificação de padrões utilizando o k-NN, o conjunto ou amostra desconhecida é atribuído à classe comum entre seus  $k$ -vizinhos mais próximos. Se  $k = 1$  o conjunto desconhecido é atribuído à classe do conjunto de treinamento mais próxima do seu espaço padrão. Uma consideração importante a ser feita, é que os dados devem ser normalizados para evitar que as medidas de distância sejam dominadas por um único atributo (SURAJ; DELIMATA, 2006).

A determinação de  $k$  é dada pelo usuário e corresponde ao único parâmetro livre a ser ajustado, de modo a se obter uma classificação adequada ao problema proposto. A escolha de um valor muito pequeno para esse parâmetro pode ocasionar em uma classificação sensível a pontos de ruídos, e um valor muito grande tende a incluir elementos de outra classe. Ainda, é sugerida a escolha de um valor ímpar para evitar empates nas análises (ZHANG; SONG, 2014). A Figura 11 apresenta um exemplo da identificação de



uma amostra desconhecida com o uso do  $k$ -NN.



**Figura 11:** Exemplo de classificação do  $k$ -NN com dois rótulos de classe

**Fonte:** Autoria Própria

Como pode ser observado na Figura 11, foi estabelecido o valor de  $k = 5$  para realizar a classificação da amostra desconhecida. Nesse caso, os 5 vizinhos mais próximos englobam as duas classes possíveis de serem classificadas e, por se tratar de um número ímpar, há três vizinhos de um conjunto pré-rotulado (círculo) e dois do outro conjunto (triângulo). Por haver mais vizinhos da classe círculos próximos, então, a amostra desconhecida também é classificada como círculo.

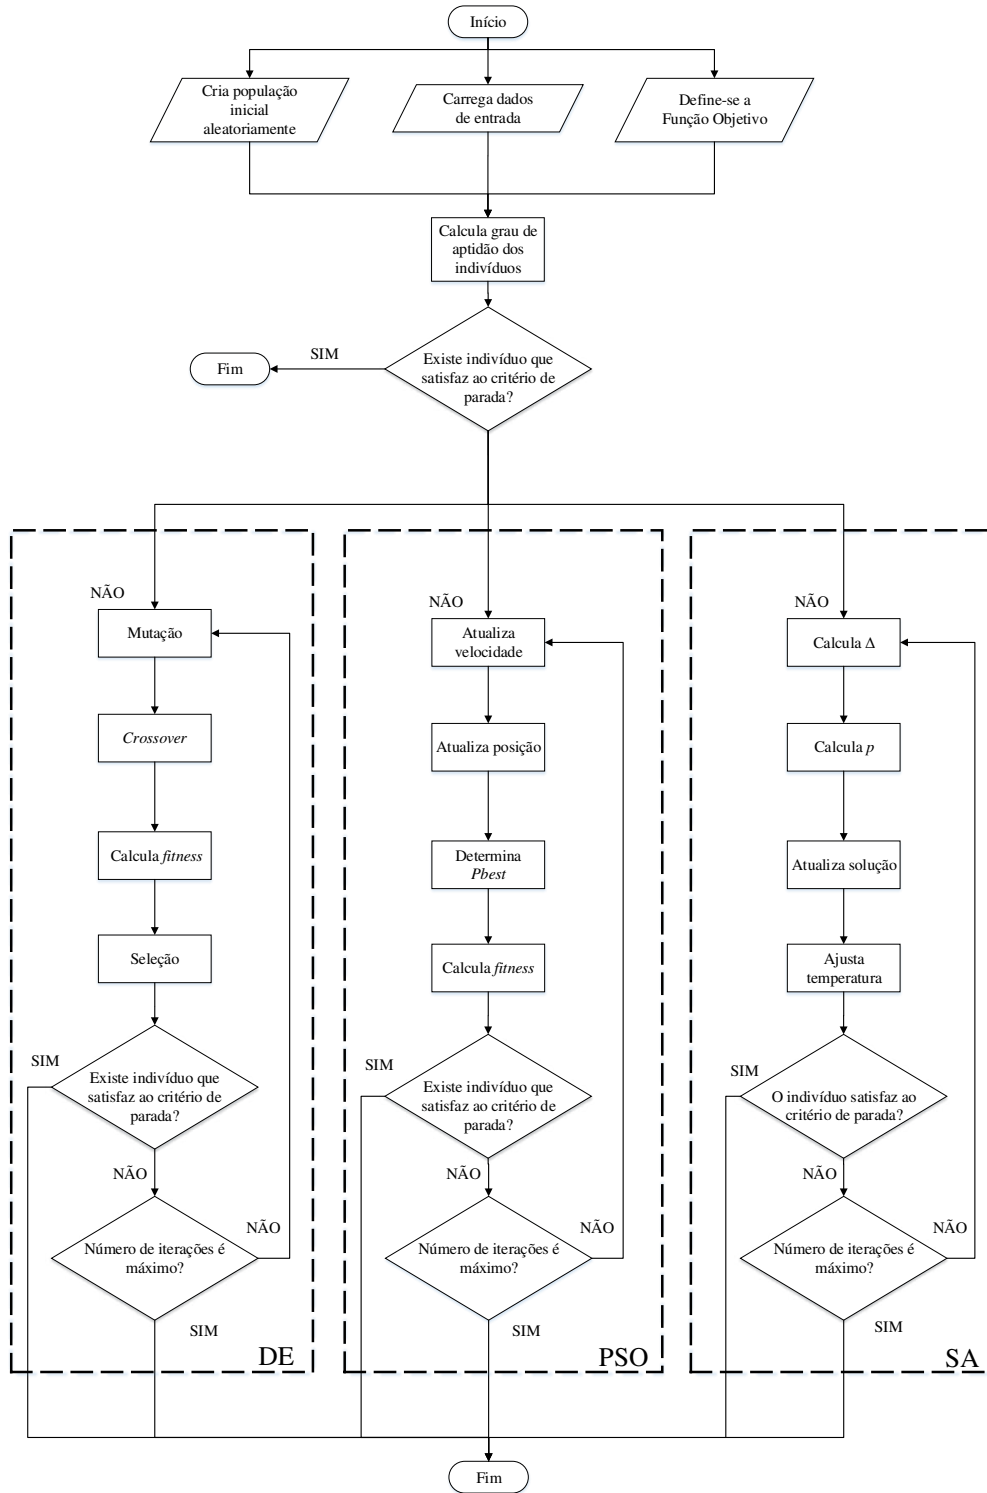
Neste trabalho o algoritmo  $k$ -NN é o terceiro classificador de padrões utilizado, a fim de se estabelecer uma comparação com a RNA e o SVM, e identificar qual o melhor classificador para a metodologia proposta. A seguir é apresentada a conclusão deste capítulo.

### 3.5 CONCLUSÃO DO CAPÍTULO

Neste capítulo foram apresentadas as ferramentas que são utilizadas no desenvolvimento da metodologia proposta para a identificação de falhas do MIT. No primeiro momento, a modelagem do MIT foi apresentada, pois a compreensão do circuito elétrico equivalente auxilia na interpretação da FO que será aplicada aos algoritmos de otimização, e também esclarece a necessidade da utilização dos dados de tensão, corrente e velocidade mencionados. Por meio da modelagem matemática é possível recriar o sinal de corrente com os parâmetros estimados e, então, compará-lo com o sinal de corrente experimental.

Neste trabalho, a estimação dos parâmetros é realizada por três algoritmos de otimização diferentes, com o intuito de analisar e comparar o desempenho de cada um

e verificar o que mais se adequa à metodologia proposta. Os AOs utilizados são o DE, PSO e SA. A Figura 12 apresenta um fluxograma do funcionamento dos AOs em paralelo, implementados nesta Tese.



**Figura 12:** Funcionamento dos algoritmos de otimização DE, PSO e SA

**Fonte:** Autoria própria

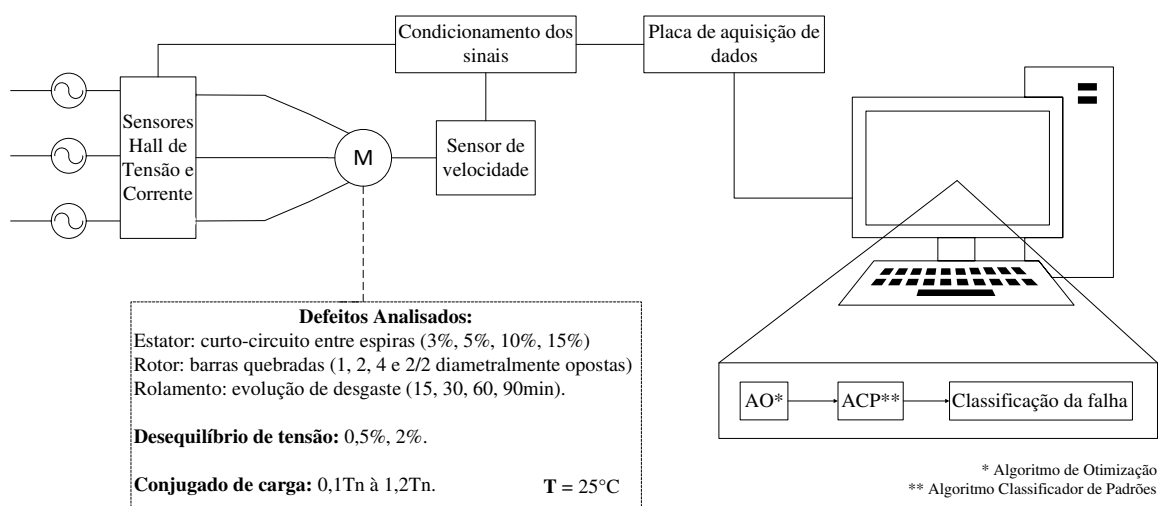
Por fim, após a estimação dos parâmetros do MIT, estes dados, junto ao pico das correntes da máquina, são inseridos na entrada dos classificadores de padrões. Assim como na etapa de estimação, para a etapa de classificação também são utilizados três classificadores de características distintas (RNA, SVM e k-NN), a fim de verificar qual dos métodos utilizados apresentará melhor desempenho para a identificação de falhas individuais e múltiplas falhas. No capítulo subsequente são apresentados os aspectos gerais relativos ao desenvolvimento e implementação do método proposto, bem como a aplicação dos itens aqui abordados.

## 4 METODOLOGIA

### 4.1 INTRODUÇÃO

O comportamento das falhas e seu efeitos em motores de indução podem ser reproduzidos em laboratório para simular o ambiente industrial, onde diversas condições de operação e situações de falhas são testadas, com o objetivo de criar métodos eficientes de diagnósticos quando aplicados em condições reais.

Neste capítulo são descritos os processos desenvolvidos para criação do banco de dados experimental, bem como sua utilização para implementação e validação do sistema de diagnóstico de falhas detalhado. Assim, é abordada a implementação dos algoritmos de otimização para a estimação de parâmetros em regime permanente, empregados como parte dos dados de entrada para os sistemas classificadores de padrões. A Figura 13 apresenta a organização geral do desenvolvimento da metodologia proposta, cujos detalhes serão explanados ao longo do presente capítulo.




**Figura 13:** Organização geral da metodologia proposta

**Fonte:** Autoria própria

## 4.2 ASPECTOS RELACIONADOS AO CONJUNTO DE DADOS

A bancada utilizada, apresentada na Figura 14, foi projetada por Goedel (2007) e reproduzida no Laboratório de Sistemas Inteligentes (LSI) da UTFPR para o monitoramento de tensões, correntes, vibrações, torque e velocidade de um motor de indução trifásico. O condicionamento de sinais dos sensores Hall faz com que as tensões e as 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<sup>®</sup>, com uma taxa de aquisição de 15,5kHz.

Esta ainda 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 Gongora et al. (2013), Broniera (2014), Santos et al. (2014), Lopes (2016), Graciola et al. (2016), Palácios et al. (2017), Godoy et al. (2018), Bazan et al. (2019) entre outros.



**Figura 14:** Bancada experimental: LSI - UTFPR

**Fonte:** Autoria própria

Para o desenvolvimento do presente trabalho, foram utilizados dois motores de indução trifásicos com potências distintas, cujos parâmetros e características são apresentados na Tabela 1.

**Tabela 1:** Dados de placa dos MITs utilizados nos experimentos, considerando operação com conjugado nominal

Item	Motor 1	Motor 2
Tensão de alimentação	127V/ 220V	127V/ 220V
Marca	WEG	WEG
Modelo	W22Plus (IE2)	W22Plus (IE2)
Potência	1 CV	2 CV
Alimentação	$3\phi$	$3\phi$
Frequência	60 Hz	60 Hz
Velocidade Nominal	1730 rpm	1750 rpm
$I_p/I_n$	8,0	7,1
Classe	A	A
Isolação	Tipo F	Tipo F
Fator de Serviço	1,15	1,15
Fator de potência	0,80	0,78
Rendimento	82,5%	84,2%

A base de dados experimentais consiste em testes que incluem variação de conjugado de carga, desequilíbrio de tensão de até 2% e diferentes falhas de curto-circuito entre as espiras do enrolamento do estator, barras quebradas de rotor e desgaste de rolamento. A Tabela 2 apresenta a relação dos testes realizados em ambos os MITs. Vale ressaltar que todas as variações de conjugado de carga e desequilíbrio de tensão foram aplicadas para os 3 tipos de falhas estudados.

Para os testes realizados, os desequilíbrios relacionados à 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.

**Tabela 2:** Variações de operação impostas ao MIT com acionamento direto

Motor	Defeito	Condição	Alimentação Senoidal
Motor 1 (1 CV)	-	Sem defeito	30
	Estator	3% curto-circuito entre as espiras	30
		5% curto-circuito entre as espiras	30
		10% curto-circuito entre as espiras	30
		15% curto-circuito entre as espiras	30
	Rotor	1 barra quebrada	30
		2 barras quebradas	30
		4 barras quebradas	30
		2/2 barras quebradas	30
	Rolamento	Desgaste de 15 min.	30
		Desgaste de 30 min.	30
		Desgaste de 60 min.	30
		Desgaste de 90 min.	30
Motor 2 (2 CV)	-	Sem defeito	30
	Estator	3% curto-circuito entre as espiras	30
		5% curto-circuito entre as espiras	30
		10% curto-circuito entre as espiras	30
		15% curto-circuito entre as espiras	30
	Rotor	1 barra quebrada	30
		2 barras quebradas	30
		4 barras quebradas	30
		2/2 barras quebradas	30
	Rolamento	Desgaste de 15 min.	30
		Desgaste de 30 min.	30
		Desgaste de 60 min.	30
		Desgaste de 90 min.	30
<b>Número total de aquisições</b>			<b>780</b>

A Tabela 2 apresenta a quantidade de ensaios diferentes que foram realizados para o banco de dados utilizado. Pode-se observar que foram realizados 30 ensaios diferentes para cada condição de operação, o que resulta em 120 amostras diferentes por falha e 30 para o motor operando sem falha.


No entanto, como *dataset* para a etapa de classificação deve ser balanceado, os ensaios sem defeitos que foram replicados de modo que a quantidade de amostras ficasse igual para os casos sem falha ou com falha. Isso quer dizer que, para uma análise com 120 amostras defeituosas, por exemplo, de um único sinal sem defeito foram extraídas as informações de corrente em 4 instantes de tempo distintos e realizada a estimação de parâmetros para esses 4 sinais.

Outra consideração fundamental a ser feita, é que as simulações de falha de

curto-circuito no estator foram realizadas apenas nas espiras correspondentes à fase A, ou seja, nas fases B e C não foi aplicado nenhum nível de curto-circuito. Por esse motivo, a estimação de parâmetros foi realizada considerando a corrente e a tensão da fase A. As demais correntes, B e C, foram utilizadas apenas na composição das informações de entrada dos classificadores de padrões, onde foram apresentados os seus respectivos valores de pico.

Considerando que a falha de estator influencia diretamente a fase A e que as falhas de rotor e rolamento influenciam igualmente as três fases (conforme será apresentado ainda nessa seção), a estimação de parâmetros com as informações da corrente e tensão da fase A, junto ao módulo da velocidade, fornecem informações suficientes para a classificação das diversas falhas, de acordo com a estratégia proposta nesta Tese.

O curto-circuito entre as espiras da bobina no enrolamento de estator 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 dessa falha, o estator foi rebobinado conforme a metodologia de Suetake (2012), aplicado por Broniera (2014). O motor foi rebobinado com 3 bobinas isoladas com verniz, respeitando as medidas originais e classe de isolamento do MIT, permitindo que várias derivações fossem construídas. Essas derivações permitiram ensaios de 3%, 5%, 10% e 15% de curto-circuito entre as espiras do estator. A Figura 15 ilustra os *taps* adicionais inseridos no enrolamento do motor de indução trifásico junto ao seu respectivo esquema elétrico e, ainda, o comportamento da corrente de estator para uma falha de 3%.



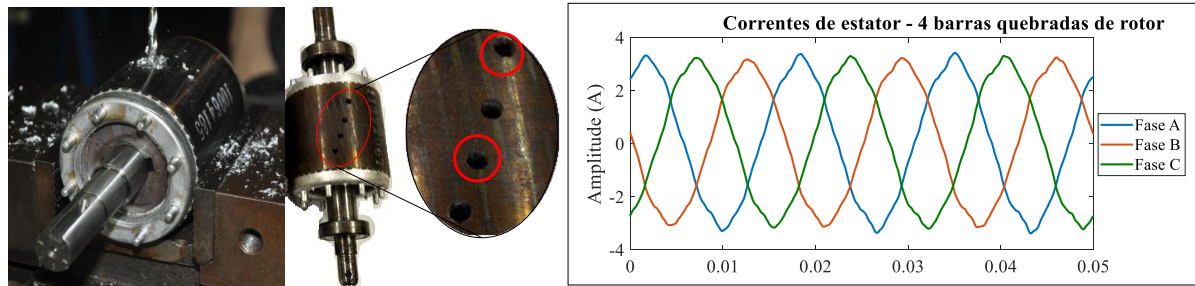
**Figura 15:** Imagem ilustrativa dos *taps* de derivação

**Fonte:** Autoria Própria

Para a reprodução das falhas de barras quebradas do rotor gaiola de esquilo, foi realizado o cisalhamento das mesmas por meio de perfurações com uma broca de diâmetro suficiente para rompimento da barra em questão. Para cada nível de falha foi perfurado



um rotor diferente. A Figura 16 mostra o processo de perfuração junto ao resultado das barras quebradas, onde a parte em destaque apresenta um *zoom* do rompimento completo de uma barrada e, ainda, é apresentado o comportamento da corrente de estator quando o MIT opera com falha de rotor.




**Figura 16:** Imagem representativa da criação de barras quebradas no rotor

**Fonte: Autoria Própria**

Esse tipo de falha pode ter sua origem devido ao excesso de vibração, desalinhamento, excentricidade ou, ainda, carga excessiva no eixo. Os defeitos relacionados às barras quebradas correspondem a cerca de 5% de todas as falhas do MIT (BELLINI et al., 2008), e têm como principais consequências o aumento da oscilação de conjugado, vibração, ruído e interferência na dinâmica de partida (GODOY, 2016).

Por fim, as falhas de rolamento foram reproduzidas para simular o desgaste relacionado ao uso excessivo, falta de lubrificação ou sobrecarga no eixo. O procedimento para simulação da falha consistiu em trocar a lubrificação do rolamento por pasta abrasiva, responsável por promover o desgaste das peças internas do mesmo. Nesse caso, foram utilizados quatro rolamentos e cada um operou intermitentemente por 15, 30, 60 e 90 minutos, respectivamente. Na sequência, os componentes foram limpos e receberam a lubrificação correta para que a aquisição de dados pudesse ser realizada. A Figura 17 mostra o processo de desgaste do rolamento junto ao comportamento da corrente de estator quando o MIT opera com essa falha.



**Figura 17:** Imagem representativa da criação de barras quebradas no rotor

**Fonte:** Autoria Própria

Para a identificação e classificação da falha pela metodologia proposta, foram extraídos os dados de corrente, tensão e módulo da velocidade, uma vez que é necessário calcular o escorregamento para a estimação dos parâmetros elétricos utilizando o modelo em regime permanente. A seção seguinte, apresenta detalhadamente o funcionamento dos algoritmos de otimização para a estimação dos parâmetros elétricos do MIT.

#### 4.3 IDENTIFICAÇÃO DOS PARÂMETROS UTILIZANDO ALGORITMOS DE OTIMIZAÇÃO

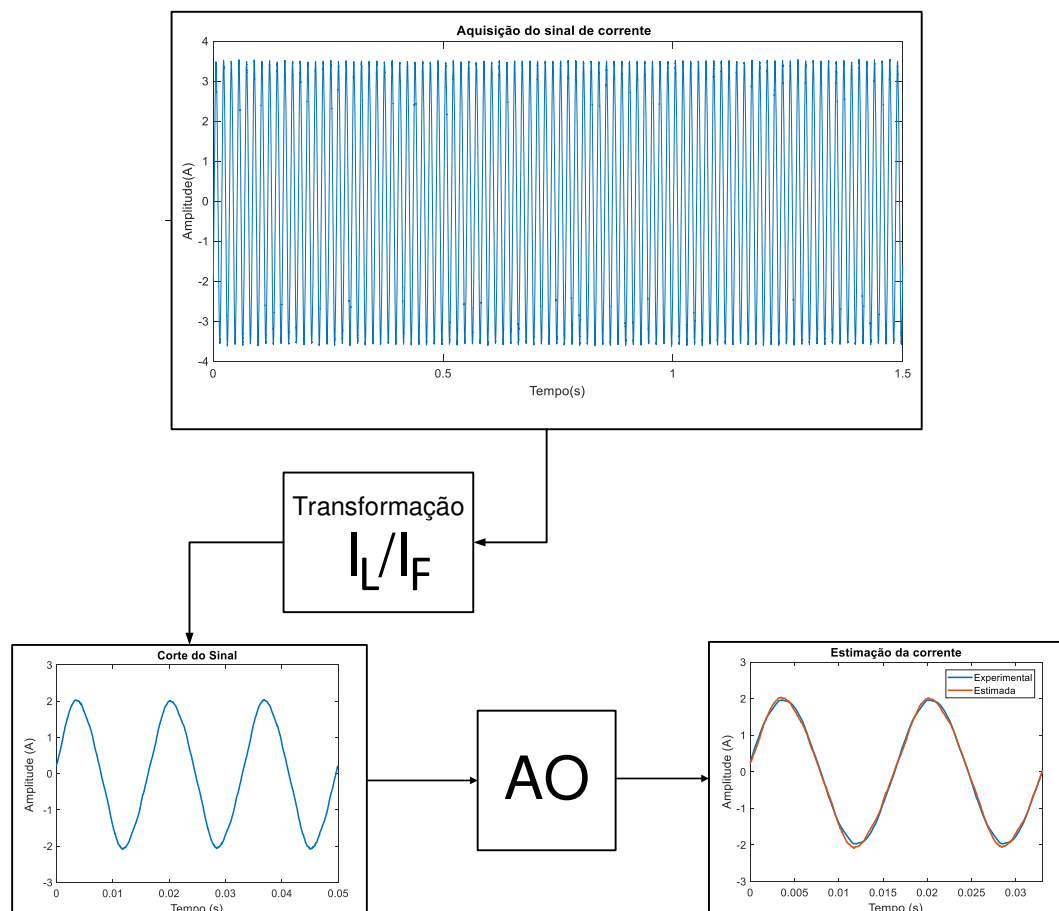
Para a identificação da falha por meio dos AOs utilizam-se os sinais de corrente e tensão de fase como dados de entrada. Além disso, também é necessário informar o módulo da velocidade para determinar o escorregamento, presente no circuito elétrico equivalente do MIT, conforme Equação (4). Estudos atuais apontam alternativas aos sensores de velocidade - em alguns casos mais caros que o próprio MIT - que são capazes de realizar a estimação da mesma com baixo custo, como no trabalho de Graciola et al. (2016).

O primeiro passo para iniciar a identificação da falha consiste na extração das características necessárias dos sinais de entrada. Como descrito na Seção 4.2, foi utilizada uma taxa de aquisição de 15.500 pontos por segundo de amostragem. Entretanto, por se tratar de uma operação em regime permanente, cujo sinal apresentado é periódico, não há a necessidade de utilizar as amostras completas, que foram coletadas por um período que variou de 1,5s (condições de operação saudável e com falha de estator) a 5s (condições de operação com falhas de rotor e rolamento).

Para otimizar o tempo de estimação e custo de processamento, são extraídos 3

períodos do sinal, periódico, para garantir a repetição de pelo menos um período. O corte do sinal é realizado com base no valor máximo da tensão e, a partir de então, são armazenados os respectivos pontos com relação aos outros dados de entrada. Assim, um período do sinal é utilizado para o ajuste da fase da corrente.

Na Seção 3.2, a modelagem apresentada descreve o comportamento do motor 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 delta e a corrente aquisitada foi a corrente de linha. Dessa forma, é necessário realizar a transformação do sinal de linha para fase. Essa transformação é realizada considerando um sistema equilibrado, onde a somatória das correntes é nula (ALEXANDER; SADIKU, 2013). A Figura 18 apresenta como é realizado o processamento do sinal da corrente para a extração e utilização dos AOs. O mesmo ocorre com o sinal de tensão, porém sem a transformação, que se mantém igual nas duas configurações.



**Figura 18:** Processamento do sinal da corrente

**Fonte:** Autoria Própria

O primeiro passo para a identificação da falha consiste na determinação dos valores de referência do circuito elétrico equivalente. Com a análise da variação dos referidos parâmetros para diversas situações de operação da máquina, busca-se identificar a ocorrência dos defeitos de estator, rotor ou rolamento.

Cada algoritmo de otimização é utilizado na primeira etapa para estimação de todos os parâmetros do circuito elétrico equivalente do MIT, considerando dados de máquinas sem falhas e com tensões equilibradas.

Na identificação dos parâmetros reais, apenas com dados em regime permanente, foram realizados seis testes que combinavam sinais de diferentes níveis de conjugado, a saber: operação a vazio e com torque nominal ( $T_n$ ) com e sem  $R_1$  fixo; operação a vazio e rotor bloqueado com e sem  $R_1$  fixo; operação a vazio, meia carga e nominal com e sem  $R_1$ . O intuito de considerar o valor de  $R_1$  fixo, de acordo com o resultado apresentado em (GUEDES et al., 2018b), foi reduzir o número de parâmetros a serem estimados e encontrar resultados com maior exatidão. Ainda, o objetivo de combinar instantes diferentes de operação na FO é encontrar uma solução que satisfaça, ao mesmo tempo, a aproximação desses sinais com um único conjunto de parâmetros.

Assim, a FO deste trabalho consiste no cálculo do erro médio quadrático resultante das correntes estimada e experimental de cada operação, conforme apresentado em (34). O valor de  $m$  é 2 ou 3, dependendo da situação analisada.

$$FO = \sum_{j=1}^m \left( \frac{1}{2} \sum_{i=1}^n \frac{(I_{estimada_{ij}} - I_{experimental_{ij}})^2}{n} \right) \quad (34)$$

onde  $I_{estimada}$  é a corrente obtida por meio dos parâmetros estimados com o algoritmo de otimização,  $I_{experimental}$  é a corrente de referência extraída do MIT e  $n$  corresponde à dimensão do vetor das correntes (para uma taxa de amostragem de 15,5kHz,  $n = 256$ ).

A partir da estimação do vetor de referência, é possível iniciar a análise comportamental dos parâmetros do circuito elétrico equivalente quando o motor é submetido a uma operação com falha.

No trabalho de Guedes et al. (2018a) observou-se que a variação da indutância de magnetização apresentou um comportamento característico, tal que foi possível a identificação e evolução de uma de falha de curto-circuito no estator. Por se tratar dessa falha, no entanto, foi analisada a variação dos parâmetros de estator em conjunto com o de magnetização, ou seja,  $R_1$ ,  $L_1$  e  $L_M$ , fixando-se os parâmetros do rotor de acordo com o vetor de referência estimado. Embora similar à metodologia para esta Tese, há algumas

diferenças que devem ser destacadas.

No presente trabalho são estimados os parâmetros reais da máquina, e são considerados outros tipos de falha. Além disso, nesta Tese considera-se a multiclassificação de falhas e a presença das mesmas, quando analisadas individualmente, mas não é abordada a identificação da severidade de cada falha. Por esses motivos, com o objetivo de encontrar quais variações resultariam no melhor diagnóstico para identificação e classificação de todos os tipos de falha, foram realizados testes considerando a análise da variação de sete combinações diferentes na estimação de parâmetros, conforme apresentado na Tabela 3.

É importante ressaltar que quando uma combinação foi testada, os parâmetros apresentados na tabela são estimados para todas as amostras analisadas, e os demais parâmetros permanecem fixos. Por exemplo, na combinação 1, os parâmetros  $R_1$ ,  $L_1$  e  $L_M$  serão estimados para qualquer amostra e os parâmetros  $R_2$ ,  $L_2$  permanecerão fixos, de acordo com o vetor de referência estimado a partir dos ensaios do MIT sem falha e alimentado com tensões equilibradas.

**Tabela 3:** Conjuntos de parâmetros estimados para a identificação da falha

Combinação	Descrição	
	Quantidade de dados estimados	Parâmetros estimados
1	3	$L_1, R_1, L_M$
2	3	$L_2, R_2, L_M$
3	2	$L_2, L_M$
4	2	$R_2, L_M$
5	2	$L_1, L_M$
6	2	$R_1, L_M$
7	1	$L_M$

Observa-se que em todos os casos há a variação do parâmetro de magnetização ( $L_M$ ), pois foram realizados testes preliminares, onde constatou-se a mudança característica em seu valor para todas as falhas. Conforme apresentado no Capítulo 3, os AOs necessitam de um espaço de busca para trabalharem suas soluções e conseguirem convergir para um ótimo global. Assim, para a realização da estimação dos parâmetros - tanto na etapa de criação do vetor de referência, quanto na etapa de análise da variação de parâmetros - é necessário estabelecer um espaço de busca, apresentado na Tabela 4. O mesmo espaço de busca foi aplicado para os três algoritmos de otimização: DE, PSO e SA.

**Tabela 4:** Espaço de busca utilizado para a estimação de parâmetros

Parâmetro	Espaço de busca
$R_1$ ( $\Omega$ )	[2 20]
$R_2$ ( $\Omega$ )	[2 10]
$L_1$ (H)	[0,001 0,5]
$L_2$ (H)	[0,001 0,5]
$L_M$ (H)	[0,01 3]

Além do espaço de busca, devem ser estabelecidos os valores relacionados aos parâmetros necessários para o funcionamento de cada AO, como taxa de cruzamento (DE), coeficiente de aceleração (PSO), temperatura inicial (SA), entre outros. A Tabela 5 apresenta os parâmetros configurados para cada algoritmo de otimização.

**Tabela 5:** Informações dos Algoritmos de Otimização

DE		PSO		SA	
População	15	População	30	População	1
Fator de Ponderação (F)	rand(0,1)	Coeficiente de aceleração pessoal ( $c_1$ )	2,05	Temperatura inicial ( $T_0$ )	100
Taxa de cruzamento ( $C_r$ )	0,5	Coeficiente de aceleração social ( $c_2$ )	2,05	Fator de resfriamento ( $\alpha$ )	0,99

Para a criação do vetor mutado no DE, é atribuído um fator de ponderação, que é aplicado à resultante da diferença entre dois vetores para ser somado ao *target vector*. Para este trabalho optou-se pela utilização de um fator aleatório, ou seja, a cada iteração foi gerado um novo fator de ponderação para permitir uma maior variação na construção dos vetores mutados. Já a taxa de cruzamento, foi atribuída de tal forma a garantir que a probabilidade de escolha do vetor mutado ou não mutado seja a mesma.

Para o PSO, devem ser ajustados os coeficientes de aceleração pessoal e social, podendo também ser atribuído um coeficiente de inércia ou ainda um coeficiente de constrição. Na busca por garantir a convergência, e considerando testes preliminares, optou-se pela utilização da alteração da velocidade com o coeficiente de constrição, dependente de  $c_1$  e  $c_2$  - cujos valores foram ajustados de acordo com o que vem sendo apresentado na literatura (EBERHART; SHI, 2000; LEE; EL-SHARKAWI, 2008).

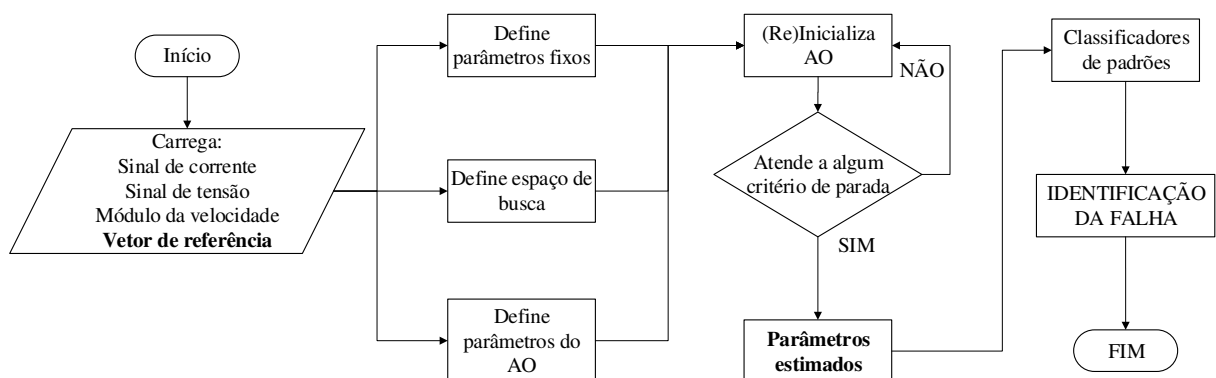
Por fim, para o SA foi atribuída uma temperatura elevada para permitir que o algoritmo aceite diversas soluções inicialmente, evitando que este caia em um mínimo local. Já o fator de resfriamento foi definido como o máximo, na busca de proporcionar um resfriamento lento que aumente as chances de se encontrar um ótimo global.

O último ajuste atribuído a todos os AOs foi o critério de parada. A fim de criar

um método rápido e eficiente, foram estabelecidos 2 critérios de parada, explanados no Capítulo 3. O primeiro critério estabelecido foi um erro inferior a 0,02, ou seja, quando o valor da FO é inferior a 0,02. Já o segundo critério, determina a parada do algoritmo pelo número de iterações. O número de iterações máximas foi estabelecido após a análise dos resultados obtidos com o primeiro critério de parada satisfeito. Desta forma, optou-se por um valor duas vezes maior, para garantir que o sistema tente sair do seu mínimo local e busque um mínimo global. Para cada algoritmo foi atribuído um número máximo de iterações diferentes, após a análise individual do comportamento de cada um, que será apresentado na seção de resultados.

Quando o algoritmo é encerrado, o valor dos parâmetros do MIT que são armazenados correspondem à corrente estimada, cuja diferença em relação à corrente experimental satisfaz a um critério de parada. Para evitar que o processo apresente resultados insatisfatórios, são realizadas 5 médias de 5 conjuntos com 20 resultados cada. Dessas 5 médias é extraída uma média final, que corresponde à resposta do sistema.

O processo apresentado de utilização do algoritmo de otimização, é o mesmo para a criação do vetor de referência e para a estimação dos parâmetros na fase de identificação da falha. Após obter-se o vetor de referência, inicia-se o processo de estimação de parâmetros do MIT para análise de sua situação de operação - com ou sem falha -, onde foram testadas todas as situações apresentadas na Tabela 3. O fluxograma da Figura 19 sintetiza a utilização dos AOs para o diagnóstico de falha. As etapas em negrito representam a finalização de um ciclo relacionado com a estimação dos parâmetros por meio dos AOs.



**Figura 19:** Fluxograma da utilização dos algoritmos de otimização para identificação de falha

**Fonte:** Autoria própria

Para a etapa de implementação dos algoritmos de otimização, foi utilizado o *software* MATLAB<sup>®</sup>. As configurações do computador usado no desenvolvimento e validação do sistema proposto, consiste em um processador Intel<sup>®</sup> Core<sup>™</sup> i7-4510U 2,6 GHz, memória RAM de 8GB e SSD de 240GB. A seção a seguir apresenta o processo de identificação da falha com o auxílio do classificador de padrões.

#### 4.4 IDENTIFICAÇÃO DA FALHA UTILIZANDO SISTEMAS INTELIGENTES

Para a realização da identificação da falha, optou-se por utilizar três classificadores de padrões distintos, RNA, SVM e k-NN, que são consolidados na literatura para identificação de falhas (PALÁCIOS et al., 2015; GODOY et al., 2016; RAJAMANY; SRINIVASAN, 2017; PANDARAKONE et al., 2017; SHARMA et al., 2018; BAZAN et al., 2019).

O vetor de entrada variou conforme apresentado na Tabela 3. Para cada possibilidade criou-se um banco inicial com 10% das amostras que representassem o comportamento do MIT, desde sua operação a vazio até sua operação com conjugado de carga nominal. Foram testadas todas as combinações dos parâmetros estimados e, além disso, optou-se por inserir o valor de pico da corrente junto com os parâmetros, na busca de fornecer dados suficientes para uma identificação mais robusta. Assim, o conjunto de dados de entrada variou de 2 a 8 dados, sendo que 2 dados representam o parâmetro de magnetização e o pico de corrente da fase A, e 8 dados representam todos os parâmetros do circuito elétrico equivalente, junto ao o pico das três fases da corrente.

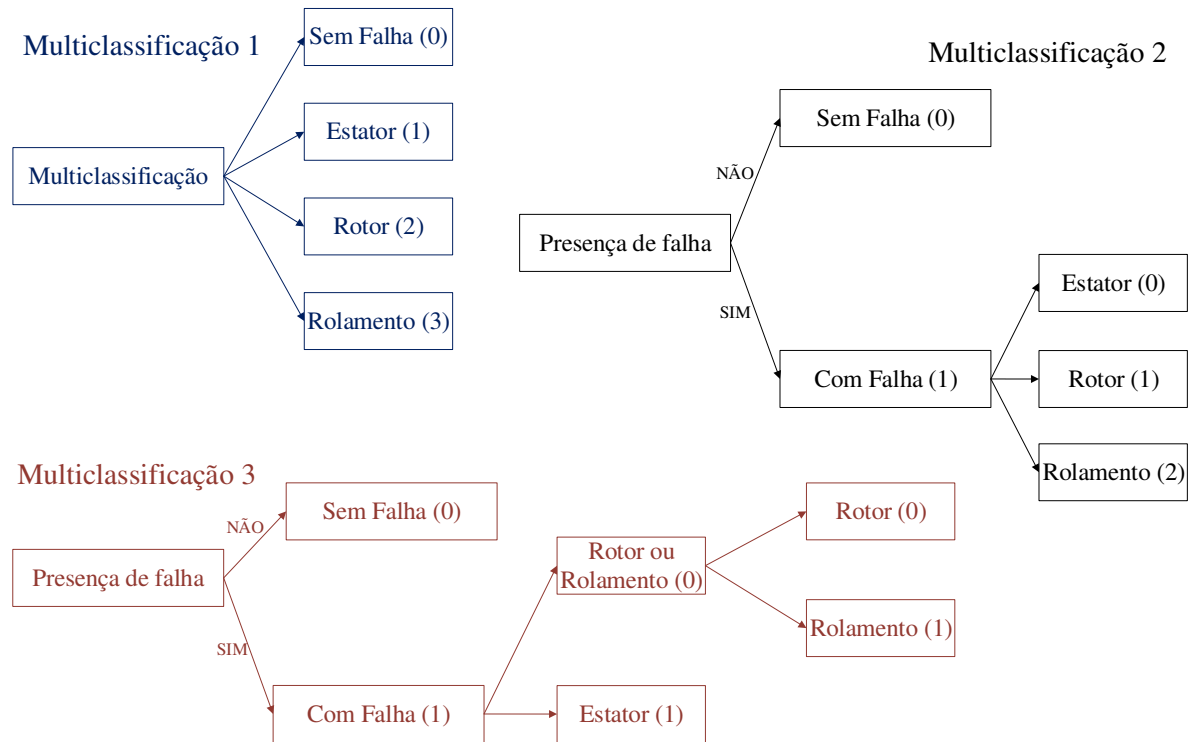
A separação dos dados para treinamento e validação, ocorreu de forma aleatória para todos os casos, e foram testados o método de *k-partições*, onde  $k=10$ . Nesse caso, o processo se repetiu por 10 vezes onde, para cada iteração, 1 conjunto era utilizado para validação e os demais para treinamento. A cada iteração realizou-se a classificação, e o resultado final foi dado pelo erro médio do classificador nos 10 testes realizados (SILVA et al., 2017). É importante ressaltar que para todos os casos testados, foi utilizado um banco de dados com *dataset* balanceado, contendo a mesma quantidade de amostras para cada situação de operação.

Com relação às saídas, foram testados cinco casos distintos, a saber: classificação de falha e não falha com cada um dos defeitos separadamente; classificação de falha e não falha com todos os defeitos juntos; multiclassificação das falhas. Ainda, na etapa de multiclassificação, foram consideradas três multiclassificações diferentes, visando obter a



maior taxa de acerto para a identificação de múltiplas falhas.

A Figura 20 apresenta as três multiclassificações que foram realizadas. Nos casos das multiclassificações 2 e 3 são realizadas classificações hierárquicas e, nesse caso, considera-se apenas os conjuntos que estão na classificação em questão. Por exemplo, na Multiclassificação 2, quando é atribuído que um sinal está com falha, a classificação para o tipo de falha ocorre sem incluir o conjunto de dados sem falha.



**Figura 20:** Classificações realizadas para identificação de múltiplas falhas

**Fonte:** Autoria própria

Para a etapa de classificação de padrões foi utilizado o *software* WEKA<sup>®</sup>, aplicado na resolução de problemas envolvendo classificação de padrões por meio do conjunto de algoritmos disponíveis, dentre eles a RNA, o SVM e o k-NN (GARNER et al., 1995).

Entretanto, alguns valores devem ser informados para cada algoritmo. Na aplicação da RNA, para esse trabalho, foi utilizada apenas uma camada intermediária com 10 neurônios, taxa de aprendizagem = 0,3, *momentum* = 0,2 e o número máximo de 500 épocas para o treinamento. Além disso, optou-se pela utilização da função logística para a camada intermediária e linear para a camada de saída.

Quando utilizado o SVM, a taxa de erro de arredondamento recebeu valor de  $10^{-12}$  e o parâmetro de tolerância de erro de 0,001. Já o parâmetro de margem  $C$  que

determina um ponto de equilíbrio entre a maximização da margem e a minimização do erro, controlando a influência de cada vetor, foi fixado em 1 (SAMANTA; NATARAJ, 2009; ALPAYDIN, 2009).

Por fim, para o uso do k-NN, foi aplicado o cálculo de distância Euclidiana e a escolha dos vizinhos foi baseada em testes preliminares. Neste trabalho o número de vizinhos foi alterado entre 1 e 9 e foram obtidos os melhores resultados quando k=5.

Assim como para a estimação dos parâmetros, as classificações das falhas foram processadas em um computador com processador Intel<sup>®</sup> Core<sup>™</sup> i7-4510U 2,6 GHz, memória RAM de 8GB e SSD de 240GB.

#### 4.5 IMPLEMENTAÇÃO DA METODOLOGIA EM *HARDWARE*

A implementação em *hardware* visa a possibilidade de um monitoramento *online* para identificação de falhas em MITs. Tendo em vista a proposta de uma estratégia que envolve três algoritmos de otimização, combinado a três classificadores de padrões, foram criadas 9 combinações distintas para analisar todas as classificações.

Assim, optou-se por implementar em *hardware* o sistema com melhor combinação AO/Classificador para um tipo de falha em um DSP, comprovando a viabilidade de implementação da metodologia embarcada.

Para este trabalho foi escolhido o DSP TMS320F28379D da empresa Texas Instruments<sup>®</sup>, que está presente no Development Kit LAUNCHXL-F28379D. A escolha deste *hardware* foi realizada a partir de suas características e da disponibilidade do material. Suas configurações são uma CPU dual-core de 32-bit com suporte a ponto flutuante e seu *Clock* base de 200MHz, 16 canais de conversão analógica para digital, 512KB de Flash por núcleo e 102KB de RAM por núcleo.

A aquisição dos dados foi realizada utilizando os canais do conversor A/D para realizar a aquisição simultânea. A frequência de amostragem foi a mesma utilizada nos testes experimentais via computador (15,5kHz) e as referências de tensão positiva e negativa foram, respectivamente, 3,3V e 0V.

#### 4.6 CONCLUSÃO DO CAPÍTULO

Neste capítulo foram detalhados os aspectos gerais relacionados à metodologia proposta para identificação e classificação de falhas no MIT. Para isso, apresentou-se a

bancada experimental e o procedimento para desenvolver o banco de dados utilizado, bem como a metodologia para estimação de parâmetros por meio dos algoritmos de otimização DE, PSO e SA. Além disso, apresentou-se neste capítulo o processo de classificação da falha para diferentes possibilidades com os classificadores RNA, SVM e k-NN. Ainda, foi explanado o funcionamento da implementação em *hardware* para um monitoramento *online* de falha em MITs. No Capítulo 5 são apresentados e discutidos os resultados obtidos nesta Tese.

## 5 RESULTADOS EXPERIMENTAIS

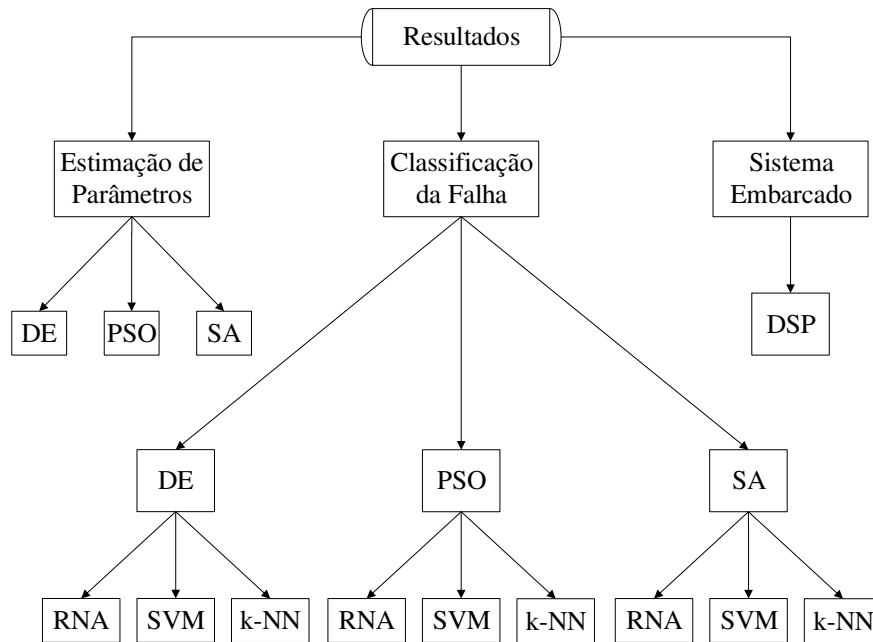
### 5.1 INTRODUÇÃO

Este capítulo apresenta os resultados experimentais das estimações dos parâmetros dos MITs estudados, utilizando os algoritmos de otimização DE, PSO e SA, bem como a classificação dos dados realizada com o auxílio de três diferentes classificadores de padrões: RNA, SVM e k-NN. Os dados utilizados foram extraídos dos MITs apresentados na Tabela 1, com acionamento direto da rede de alimentação.

A proposta abordada no presente contexto visa a identificação de falhas em MIT por meio dos parâmetros do circuito elétrico equivalente estimados da máquina, combinado ao valor de pico das correntes de estator, reduzindo significativamente o número de pontos a serem inseridos na entrada dos classificadores de padrões.

As classificações realizadas foram divididas em duas fases. Inicialmente foi realizada a identificação de falha e não falha, onde os defeitos de estator, rotor e rolamento foram avaliados separadamente. Posteriormente, ocorreu a junção de todo o conjunto de dados obtidos para indicação de falha, bem como a multiclassificação destas.

Este capítulo está subdividido em três seções, conforme apresentado na Figura 21, onde a primeira seção descreve os resultados da identificação de parâmetros para a criação do vetor de referência, utilizando os diferentes algoritmos de otimização; a segunda seção apresenta a classificação das falhas utilizando os diferentes classificadores de padrões; e a terceira seção expõe a implementação em *hardware* que foi desenvolvida para este trabalho.



**Figura 21:** Distribuição do capítulo de resultados

**Fonte:** Autoria própria

## 5.2 IDENTIFICAÇÃO DOS PARÂMETROS DO MIT

A identificação de parâmetros do MIT foi realizada utilizando apenas amostras com operação em regime permanente, pois esta é uma demanda do setor industrial. Na busca de encontrar a melhor forma de realizar a estimação dos parâmetros, com o menor custo computacional possível, foram testadas 3 combinações diferentes: operação a vazio e nominal - com e sem  $R_1$  fixo; operação a vazio e rotor bloqueado - com e sem  $R_1$  fixo; operação a vazio, com meia carga e com carga nominal - com e sem  $R_1$  fixo. Em cada um dos casos testados foi extraído o melhor conjunto de parâmetros para ser aplicado ao modelo do MIT e permitir a comparação da corrente estimada com todas as correntes experimentais, inclusive as que não foram utilizadas no teste.

Vale ressaltar ainda, que o intuito dos testes a vazio e nominal, assim como a vazio, nominal e meia carga, é utilizar em um momento dois instantes de operação e no outro, três instantes distintos de operação, a fim de verificar se a aplicação de três condições distintas de operação apresentaria resultados mais satisfatórios do que o uso de apenas duas condições distintas. Por conveniência, adotou-se os valores de meia carga e nominal.

Para melhor compreensão dos testes realizados, cada caso será explicado e ilus-

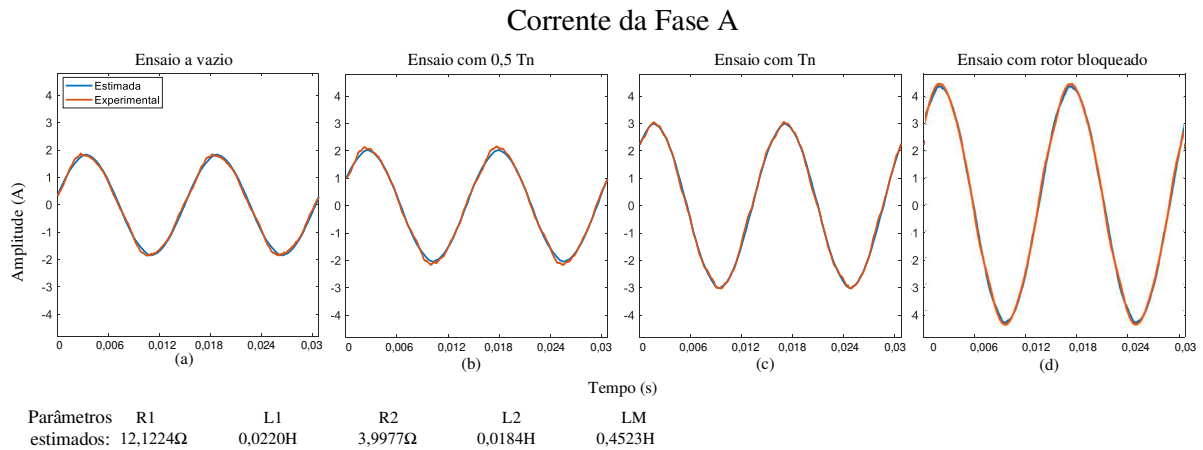
trado separadamente. Todos os testes realizados para identificar a melhor forma de estimar parâmetros em regime permanente foram feitos no MIT de 1 CV, utilizando-se o algoritmo de otimização DE. O conjunto de dados combinados que apresentou o melhor resultado, foi implementado nas demais situações, a saber: o MIT de 2CV com os AOs DE, PSO e SA, e a estimação usando os outros algoritmos de otimização, PSO e SA para o MIT de 1 CV. Para os instantes em que foi utilizado  $R_1$  fixo, atribuiu-se  $R_1 = 5,08\Omega$ , com base nos parâmetros fornecidos em Guedes et al. (2018b), apresentados na Tabela 6.

**Tabela 6:** Parâmetros do MIT de 1 CV

$R_1$ ( $\Omega$ )	$R_2$ ( $\Omega$ )	$L_1$ (H)	$L_2$ (H)	$L_M$ (H)	$J(kg.m^2)$	$K_D$
5,0798	4,2047	0,0311	0,0202	0,4705	0,0216	0,0002

• **Caso 1: Operação a vazio e nominal**

O primeiro caso, consiste na utilização dos sinais com operação a vazio e com carga nominal como referência para o algoritmo de otimização. Inicialmente, foram realizados os testes para a estimação de todos os parâmetros. As Figuras 22 e 23 apresentam o melhor e pior resultado, sem fixar o valor de  $R_1$ , com 0,49% e 0,95% de erro na FO, respectivamente.




**Figura 22:** Caso 1, sem  $R_1$  fixo, com erro de 0,49%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado

**Fonte: Autoria própria**

A partir dos gráficos apresentados na Figura 22, observa-se uma aproximação significativa para os quatro instantes de operação estudados. Os sinais utilizados para compor a FO foram os de operação a vazio e nominal. No entanto, houve um acompanhamento do comportamento da corrente quando comparado também com os casos de 0,5Tn

e rotor bloqueado. Ainda, os parâmetros apresentados na figura correspondente é equivalente ao vetor que gerou as correntes estimadas. Pode-se observar também, que a maior diferença entre as correntes estimada e experimental está no ensaio de rotor bloqueado, com relação à defasagem.



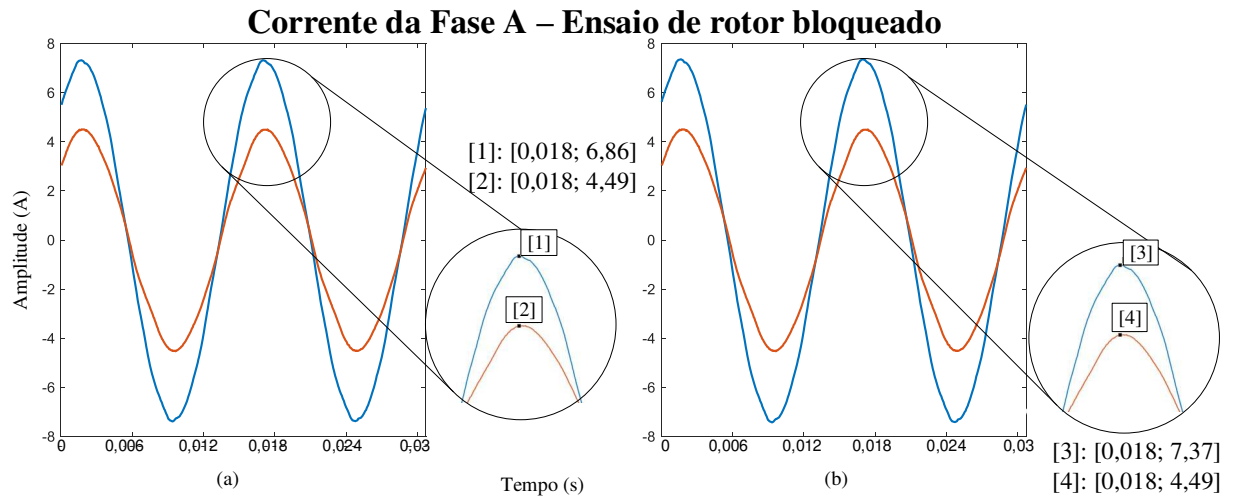
**Figura 23:** Caso 1, sem  $R_1$  fixo, com erro de 0,95%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado

**Fonte: Autoria própria**

Analisando os gráficos apresentados na Figura 23, também é possível observar uma aproximação significativa para os quatro instantes de operação. Entretanto, no ensaio de rotor bloqueado é apresentada uma pequena diferença na defasagem e na amplitude entre as correntes estimada e experimental.

Considerando ambos os casos, a principal diferença está na comparação das correntes quando o motor opera com rotor bloqueado. Tal ensaio foi considerado, pois está previsto em norma para o cálculo de parâmetros do MIT (IEEE, 2018). Dessa forma, mesmo que não tenha sido utilizado como referência para o DE, a corrente estimada a partir dos parâmetros encontrados deve ser compatível, também, com o ensaio de rotor bloqueado. Os demais testes realizados para este caso apresentaram erros inferiores a 1% na FO.

Para o caso em que  $R_1$  foi fixado, não foi possível obter um conjunto de parâmetros cuja corrente gerada acompanhasse a corrente de rotor bloqueado. A Figura 24 apresenta a comparação das correntes estimadas com as de rotor bloqueado para o melhor e pior caso, cujos erros foram de 0,56% e de 0,97%, respectivamente. É importante ressaltar que o valor do erro foi inferior a 1%, pois a corrente de rotor bloqueado não foi considerada na FO.



**Figura 24:** Caso 1, com  $R_1$  fixo, ensaio de rotor bloqueado: (a) Erro de 0,56%, (b) Erro de 0,97%


**Fonte: Autoria própria**

Pode-se observar que, embora haja uma diferença na amplitude da corrente estimada para o melhor e o pior caso, ambos não seguem o comportamento do MIT na operação em rotor bloqueado. Isto deve-se ao fato da fixação de  $R_1$  ser baseada em um valor que não corresponde ao valor exato da resistência de estator. Uma vez que o motor está em constante operação e é submetido a diversos tipos de ensaio, há a modificação de seus parâmetros com o decorrer do tempo (RAJINDER et al., 2017). Assim, mesmo que o erro tenha sido pequeno, os resultados para  $R_1$  fixo foram desconsiderados por não apresentarem boa aproximação em todos os instantes de operação.

- **Caso 2: Operação a vazio e com rotor bloqueado**

Para o segundo caso, foram utilizadas as correntes de operação a vazio e com rotor bloqueado como referência para o algoritmo de otimização. Assim como para o Caso 1, primeiramente testou-se a estimação sem a fixação de  $R_1$  e na sequência, com a fixação de  $R_1$ . As Figuras 25 e 26 apresentam o melhor e pior resultado, sem fixar o valor de  $R_1$ , com 0,47% e 1,2% de erro na FO, respectivamente.






**Figura 25:** Caso 2, sem  $R_1$  fixo, com erro de 0,47%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado

**Fonte: Autoria própria**

A partir dos gráficos apresentados na Figura 25, observa-se uma aproximação significativa para os quatro instantes de operação estudados. Neste caso, os sinais utilizados para compor a FO, foram os de operação a vazio e rotor bloqueado. Contudo, o comportamento das correntes estimadas a partir do vetor apresentado na imagem, foram compatíveis também para os casos de 0,5Tn e Tn.



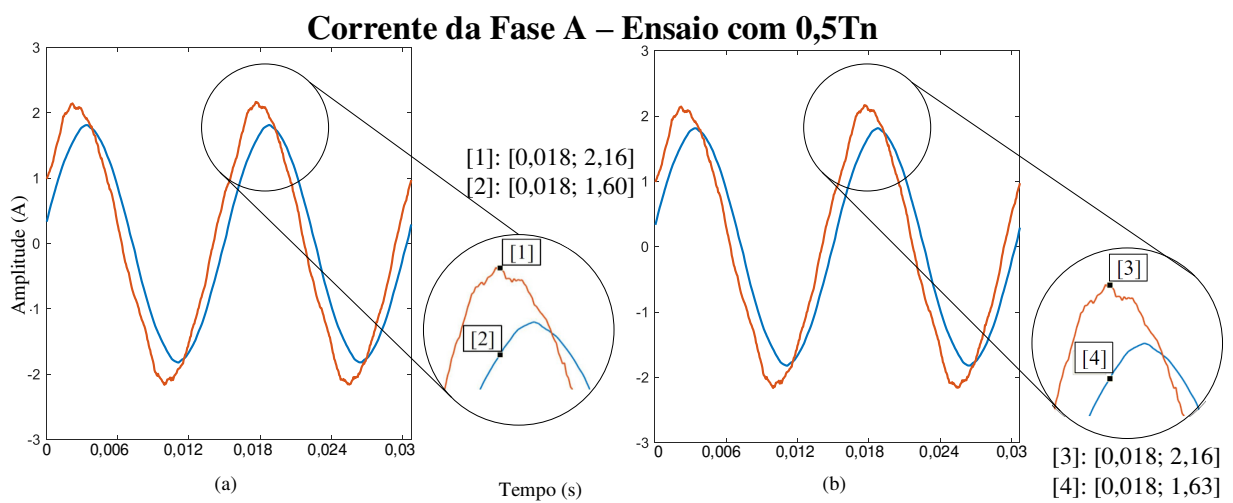
**Figura 26:** Caso 2, sem  $R_1$  fixo, com erro de 1,2%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado

**Fonte: Autoria própria**

A partir da análise gráfica do pior resultado para o Caso 2, Figura 26, observa-se uma divergência na amplitude entre as correntes estimada e experimental quando o motor opera com conjugado de carga nominal, ou seja, Tn. Além disso, também é possível observar uma pequena diferença na amplitude das correntes, para o ensaio de rotor blo-

queado, o que justifica o erro obtido superior a 1%. Ainda, é importante reforçar que a FO do algoritmo de otimização considera apenas os sinais a vazio e de rotor bloqueado e, por isso, a diferença entre as correntes estimada e experimental do motor operando com torque nominal ( $T_n$ ) não influenciou no cálculo do erro.

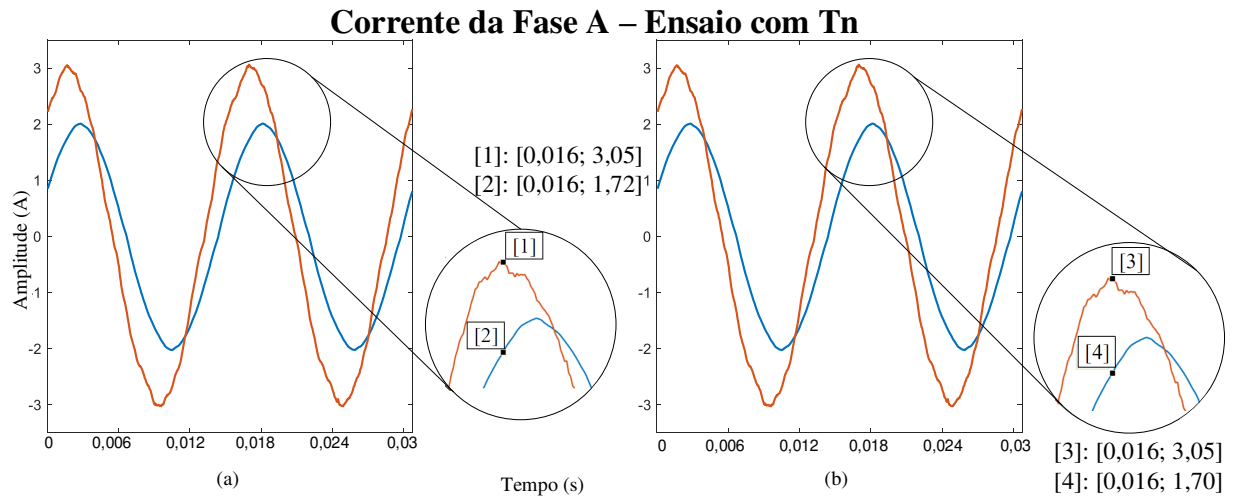
Considerando a fixação  $R_1$ , não foi possível obter um conjunto de parâmetros no qual as correntes geradas apresentassem o mesmo comportamento dos ensaios de  $0,5T_n$  e  $T_n$ . As Figuras 27 e 28 apresentam, respectivamente, o pior e o melhor caso da comparação para cada um dos ensaios mencionados.



**Figura 27:** Caso 2, com  $R_1$  fixo, ensaio com  $0,5T_n$ : (a) Erro de 2,15%, (b) Erro de 2,93%

**Fonte: Autoria própria**

Para operação com  $0,5T_n$  pode-se observar graficamente a diferença de amplitude e fase entre as correntes estimadas e experimental, onde a corrente estimada tem seu valor de pico inferior ao valor real. Realizando-se uma análise quantitativa, tem-se uma diferença aproximada de 35% de erro entre as correntes estimada e experimental, quando comparado o valor do mesmo ponto, tanto para o melhor quanto para o pior caso.



**Figura 28:** Caso 2, com  $R_1$  fixo, ensaio com  $T_n$ : (a) Erro de 2,15%, (b) Erro de 2,93%


**Fonte:** Autoria própria

Analisando os resultados gráficos para a operação com  $T_n$ , pode-se dizer que há o aumento do erro com relação ao ensaio com  $0,5T_n$ . No caso de operação com carga nominal, a diferença entre as amplitudes de um mesmo ponto chega a 77%.

Assim, pode-se considerar que o valor da resistência de estator fixo, não contribuiu positivamente para a obtenção de um resultado satisfatório, pois em nenhum vetor obtido houve a aproximação comportamental de todos os modos de operação da máquina.

- **Caso 3: Operação a vazio, meia carga e nominal**

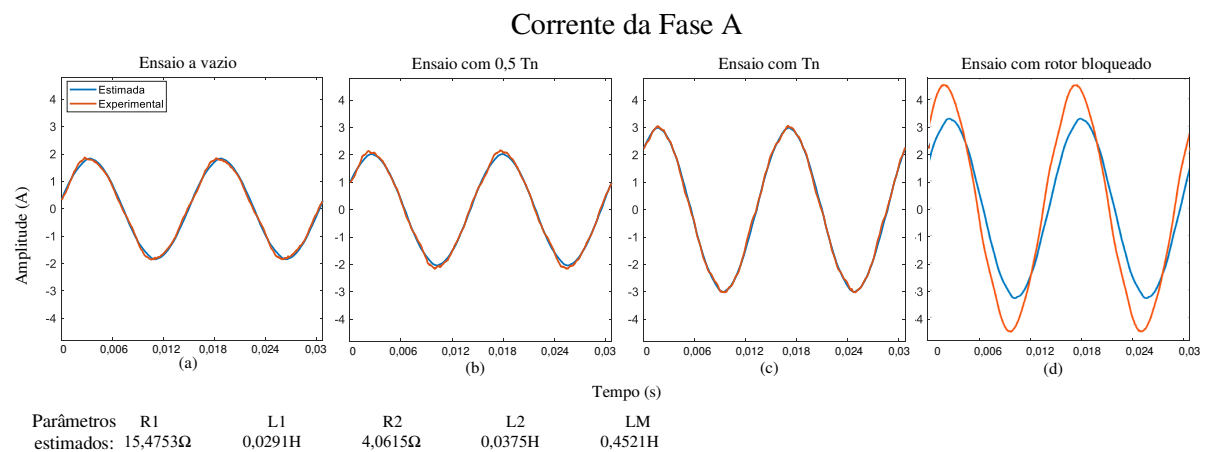
O último caso analisado tem como referência três sinais distintos de corrente, onde são consideradas as diferenças entre a corrente estimada e as correntes de operação a vazio, com meia carga e com carga nominal. O intuito do estudo deste caso, foi observar se há uma resposta mais exata em relação ao Caso 1. Assim como nos demais casos apresentados, foram realizados testes com e sem a fixação de  $R_1$ . As Figuras 29 e 30 apresentam o melhor e o pior resultado, sem fixar o valor de  $R_1$ , com 0,51% e 0,97% de erro na FO, respectivamente.



**Figura 29:** Caso 3, sem  $R_1$  fixo, com erro de 0,51%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado

**Fonte: Autoria própria**

A partir dos gráficos apresentados na Figura 29, observa-se maior aproximação para os três primeiros instantes de operação estudados - a vazio, 0,5Tn e Tn -, cujos sinais foram usados para compor a FO. No entanto, com relação ao ensaio de rotor bloqueado, não inserido na FO, nota-se uma diferença na amplitude de aproximadamente 10,61%, o que aponta para um resultado insatisfatório. Assim, os parâmetros estimados nesse caso não podem ser empregados em um vetor de referência.




**Figura 30:** Caso 3, sem  $R_1$  fixo, com erro de 0,97%: (a)Ensaio a vazio, (b)Ensaio com 0,5Tn, (c)Ensaio com Tn, (d)Ensaio com Rotor Bloqueado

**Fonte: Autoria própria**

Já para a análise da Figura 30, observa-se a ampliação na diferença dos picos entre as correntes de rotor bloqueado, agora com 27,6%, apresentando ainda uma defasagem de aproximadamente 11,37°. Após a análise de ambas as respostas - menor e maior erro

na FO -, é possível observar que o teste não apresentou resultados satisfatórios, pois não houve total compatibilidade da corrente estimada com os quatro casos de operação analisados.

Quando foi realizada a estimação dos parâmetros com a fixação da resistência de estator, pôde-se constatar um comportamento similar ao Caso 1, onde não houve nenhum conjunto de parâmetros que conseguisse acompanhar a corrente de rotor bloqueado. A Figura 31 apresenta uma comparação entre o melhor e o pior caso, apenas analisando as correntes estimada e experimental de rotor bloqueado.



**Figura 31:** Caso 3, com  $R_1$  fixo, ensaio com rotor bloqueado: (a) Erro de 2,78%, (b) Erro de 3,15%

**Fonte: Autoria própria**

Assim, pode-se inferir que o acréscimo de mais um sinal de corrente como referência para a estimação dos parâmetros elétricos do MIT não é conveniente e, não contribui para a melhoria da estimação de parâmetros. Além disso, a inserção de mais um sinal de referência implica a modificação da FO, aumentando o seu tempo de processamento. A Tabela 7 apresenta um resumo dos resultados obtidos. Considera-se como resultado satisfatório o vetor, cuja corrente estimada foi compatível com as correntes experimentais dos quatro instantes diferentes de operação.

**Tabela 7:** Testes realizados para estimação de parâmetros

Teste realizado		FO (%)		Satisfatório
		Melhor	Pior	
Caso 1	Sem $R_1$ fixo	0,49	0,95	SIM
	Com $R_1$ fixo	0,56	0,97	NÃO
Caso 2	Sem $R_1$ fixo	0,47	1,21	SIM
	Com $R_1$ fixo	2,15	2,93	NÃO
Caso 3	Sem $R_1$ fixo	0,51	0,97	NÃO
	Com $R_1$ fixo	2,78	3,15	NÃO

A partir dos resultados analisados para a estimação dos parâmetros do MIT de 1CV utilizando o DE, conclui-se que os vetores obtidos nos Casos 1 e 2 sem  $R_1$  fixo podem ser utilizados para determinar o vetor de referência que será utilizado na identificação de falhas do MIT. Por uma questão de viabilidade, onde o ensaio com Tn ou qualquer outro valor de conjugado é mais simples do que o ensaio de rotor bloqueado, optou-se pela utilização do vetor de referência obtido pelo Caso 1.

Assim, para os demais algoritmos de otimização e, ainda, para o MIT de 2 CV foi implementado apenas o Caso 1, sem  $R_1$  fixo. As subseções a seguir apresentam os vetores de referências obtidos para ambos os motores, utilizando-se os três algoritmos de otimização diferentes. Ainda, são apresentados os parâmetros de configuração utilizados na implementação de cada algoritmo.

### 5.2.1 ESTIMAÇÃO DE PARÂMETROS UTILIZANDO EVOLUÇÃO DIFERENCIAL

Para a utilização do algoritmo de Evolução Diferencial é necessário fornecer informações relativas ao número de indivíduos da população analisada, taxa de cruzamento e fator de ponderação na mutação, bem como o espaço de busca utilizado. A Tabela 8 apresenta os valores atribuídos a cada um desses parâmetros.

**Tabela 8:** Informações do DE

<b>Espaço de Busca</b>	
$R_1$ ( $\Omega$ )	[2 20]
$R_2$ ( $\Omega$ )	[2 10]
$L_1$ (H)	[0,001 0,5]
$L_2$ (H)	[0,001 0,5]
$L_M$ (H)	[0,01 1]
<b>População</b>	
Número de indivíduos	15
<b>Mutação</b>	
Fator de Ponderação	rand(0,1)
<b>Cruzamento</b>	
Taxa de cruzamento	0,5

Por se tratar de um método estocástico, optou-se por realizar a estimação de parâmetros mais de uma vez e, a partir de um conjunto estimado, obteve-se a média desses valores. Para esse trabalho foram feitos 5 grupos com 20 estimações cada. Para cada conjunto de 20 estimações extraiu-se a média dos valores obtidos e, ao término da obtenção desses conjuntos, foi retirada a média das 5 médias. No total, são realizadas 100 estimações para o mesmo sinal, a fim de se obter um valor mais exato, eliminando possíveis discrepâncias.

As Tabelas 9 e 10 apresentam os resultados das 5 médias junto ao valor da FO. Na análise da FO foram apresentadas as parcelas, tanto para o ensaio com operação a vazio, quanto o ensaio com carga nominal. Embora a FO seja a soma de ambas, é válido analisar que as duas ficaram dentro do erro estabelecido como critério de parada ( $FO < 2\%$ ).

**Tabela 9:** Médias dos valores de referência para o MIT de 1 CV, utilizando DE

Média	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO_{vazio}$	$FO_{nominal}$	$FO_{total}$
1	12,8991	0,0182	4,0353	0,0215	0,4511	0,0028	0,0019	0,0047
2	12,9387	0,0189	4,0478	0,0229	0,4513	0,0028	0,0019	0,0047
3	12,9383	0,0190	4,0469	0,0234	0,4521	0,0028	0,0019	0,0047
4	12,9371	0,0175	4,1220	0,0221	0,4560	0,0029	0,0020	0,0049
5	12,9182	0,0185	4,0763	0,0217	0,4538	0,0028	0,0019	0,0047

**Tabela 10:** Médias dos valores de referência para o MIT de 2 CV, utilizando DE

Média	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO_{vazio}$	$FO_{nominal}$	$FO_{total}$
1	8,0346	0,0141	2,0509	0,0181	0,3088	0,0109	0,0080	0,0189
2	7,9818	0,0139	2,0539	0,0181	0,3090	0,0109	0,0080	0,0189
3	7,9524	0,0139	2,0524	0,0183	0,3094	0,0109	0,0080	0,0189
4	7,9431	0,0139	2,0532	0,0179	0,3091	0,0109	0,0080	0,0189
5	7,9084	0,0140	2,0513	0,0178	0,3092	0,0109	0,0080	0,0189

A partir da análise dos resultados apresentados, é possível observar que há um padrão característico para as médias em cada motor. Os valores apresentados tanto dos parâmetros quanto da FO são próximos, o que mostra que o algoritmo de otimização tem um comportamento bem definido. Ainda, é importante ressaltar que para cada estimação realizada foi gerada uma nova população inicial, aleatória e independente de qualquer outro resultado obtido.

Com relação ao número de iterações, o MIT 1 apresentou uma convergência mais rápida, com o número de iterações variando entre 1 e 40. Já para o MIT 2, houve maior número de iterações até a conversão, variando entre 20 e 100. Entretanto, devido às especificações do computador utilizado, cada média levou menos de 1 minuto para ser realizada, em ambos os casos.

A Tabela 11 apresenta os vetores finais que foram utilizados como referência para a identificação das falhas no MIT.

**Tabela 11:** Vetores de referência para identificação da falha utilizando o DE

Parâmetros	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$
MIT 1	12,9263	0,0194	4,0656	0,0223	0,4529
MIT 2	7,9640	0,0140	2,0253	0,0180	0,3091

A seguir, serão apresentados os resultados da estimação de parâmetros por meio do algoritmo de otimização PSO.

### 5.2.2 ESTIMAÇÃO DE PARÂMETROS UTILIZANDO *PARTICLE SWARM OPTIMIZATION*

O algoritmo PSO é um método bio-inspirado baseado no comportamento populacional. Para a sua utilização de forma adequada é necessário realizar o ajuste de alguns parâmetros do método, além de fornecer ao sistema informações sobre o espaço amostral que pode ser explorado. A Tabela 12 apresenta os valores utilizados em parâmetros do algoritmo, para que este pudesse ser aplicado à metodologia proposta.



**Tabela 12:** Informações do PSO

<b>Espaço de Busca</b>	
$R_1$ ( $\Omega$ )	[2 20]
$R_2$ ( $\Omega$ )	[2 10]
$L_1$ (H)	[0,001 0,5]
$L_2$ (H)	[0,001 0,5]
$L_M$ (H)	[0,01 1]
<b>População</b>	
Número de indivíduos	30
<b>Parâmetros do PSO</b>	
Coefficiente de aceleração pessoal $c_1$	2
Coefficiente de aceleração social $c_2$	2

Do mesmo modo que o DE, o PSO trata-se de um método estocástico, podendo admitir mais de uma solução para o mesmo problema apresentado. Assim, na busca pelo mínimo global, optou-se por considerar como resultado final a média de 5 médias realizadas, onde cada média individual é decorrente da estimação de 20 soluções candidatas iniciais distintas. Esta metodologia, segue o estabelecido para o algoritmo de evolução diferencial.

É importante ressaltar, que embora seja utilizada uma população de 30 indivíduos para este algoritmo, os 15 primeiros são os mesmos que foram utilizados no DE, a fim de estabelecer o maior número de soluções iniciais iguais. Assim, aproximam-se as condições iniciais entre os algoritmos utilizados, possibilitando a comparação com maior confiabilidade.

As Tabelas 13 e 14 mostram os resultados das 5 médias seguidas pelo valor de sua respectiva FO para os dois motores utilizados.

**Tabela 13:** Médias dos valores de referência para o MIT de 1 CV, utilizando PSO

Média	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO_{vazio}$	$FO_{nominal}$	$FO_{total}$
1	12,8712	0,0302	3,9320	0,0376	0,4653	0,0049	0,0030	0,0078
2	12,8434	0,0303	3,9304	0,0374	0,4652	0,0049	0,0030	0,0078
3	12,9305	0,0307	3,9274	0,0375	0,4654	0,0050	0,0066	0,0116
4	12,8121	0,0300	3,9399	0,0376	0,4657	0,0049	0,0030	0,0079
5	12,8752	0,0308	3,9225	0,0375	0,4655	0,0050	0,0066	0,0116

**Tabela 14:** Médias dos valores de referência para o MIT de 2 CV, utilizando PSO

Média	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO_{vazio}$	$FO_{nominal}$	$FO_{total}$
1	9,1202	0,0137	2,0405	0,0216	0,3073	0,0108	0,0080	0,0188
2	9,1331	0,0139	2,0376	0,0215	0,3070	0,0108	0,0080	0,0188
3	9,1312	0,0137	2,0398	0,0217	0,3074	0,0108	0,0080	0,0188
4	9,0841	0,0135	2,0449	0,0216	0,3074	0,0108	0,0080	0,0188
5	9,1161	0,0139	2,0378	0,0215	0,3073	0,0108	0,0080	0,0188

Analisando-se os parâmetros obtidos para o Motor 1, apresentados na Tabela 13, verifica-se uma semelhança com os parâmetros encontrado com o DE, apresentados na Tabela 9, exceto pelas indutâncias de dispersão ( $L_1$ ) e ( $L_2$ ). Este fator deve ser observado uma vez que se espera que ambas as indutâncias de dispersão possuam o mesmo valor, devido à classe do MIT (CHAPMAN, 2013; UMANS, 2014).

Por outro lado, quando observam-se as indutâncias de dispersão médias obtidas para o Motor 2, estas apresentam uma diferença média de 35% entre  $L_1$  e  $L_2$ . Além disso, também é possível verificar que há uma diferença mais significativa entre as resistências de estator de cada algoritmo de otimização.

Contudo, para ambos os AOs pode-se verificar que houve a convergência de todas as médias abaixo do valor do erro proposto para a FO, tendo o Motor 1 convergido com um erro menor do que o Motor 2.

Com relação ao processo iterativo, o uso do PSO apresentou uma vantagem sobre o DE, pois foi necessário um menor número de iterações até que o critério de parada fosse atingido. Neste caso, para o Motor 1 foram necessárias entre 2 e 20 iterações até atingir o critério de parada estabelecido e para o Motor 2 até 60 iterações.

A Tabela 15 apresenta o resultado das médias utilizadas como vetor de referência para o uso do PSO.

**Tabela 15:** Vetores de referência para identificação da falha utilizando o PSO

Parâmetros	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$
MIT 1	12,8665	0,0304	3,9304	0,0375	0,4654
MIT 2	9,1169	0,0137	2,0401	0,0216	0,3073

Comparando-se as Tabelas 15 e 11 pode-se observar que, as resistências e a indutância de magnetização apresentaram erro inferior a 5% quando comparados os dois métodos no Motor 1. O menor erro obtido foi 2,7%, com relação à indutância de magnetização ( $L_M$ ), a qual será utilizada para a identificação da falha. Já para o Motor 2, nota-se que três dos cinco parâmetros estimados possuem erros inferiores a 3%. Nova-

mente a indutância de magnetização apresenta a menor diferença quando se compara o resultado dos dois algoritmos utilizados (0,6%).

Na próxima seção são apresentados os resultados referentes ao uso do SA.

### 5.2.3 ESTIMAÇÃO DE PARÂMETROS UTILIZANDO *SIMULATED ANNEALING*

O *Simulated Annealing* é uma técnica que imita o processo de recozimento dos metais em busca de uma cristalização perfeita. Para seu funcionamento adequado, deve-se estabelecer o valor da temperatura inicial que será admitida, bem como o fator de resfriamento que será aplicado na busca de soluções satisfatórias. Além disso, considerando uma solução candidata inicial, é necessário saber qual é o espaço de busca em que cada elemento do vetor deve estar contido. A Tabela 16 apresenta os valores iniciais e fixos necessários na aplicação do algoritmo.

**Tabela 16:** Informações do SA

<b>Espaço de Busca</b>	
$R_1$ ( $\Omega$ )	[2 20]
$R_2$ ( $\Omega$ )	[2 10]
$L_1$ (H)	[0,001 0,5]
$L_2$ (H)	[0,001 0,5]
$L_M$ (H)	[0,01 1]
<b>População</b>	
Número de indivíduos	1
<b>Parâmetros do SA</b>	
Temperatura Inicial ( $T_0$ )	100
Fator de Resfriamento $\alpha$	0,9

Assim como os algoritmos DE e PSO, o SA é um método estocástico que busca um ótimo global, mas pode admitir mais de uma solução de acordo com as informações previamente fornecidas ao problema. Por esse motivo, visando a fuga de ótimos locais ou a obtenção de um resultado isolado não satisfatório, optou-se por realizar a média de 5 médias, do mesmo modo que para os demais algoritmos.

Ainda, é importante esclarecer que para esse algoritmo há apenas uma solução inicial aleatória, que é modificada até que um critério de parada estabelecido seja atingido. Nesse caso, utilizou-se o primeiro vetor do conjunto gerado para o PSO e DE, tendo a solução candidata inicial comum aos demais AOs.

As Tabelas 17 e 18 apresentam os resultados das 5 médias de cada motor estudado, com seu respectivo resultante na FO.

**Tabela 17:** Médias dos valores de referência para o MIT de 1 CV, utilizando SA

Média	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO_{vazio}$	$FO_{nominal}$	$FO_{total}$
1	13,5245	0,0146	4,1484	0,0331	0,4508	0,0029	0,0020	0,0049
2	13,6962	0,0139	4,1573	0,0354	0,4524	0,0028	0,0020	0,0048
3	13,5831	0,0141	4,1432	0,0340	0,4516	0,0029	0,0020	0,0049
4	13,4673	0,0141	4,1522	0,0334	0,4520	0,0028	0,0020	0,0048
5	13,5429	0,0139	4,1535	0,0343	0,4518	0,0029	0,0020	0,0049

**Tabela 18:** Médias dos valores de referência para o MIT de 2 CV, utilizando SA

Média	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO_{vazio}$	$FO_{nominal}$	$FO_{total}$
1	6,4574	0,0225	3,0288	0,0185	0,3795	0,0903	0,4015	0,4918
2	6,4881	0,0221	3,0048	0,0186	0,3793	0,0893	0,3909	0,4801
3	6,4498	0,0227	3,0247	0,0181	0,3582	0,1000	0,4135	0,5135
4	6,4962	0,0223	3,0300	0,0182	0,3852	0,0993	0,4134	0,5127
5	6,6392	0,0221	3,1146	0,0185	0,3879	0,1040	0,4502	0,5542

Em uma análise geral dos parâmetros obtidos para o Motor 1, na Tabela 17, pode-se observar que os erros da FO variam entre 0,48% e 0,49%, valores próximos aos obtidos com o DE na Tabela 9 (entre 0,47% e 0,48%). No entanto nota-se que para o SA, a diferença entre as indutâncias de dispersão de rotor e estator chega a 60%, apresentando um comportamento diferente dos apresentados nas Tabelas 9 e 13.

Já para o Motor 2 deve-se observar os valores atribuídos à FO. Nota-se que nenhuma das médias geradas atingiu o erro pré-estabelecido de até 2%, sendo necessária a utilização de parada pelo número de iterações.

Deve-se frisar que o critério de parada estabelecido para cada algoritmo de otimização foi feito com base em análises preliminares, onde foi observado para cada algoritmo o número médio de iterações até a convergência da FO proposta, no momento de implementação do algoritmo, ou seja, antes de sua validação.

Na referida análise foi observado que o SA apresentava uma diferença significativa de iterações até a convergência. Desta forma, atribuiu-se a quantidade de iterações máximas em 10 mil. Para o Motor 1, foi possível obter os resultados apresentados com até 5 mil iterações. Para o Motor 2, o algoritmo foi encerrado ao atingir as 10 mil iterações estabelecidas. Em testes de extrapolação, foi estabelecido um número de iterações máximas na ordem de 100 mil, mas não houve diferença com relação aos resultados.

A Tabela 19 apresenta os vetores de referência que foram utilizados para a etapa de classificação de falhas.

**Tabela 19:** Vetores de referência para identificação da falha utilizando o SA

Parâmetros	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$
MIT 1	13,5628	0,0141	4,1509	0,0340	0,4517
MIT 2	6,5062	0,0223	3,0406	0,0184	0,3834

A partir dos vetores de referência apresentados, é possível fazer uma análise quantitativa com relação à diferença dos demais vetores estimados com os algoritmos DE e PSO. Para o Motor 1, observa-se a diferença entre 0,26% e 3% para a indutância de magnetização, que será utilizada para a identificação da falha. Já para o Motor 2, essa diferença é superior a 18% em ambos os casos. No entanto, é importante ressaltar que não é a diferença entre os parâmetros estimados por diferentes algoritmos que contribui para a acurácia apresentada com o uso do SA e sim a influência do valor de  $L_M$  no erro da FO. A seguir é apresentado o resumo da seção.

### 5.2.3.1 RESUMO DA SEÇÃO DE ESTIMAÇÃO DE PARÂMETROS

Esta seção apresentou os parâmetros estimados do circuito elétrico equivalente de dois motores de indução trifásicos. A Tabela 20 apresenta o resumo dos vetores de referência obtidos para cada algoritmo de otimização, bem como o desvio padrão de cada parâmetro.

**Tabela 20:** Vetores de referência para identificação da falhas utilizando os algoritmos de otimização: DE, PSO e SA

<b>Motor 1</b>						
	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO$
DE	12,9263	0,0180	4,0656	0,0239	0,4529	0,0048
PSO	12,8665	0,0304	3,9304	0,0375	0,4654	0,0093
SA	13,5628	0,0141	4,1509	0,0340	0,4517	0,0049
<b>Motor 2</b>						
	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO$
DE	7,9640	0,0140	2,0253	0,0180	0,3091	0,0189
PSO	9,1169	0,0137	2,0401	0,0216	0,3073	0,0188
SA	6,5062	0,0223	3,0406	0,0184	0,3834	0,5105

A partir dos parâmetros estimados utilizando-se três algoritmos de otimização distintos, pode-se observar para o Motor 1 que a maior diferença obtida entre as resistências estimadas foi de 5,3% (comparando-se SA e PSO) e no caso da indutância de magnetização, o erro foi de 2,9% (comparando-se SA e PSO). Embora cada algoritmo seja tratado separadamente, é interessante observar a proximidade desses valores, pois mostra a robustez da metodologia proposta para a estimação de parâmetros.

No caso do Motor 2, observa-se uma diferença de 20% na indutância de magnetização estimada com o SA, quando comparado aos valores obtidos com o uso do DE e do PSO. Esse valor deve-se ao fato de que a convergência para o SA ocorreu pelo número de iterações. Por outro lado, ao comparar os algoritmo DE e PSO, nota-se uma diferença aproximada de 0,6% no valor da indutância de magnetização.

A Seção 5.3, apresenta a utilização desses parâmetros aplicados à identificação de falhas nos MITs. Será apresentado o resultado com relação a identificação das falhas de estator, rotor e rolamento separadamente e também a classificação de múltiplas falhas, com alimentação senoidal equilibrada e até 2% de desequilíbrio de tensão, além de variação de conjugado de carga, emulando as condições de trabalho na indústria.

### 5.3 IDENTIFICAÇÃO DE FALHAS

Nesta seção são descritos os principais resultados de identificação de falhas com o uso do classificadores de padrões RNA - do tipo PMC -, SVM e k-NN, treinados a partir dos parâmetros elétricos do circuito equivalente do MIT e do pico das correntes trifásicas. As medidas foram obtidas por meio de ensaios experimentais, utilizando dois motores de indução trifásicos de potências distintas e com alimentação direta da rede.

Neste trabalho, a estratégia apresentada visa o monitoramento e identificação de defeitos de estator, rotor e rolamento dos MITs. Foram realizadas cinco análises distintas de anomalias, sendo quatro binárias e uma multiclassificação, a saber: classificação binária individual, i.e. presença de falha com os defeitos de estator, rotor e rolamento analisados separadamente; classificação binária com todos os defeitos no mesmo conjunto amostral, onde as amostras defeituosas de estator, rotor e rolamento são consideradas apenas amostras com falha; e multiclassificação das falhas, onde as amostras, sem falha, com curto-circuito entre as espiras do estator, barras quebradas de rotor e desgaste de rolamento são tratadas em classes distintas, totalizando quatro classes.

Para determinar quais variações paramétricas forneceriam os melhores resultados para a identificação e multiclassificação da falha em um contexto geral, foram realizadas 7 combinações distintas de estimação, conforme apresentado na Tabela 3.

Dessa forma, foi criado um subconjunto de amostras com aproximadamente 10% da quantidade de dados total, contendo todas as informações necessárias do espaço amostral contendo variação de conjugado de carga, diferentes tipos de falhas e desequilíbrio de tensão e mantendo um *dataset* balanceado. O conjunto reduzido foi testado em todas

as combinações de variação de parâmetros. Ressalta-se que as estimações do conjunto amostral testado, foram realizadas utilizando-se o DE e a classificação foi feita por meio da RNA.

A partir desta análise, foi possível observar que os melhores resultados foram obtidos quando havia a variação somente do parâmetro de magnetização, pois este apresentou mudanças características com cada tipo de falha. Assim, o banco de dados para a entrada dos classificadores de padrões foi criado considerando a variação da indutância de magnetização.

Após a constatação de que apenas a variação de um parâmetros apresentou melhores resultados, foi testada a substituição do DE por um DE binário, a fim de aumentar a variação de possibilidades de resultados, conforme apresentado em Pampara et al. (2006), Wang et al. (2012), Zhang et al. (2020). No entanto, em seguida à implementação do DE binário, foi realizada a comparação entre este algoritmo e o tradicional, onde constatou-se que não houve diferença significativa nos resultados obtidos por ambos os métodos.

Assim, considerando também a possibilidade de implementação em *hardware*, optou-se por não utilizar a configuração binária em nenhum dos algoritmos de otimização estudado. Dessa forma, os resultados com os demais classificadores e algoritmos de otimização serão apresentados para a situação de variação da indutância de magnetização e picos das correntes trifásicas.

Esta subseção está dividida por algoritmo de otimização utilizado, tendo em vista que uma das contribuições do presente trabalho, está em apresentar uma metodologia que utiliza os parâmetros do circuito elétrico equivalente do MIT com o pico das correntes trifásicas do mesmo para a identificação da falha.

Antes da apresentação e comparação dos resultados, será apresentado, na subseção a seguir, o comportamento do MIT sujeito a cada falha, que foi observado no desenvolvimento deste trabalho e possibilitou a identificação destas por meio da metodologia proposta.

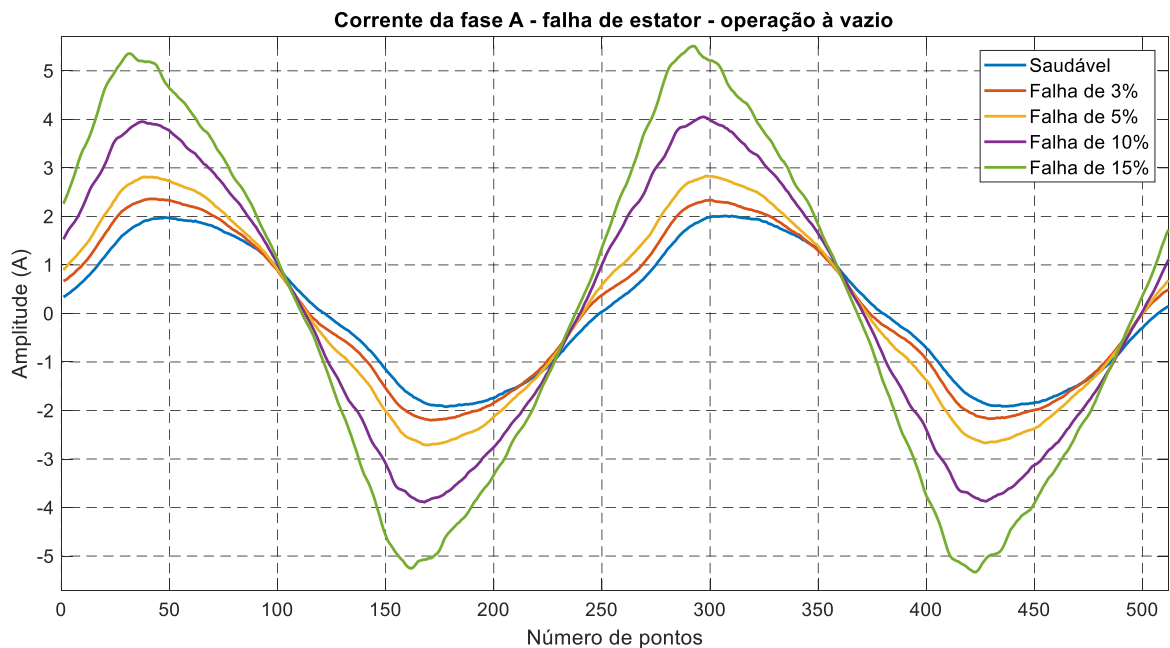
### 5.3.1 COMPORTAMENTO DO MIT SOB FALHAS DE ESTATOR, ROTOR E ROLAMENTO

Os defeitos apresentados no estator, rotor e rolamento de um MIT somam 88% das falhas totais diagnosticadas (BESSAM et al., 2016) e, por esse motivo, foram as três falhas consideradas nesta Tese. Os efeitos de cada defeito com relação à corrente e aos parâmetros

estimados são similares, independentemente do tipo de algoritmo de otimização utilizado e, por isso, serão discutidos nesta subseção, anterior aos resultados quantitativos. Ainda, será apresentado o comportamento das correntes do MIT sob o efeito das falhas em um mesmo banco de dados, que possibilite a análise da multiclassificação e presença de defeitos nos MITs.

### 5.3.1.1 FALHA DE ESTATOR

Para a identificação da falha de estator, foi construído um banco de dados com falhas de curto-circuito em 3%, 5% e 10% na fase A de ambos os motores estudados. Ainda, para o MIT 1 também foram considerados os sinais com 15% de curto-circuito. Para todos os casos foram considerados desequilíbrios de até 2%. A Figura 32 apresenta as curvas de corrente para os diferentes níveis de falha encontrados.



**Figura 32:** Comportamento da corrente com falha de curto-circuito no estator, para o Motor 1

**Fonte:** Autoria própria


O comportamento da corrente quando há falha de estator é bem característico, pois a corrente do estator permite uma análise visual. Quanto maior o nível de curto-circuito, maior é a amplitude da corrente e, menor a sua defasagem em relação à tensão. O aumento da corrente é diretamente relacionado à severidade da falha de curto-circuito,



i.e. quanto maior o nível do defeito, maior é a corrente de estator da fase em que este ocorre.

Fazendo uma análise simplificada do circuito elétrico equivalente do MIT, equação (13), se a tensão for considerada constante, o aumento da corrente será relacionado com a redução da impedância elétrica equivalente. Esta queda pode ser observada na variação do parâmetro de magnetização, que diminui com a elevação da corrente. Assim, é possível realizar a detecção da falha apenas pela alteração no valor da indutância de magnetização.

A Figura 33 apresenta um histograma com o comportamento dos dados fornecidos à entrada do classificador de padrões. Considerando que o curto-circuito de estator ocorreu apenas na fase A e que somente a indutância de magnetização sofreu alteração, o histograma apresenta os dados, normalizados, da corrente da fase A e da indutância de magnetização de um conjunto amostral que representa todo o banco de dados do MIT 1. Ainda, os dados apresentados estão normalizados (pelo valor máximo de cada conjunto de dados apresentados - corrente e indutância de magnetização), pois o valor da indutância de magnetização é inferior a 1 e o valor das correntes podem chegar a mais de 5A, o que não permitiria uma visualização detalhada dos dados.



**Figura 33:** Evolução da corrente e indutância com falha de curto-circuito no estator

**Fonte:** Autoria própria


Ao analisar os dados na Figura 33, observa-se que a indutância de magnetização é apresentada de forma crescente, onde os maiores valores encontram-se na região destacada, que corresponde ao conjunto de amostras sem falha. Avaliando ainda o comportamento da indutância de magnetização, pode-se notar também que no limiar da região destacada há algumas amostras defeituosas com magnitudes similares às das saudáveis. Entretanto, quando as respectivas correntes são comparadas, verifica-se a diferença de amplitude entre elas, o que permite ao classificador de padrões fazer a identificação correta da falha.

Considerando o comportamento da corrente apresentado, é possível notar que esta não decai na mesma proporção em que a indutância de magnetização aumenta. Isso acontece, pois a corrente do MIT aumenta, tanto com o aumento da falha, quanto com o aumento do conjugado de carga. Mesmo assim, é possível notar que não há nenhum caso em que ambos os dados apresentem compatibilidade completa, ou seja, no momento em que as correntes são similares, as indutâncias se diferenciam e vice-versa.

#### 5.3.1.2 FALHAS DE ROLAMENTO

Os sinais com falhas de rolamento foram obtidos por meio de ensaios realizados com pasta abrasiva, a fim de emular o desgaste que ocorre na indústria. Ainda, foram extraídas as características da corrente para os casos de desgaste de 15, 30, 60 e 90 minutos para os dois motores analisados. Para ampliar o espaço amostral, também foram aplicadas variações de torque de  $0,1T_n$  a  $1,2T_n$  e desequilíbrio de tensão de até 2%.

Diferente da falha de estator, a falha de rolamento não apresenta um comportamento bem definido que pode ser evidenciado na corrente de estator. A Figura 34 apresenta as curvas de corrente de estator para os diferentes níveis de falha de desgaste no rolamento no Motor 1, considerando tensões equilibradas e operação a vazio.




**Figura 34:** Comportamento da corrente com falha de desgaste de rolamento

**Fonte:** Autoria própria

Por meio da análise gráfica, pode-se observar que não há um padrão seguido pela corrente medida com relação à amplitude e defasagem para cada nível de falha. Entretanto, ao realizar a estimação dos parâmetros, foi possível observar o aumento aproximado de 10% no parâmetro de magnetização, o que pode justificar as pequenas variações de defasagem e amplitude.

Ao contrário da falha de estator, pode-se observar uma pequena variação na corrente de pico do MIT, com a diferença máxima de 2,7% entre o sinal com e sem falha, e a variação máxima de 5,76° de defasagem, o que justifica a alteração da impedância equivalente e, conseqüentemente a mudança de  $L_M$ .

A Figura 35 apresenta um histograma com o comportamento dos dados fornecidos à entrada do classificador de padrões do Motor 1 com tensões equilibradas.



**Figura 35:** Evolução da corrente de estator e indutância de magnetização com falha de rolamento no MIT 1 com tensões equilibradas

**Fonte: Autoria própria**


A falha de rolamento afeta igualmente todas as correntes do estator e esta variação pode ser obtida na análise da alteração do parâmetro de magnetização. Assim, o histograma apresenta os dados normalizados da corrente da fase A e da indutância de magnetização de um conjunto amostral contendo 20% da quantidade de dados totais que representam todo o banco de dados do MIT 1. Assim como para a análise das falhas de estator, foi realizada a normalização dos dados, pois o valor da indutância de magnetização é inferior a 1 e o valor das correntes podem chegar a mais de 5A.

Por meio da análise do histograma apresentado na Figura 35, é possível observar que os valores do parâmetro de magnetização para os dados do motor sem falha permanecem menores quando comparados a qualquer nível de conjugado de carga. Entretanto, não é possível observar a variação que permita identificar os diferentes níveis de desgaste de rolamento, assim como é possível perceber para o caso de falhas de estator.

### 5.3.1.3 FALHAS DE ROTOR

Para este trabalho foram realizados 4 tipos de ensaios diferentes para emular falhas de 1, 2 ou 4 barras de rotor rompidas, sendo que esta última eram de 4 barras em sequência e 2/2 barras diametralmente opostas. Conforme descrito na Tabela 2, foram considerados diferentes níveis de conjugado de carga - entre  $0,1T_n$  e  $1,2T_n$  - e desequilíbrio de tensão de até 2%.

Assim como na falha de rolamento, a falha de rotor também não apresenta um comportamento bem definido que pode ser evidenciado pelas amplitudes das correntes de linha do estator. A Figura 36 apresenta as curvas da corrente de estator para os diferentes níveis de falha de barras quebradas do rotor no Motor 2, considerando tensões equilibradas e operação a vazio.




**Figura 36:** Comportamento da corrente com falha de barras quebradas de rotor

**Fonte:** Autoria própria

A partir do gráfico apresentado, nota-se que não há um padrão seguido pela corrente com relação a amplitude e defasagem para cada nível de falha. É possível observar que os sinais apresentam defasagem considerando o mesmo instante de operação (a vazio com tensões equilibradas). Entretanto, o sinal sem falha não encontra-se em um dos limites da defasagem, ou seja, não está totalmente à direita ou à esquerda indicando um comportamento característico visível. Contudo, ao realizar a estimação de parâmetros foi possível observar que em alguns casos o aumento da indutância de magnetização é inferior a 10%, o que pode justificar as menores variações na defasagem.

A Figura 37 apresenta o gráfico de barras dos dados fornecidos à entrada do classificador de padrões do Motor 1, com tensões equilibradas.



**Figura 37:** Evolução da corrente de estator e indutância de magnetização com falha de rotor no MIT 1, com tensões equilibradas

**Fonte: Autoria própria**


Considerando que a falha de rotor é refletida igualmente nas três fases e que apenas a indutância de magnetização sofreu alteração, o gráfico de barras apresenta os dados normalizados da corrente da fase A e da indutância de magnetização de um conjunto amostral que representa todo o banco de dados do MIT 1.

A análise do gráfico evidencia o comportamento da indutância de magnetização, sendo possível constatar que há uma diferença mínima de 2,5% quando comparados os sinais saudáveis e com falha, onde os sem falha apresentam os valores inferiores, independentemente do nível de conjugado de carga.

#### 5.3.1.4 ANÁLISE DE MÚLTIPLAS FALHAS

Em uma análise inicial, é importante realizar a identificação da presença de uma falha para cada defeito separadamente, a fim de determinar o seu comportamento individual. Entretanto, em um ambiente industrial sabe-se que não é possível delimitar qual

falha será apresentada e, por esse motivo, há a necessidade de conseguir identificar a presença de falha, independentemente de qual seja. A Figura 38 apresenta um conjunto de amostras que representam todo o banco de dados, cujos níveis de falha e conjugado de carga variam de seu valor mínimo (0,1Tn) ao seu valor máximo (1,2Tn). Os dados apresentados foram organizados em ordem crescente, destacando-se as falhas e não falhas.



**Figura 38:** Comportamento da indutância de magnetização para identificação geral de presença de falha - operação a vazio

**Fonte:** Autoria própria

Por meio da análise gráfica, observa-se certa proximidade entre alguns valores com falha e não falha indicados na imagem. Os valores abaixo do valor de referência correspondem a falha de estator e os dados com maior magnitude correspondem às falhas próximas de 3% de curto-circuito nas espiras do estator, o que corresponde ao menor nível de curto inserido. Aplicando-se um *zoom* na região destacada e analisando a indutância de magnetização junto a corrente da fase A, conforme também apresentado na Figura 33, observa-se que a diferenciação entre os dados sem falha e com falha de estator é dada pela corrente da fase A.

Por fim, além da identificação da presença de falhas em um banco de dados que contenha todos os tipos de defeitos estudados, também é importante investigar qual é o tipo de falha apresentado. A multiclassificação de falhas permite determinar se há ou não a presença de uma falha e, em caso positivo, qual é o tipo de falha a ser monitorado.

A Figura 39 apresenta um conjunto de amostras que representa todo o banco de dados, organizado em ordem crescente e diferenciando os tipos de falhas. Analisando o gráfico de barras, pode-se constatar que a falha de estator possui uma característica bem distinta dos outros tipos de falhas, uma vez que, em todos os casos, seu maior valor para

a indutância de magnetização com a presença de curto-circuito é menor do que o valor de referência. Além disso, também é possível perceber que as falhas de rotor e rolamento resultam em indutâncias de magnetização com magnitude acima da referência.

Entretanto, nota-se que há o embaralhamento dos valores da indutância de magnetização para as falhas de rotor e rolamento. Este fato deve ser considerado neste momento, pois a proposta consiste em diferenciar cada uma das falhas. Por esse motivo, foi realizada a ampliação na imagem e apresentado cada um dos dados com seu respectivo valor de corrente, a fim de poder analisar o conjunto completo de entradas para os classificadores de padrões. É possível observar que alguns casos com valores de indutância similares, podem ser diferenciados pelo valor de pico da corrente, porém há também uma parcela em que não se consegue diferenciar, podendo levar ao diagnóstico incorreto do tipo de falha.

Tendo em vista a diferença entre as falhas de rotor e rolamento e, ainda, a proximidade destas com o motor operando sem falha, foram analisados 3 tipos de multiclassificação diferentes, a fim de identificar qual o melhor método para o diagnóstico exato, conforme já apresentado na Figura 20.

No primeiro caso foi utilizado apenas um classificador para identificar os quatro tipos de operações diferentes. No segundo caso foram usadas dois classificadores do mesmo tipo, sendo o primeiro para detectar a presença de falha e o segundo para classificar qual o tipo de falha, considerando apenas os dados defeituosos. Por fim, no último caso são utilizados três classificadores do mesmo tipo, onde o primeiro detecta a presença de falha, o segundo separa as falhas em estator ou rotor e rolamento, juntas, e o terceiro classificador diferencia as falhas de rotor e rolamento. Todas as formas de classificação foram aplicadas aos três classificadores: RNA, SVM e k-NN.



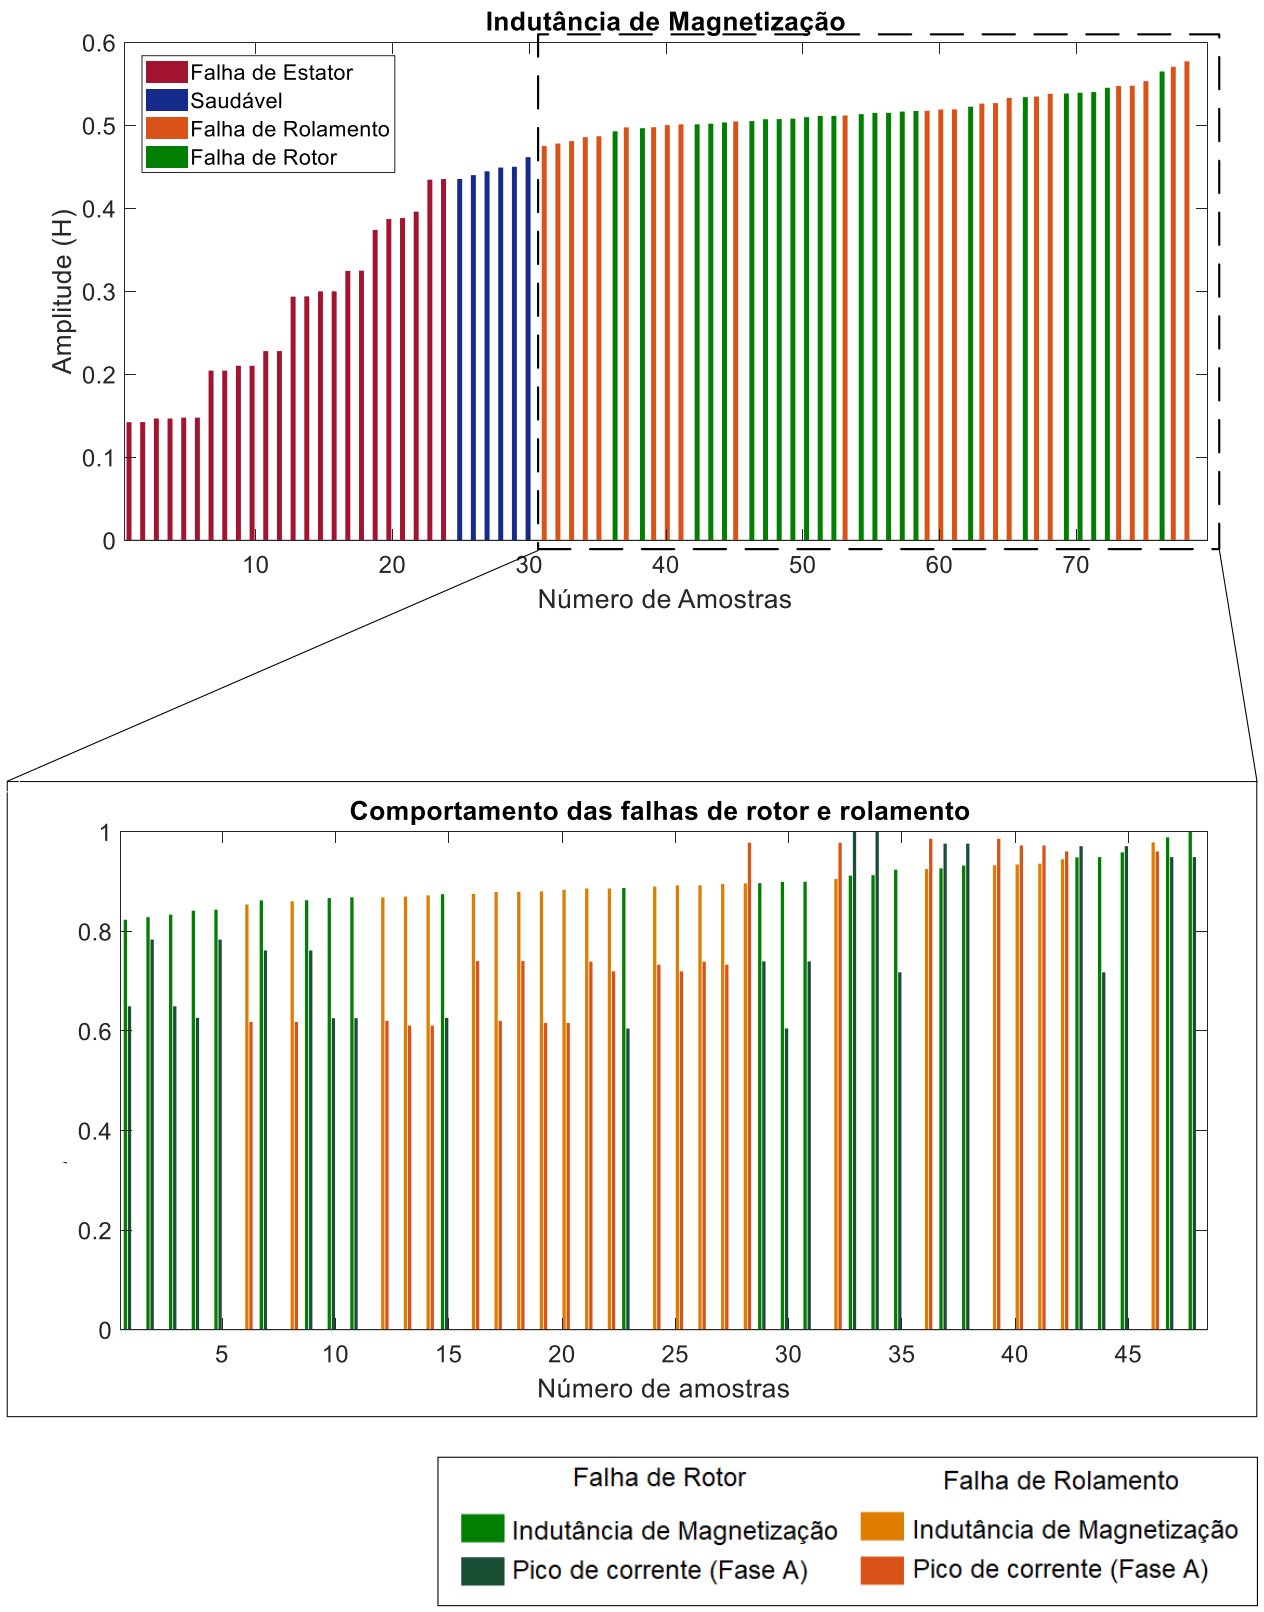


Figura 39: Amostra do conjunto de dados com todos os tipos de falhas

Fonte: Autoria própria

### 5.3.2 IDENTIFICAÇÃO DE FALHAS UTILIZANDO OS PARÂMETROS ESTIMADOS COM DE

Nesta subseção são apresentados os resultados de identificação de falhas, cujos dados de entrada dos classificadores foram obtidos por meio do uso do algoritmo de otimização DE.

Em todos os casos foram considerados desequilíbrios de tensão de até 2% e torque variando de 0,1Tn a 1,2Tn, com acionamento direto da rede. Foram utilizados três classificadores de padrões, RNA, SVM e k-NN, permitindo a comparação de resultados para determinar um método robusto de identificação das falhas. O primeiro classificador a ser apresentado é a RNA.

#### 5.3.2.1 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO RNA

A identificação de falhas com o uso das RNAs pode ser dividido em dois estágios, a saber: a análise das falhas individuais e a análise de múltiplas falhas. As Tabelas 21 e 22 apresentam, respectivamente, os resultados para os MITs 1 e 2, considerando a análise individual das falhas de estator, rotor e rolamento. Para cada motor foi utilizado um classificador RNA, treinado para o conjunto amostral analisado.

**Tabela 21:** Classificação de falhas individuais do Motor 1 utilizando DE/RNA

MIT 1 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	100,0	100,0	97,50	95,45	98,61
Acurácia - amostras sem falha (%)	100,0	100,0	100,0	93,75	86,00	100,0
Acurácia - amostras com falha (%)	100,0	100,0	100,0	97,91	100,0	97,50
Identificação de falso positivo (%)	0,00	0,00	0,00	6,25	14,00	0,00
Identificação de falso negativo (%)	0,00	0,00	0,00	2,09	0,00	2,50

**Tabela 22:** Classificação de falhas individuais do Motor 2 utilizando DE/RNA

MIT 2 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	91,67	97,5	100,0	91,67	100,0
Acurácia - amostras sem falha (%)	100,0	91,67	100,0	100,0	100,0	100,0
Acurácia - amostras com falha (%)	100,0	91,67	98,53	100,0	90,00	100,0
Identificação de falso positivo (%)	0,00	8,33	0,00	0,00	0,00	0,00
Identificação de falso negativo (%)	0,00	8,33	4,17	0,00	10,00	0,00

A partir dos dados apresentados na Tabela 21, é possível observar que o aumento do desequilíbrio de tensão ocasiona o decréscimo na exatidão da classificação para o Motor 1. É possível constatar que houve maior presença de falsos positivos, onde os sinais sem falhas são confundidos com dados defeituosos. Este fato ocorre, pois a falha de 3% de curto-circuito nas espiras do estator apresenta proximidade com o comportamento do

motor operando sem falha. Quando inserida a variação de tensão, há a alteração dos parâmetros estimados, uma vez que a corrente estimada é gerada com base na tensão fornecida. Assim, justifica-se a queda na taxa de acerto para o desequilíbrio de tensão.

Analisando-se os resultados apresentados na Tabela 22, observa-se que com o desequilíbrio de tensão, para esse caso específico, houve o aumento na taxa de acerto. No entanto, a diferença percentual entre os resultados com tensões equilibradas e desequilibradas para a falha de rolamento corresponde a aproximadamente duas amostras que foram classificadas incorretamente.

As Tabelas 23 e 24 apresentam os resultados referentes ao conjunto de dados que engloba as três falhas analisadas, inserido no classificador para a identificação da presença de falha e multiclassificação das mesmas. Conforme apresentado na Figura 20, a multiclassificação da falha foi realizada de três formas diferentes, a fim de verificar qual seria o melhor método para classificar múltiplas falhas.

Para cada tipo de falha são consideradas seis análises distintas, a saber: acurácia total do dados; acurácia dos dados sem falha; acurácia dos dados com falha; presença de falsos positivos (dados sem falha que apontam estar com falha, independente de seu tipo); presença de falsos negativos (qualquer anomalia que seja classificada como sem falha); classificação incorreta de falha (dado defeituoso que é apontado como outro tipo de falha, por exemplo, classificar uma falha de rotor como rolamento). Ainda, onde consta a sigla NA significa que aquele tipo de análise não se aplica àquele conjunto de dados.

**Tabela 23:** Multiclassificação de falhas do Motor 1 utilizando DE/RNA

MIT 1 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		96,80	100,0	90,28	100,0	92,85	80,00	97,04	76,92	99,43	81,25
Acurácia - amostras sem falha (%)		100,0	100,0	NA	NA	NA	77,78	100,0	NA	NA	NA
Acurácia - amostras com falha (%)		95,73	100,0	NA	NA	NA	80,65	94,23	NA	NA	NA
Identificação de falso positivo (%)		0,00	0,00	NA	NA	NA	22,20	0,00	NA	NA	NA
Identificação de falso negativo (%)		0,00	0,00	NA	NA	NA	3,23	5,77	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	0,00	0,57	NA
	Rotor	4,27		5,55	0,00	7,14	16,13		23,08	0,00	12,50
	Rolamento	0,00		4,17	0,00	0,00	0,00		0,00	0,00	6,25

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

**Tabela 24:** Multiclassificação de falhas do Motor 2 utilizando DE/RNA

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		96,55	91,54	96,97	100,0	97,92	94,74	91,02	96,96	97,78	97,92
Acurácia - amostras sem falha (%)		100,0	98,44	NA	NA	NA	90,00	80,00	NA	NA	NA
Acurácia - amostras com falha (%)		95,24	84,85	NA	NA	NA	100,0	93,77	NA	NA	NA
Identificação de falso positivo (%)		0,00	1,56	NA	NA	NA	10,00	20,00	NA	NA	NA
Identificação de falso negativo (%)		4,76	15,15	NA	NA	NA	0,00	6,23	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	1,52	0,00	NA
	Rotor	0,00		1,52	0,00	2,08	0,00		1,52		
	Rolamento	0,00		1,51	0,00	0,00	0,00		0,00	2,22	0,00

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
 FNF - Falha e não falha - Sem falha (0) Com falha(1)  
 E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
 E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
 R|R - Rotor(0), Rolamento (1)

Analisando-se inicialmente a multiclassificação da falha para o Motor 1, é possível observar que os dados apresentados com o MIT alimentado com tensões equilibradas levaram a erro apenas em falhas de rotor, que foram classificadas como falhas de rolamento. Ainda, quando é aplicado o desequilíbrio de tensão, há uma redução de 16,80% na acurácia total, refletida por uma queda significativa na taxa de acerto dos dados com falha e sem falha. Considerando o desequilíbrio de tensão, 22,2% dos dados sem falha são classificados como falso positivos, mas apenas 3,23% dos dados com falha foram classificados como falso negativo. Ainda, é possível observar o aumento na classificação incorreta das falhas de rotor, que são classificadas como defeitos de rolamento, justificada pela semelhança apresentada na Figura 39.

Já para a análise de falha e não falha, seguida pelas demais multiclassificações, é possível observar que os melhores resultados foram obtidos para os dados equilibrados ou quando não era necessária a identificação das falhas de rotor ou rolamento. Ainda, não houve a identificação incorreta de nenhuma amostra com defeito de estator para dados equilibrados e apenas 0,57% para dados com tensões desequilibradas. Por fim, observa-se o aumento de 5,36% na classificação da falha de rotor como falha de rolamento para o desequilíbrio de tensão e 6,25% na identificação da falha de rolamento como defeito de rotor.

Considerando a análise do Motor 2, é possível fazer uma observação semelhante à realizada na Tabela 22, onde o desequilíbrio de tensão não apresentou influência significativa na taxa de acerto de todos os tipos de combinações analisadas. Outra importante constatação para esse caso, é que a análise das diferentes multiclassificações apresentaram resultados semelhantes entre si, com a diferença máxima de 2,22% entre as colunas 4 e 9 de resultados (classificação E|RR).

Na próxima seção será apresentada a análise da identificação dos dados estimados com o uso do DE, aplicado ao classificador SVM.

### 5.3.2.2 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO SVM

O segundo tipo de classificador a ser utilizado para a identificação de falhas é o SVM. Nessa etapa, são apresentados ao classificador os mesmos dados obtidos com o uso do DE, bem como as correntes de pico das três fases normalizadas, utilizados na classificação com a RNA. As Tabelas 25 e 26 apresentam, respectivamente, os resultados para os Motores 1 e 2, considerando a análise das falhas individuais. O treinamento e validação ocorram com cada motor separadamente.

**Tabela 25:** Classificação de falhas individuais do Motor 1 utilizando DE/SVM

MIT 1 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	100,0	100,0	96,25	88,89	83,33
Acurácia - amostras sem falha (%)	100,0	100,0	100,0	93,75	71,43	71,43
Acurácia - amostras com falha (%)	100,0	100,0	100,0	100,0	100,0	90,91
Identificação de falso positivo (%)	0,00	0,00	0,00	6,25	28,57	28,57
Identificação de falso negativo (%)	0,00	0,00	0,00	4,17	0,00	9,09

**Tabela 26:** Classificação de falhas individuais do Motor 2 utilizando DE/SVM

MIT 2 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	89,58	97,50	100,0	91,67	100,0
Acurácia - amostras sem falha (%)	100,0	87,50	100,0	100,0	100,0	100,0
Acurácia - amostras com falha (%)	100,0	91,67	98,53	100,0	90,00	100,0
Identificação de falso positivo (%)	0,00	12,50	0,00	0,00	0,00	0,00
Identificação de falso negativo (%)	0,00	8,33	4,17	0,00	10,00	0,00

A partir da análise dos resultados apresentados para o Motor 1, observa-se que a classificação para as falhas com alimentação equilibrada manteve-se igual à RNA. Entretanto, quando aplica-se o desequilíbrio de tensão, tem-se 88,89% e 83,33% de acurácia para as falhas de rotor e rolamento, respectivamente, com um alto índice de falsos positivos. Esse fato, deve-se à proximidade entre os valores de indutância de magnetização e correntes dos dados com e sem falha, que são fornecidos à entrada do classificador. Devido a essa amplitude próxima, os dados não são identificados corretamente de acordo com os hiperplanos separadores obtidos no treinamento. Por outro lado, pode-se observar uma taxa de acerto para as falhas de estator, superior ao obtido com a RNA.

Com relação ao Motor 2, observam-se os melhores resultados para os dados com desequilíbrio de tensão, assim como na classificação utilizando-se RNA. Ainda, a diferença percentual entre os dados com desequilíbrio e equilibrados, correspondem a cerca de duas amostras, o que pode não ser considerado significativo devido ao uso de um método estocástico para a estimação de parâmetros.

As Tabelas 27 e 28 apresentam os resultados para a multiclassificação, utilizando

como classificador de padrões o SVM. A classificação foi realizada utilizando o mesmo procedimento aplicado à RNA, e considerando as mesmas análises.

**Tabela 27:** Multiclassificação de falhas do Motor 1 utilizando DE/SVM

MIT 1 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		83,33	67,35	77,78	100,0	91,66	66,67	91,13	72,73	99,43	62,50
Acurácia - amostras sem falha (%)		100,0	100,0	NA	NA	NA	33,33	94,44	NA	NA	NA
Acurácia - amostras com falha (%)		77,78	23,81	NA	NA	NA	73,69	87,98	NA	NA	NA
Identificação de falso positivo (%)		0,00	0,00	NA	NA	NA	66,67	5,56	NA	NA	NA
Identificação de falso negativo (%)		0,00	76,19	NA	NA	NA	2,63	12,02	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	0,00	0,57	NA
	Rotor	22,22		0,00	8,33	23,68	11,36		31,25		
	Rolamento	0,00		22,22	0,00	0,00	15,91		6,25		

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

**Tabela 28:** Multiclassificação de falhas do Motor 2 utilizando DE/SVM

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		86,73	82,54	96,97	100,0	97,92	81,63	82,54	93,75	97,62	97,92
Acurácia - amostras sem falha (%)		100,0	100,0	NA	NA	NA	50,0	100,0	NA	NA	NA
Acurácia - amostras com falha (%)		80,30	66,67	NA	NA	NA	91,89	66,67	NA	NA	NA
Identificação de falso positivo (%)		0,00	0,00	NA	NA	NA	50,00	0,00	NA	NA	NA
Identificação de falso negativo (%)		18,18	33,33	NA	NA	NA	8,11	33,33	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	6,25	0,00	NA
	Rotor	0,00		1,51	2,08	0,00	0,00		4,18		
	Rolamento	1,52		1,52	0,00	0,00	0,00		0,00		

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

Observando-se o resultado do Motor 1, pode-se constatar que as melhores taxas de acerto correspondem as análises que possuem apenas duas classes, como é o caso da identificação de falha, separação da falha de estator e a classificação das falhas de rotor e rolamento.

No Motor 2 a multiclassificação (MC) apresentou 86,73% de acurácia máxima, a qual é inferior à RNA, utilizando os mesmos dados. Outra observação a ser feita está relacionada à identificação de falha, que apresentou 82,54% de acurácia, a qual é semelhante à multiclassificação de falhas. Entretanto, para a análise desconsiderando as amostras sem falha foi possível obter uma acurácia mínima de 93,75%.

A seção a seguir apresenta o k-NN, utilizado para classificar os parâmetros estimados por meio do DE.

### 5.3.2.3 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO K-NN

O k-NN é utilizado neste trabalho para a classificação dos parâmetros estimados com o DE. Neste contexto, os dados apresentados para o classificador, foram os mesmos utilizados para a RNA e o SVM, a fim de verificar qual o melhor desempenho dentre os

três. As Tabelas 29 e 30 apresentam os resultados relacionados à identificação individual das falhas de estator, rotor e rolamento.

**Tabela 29:** Classificação de falhas individuais do Motor 1 utilizando DE/k-NN

MIT 1 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	100,0	100,0	90,00	88,89	94,44
Acurácia - amostras sem falha (%)	100,0	100,0	100,0	93,75	100,0	93,75
Acurácia - amostras com falha (%)	100,0	100,0	100,0	87,50	81,82	95,00
Identificação de falso positivo (%)	0,00	0,00	0,00	6,25	0,00	6,25
Identificação de falso negativo (%)	0,00	0,00	0,00	12,5	18,18	5,00

**Tabela 30:** Classificação de falhas individuais do Motor 2 utilizando DE/k-NN

MIT 2 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	89,58	95,00	86,67	90,91	97,22
Acurácia - amostras sem falha (%)	100,0	91,67	93,75	91,67	100,0	91,67
Acurácia - amostras com falha (%)	100,0	87,50	95,83	83,33	88,89	100,0
Identificação de falso positivo (%)	0,00	8,33	6,25	8,33	0,00	8,33
Identificação de falso negativo (%)	0,00	12,50	4,17	16,67	11,11	0,00

Analisando-se inicialmente o Motor 1, pode-se observar a mesma taxa de acerto para os dados equilibrados, assim como na classificação com RNA e SVM. Por outro lado, considerando-se o desequilíbrio de tensão, observa-se a acurácia máxima de 86,67%. Ainda, é possível observar também que a maior parte dos dados identificados incorretamente correspondem a falsos positivos. Uma vez que a tensão é utilizada na estimação de parâmetros, o desequilíbrio aplicado afeta o modelo do circuito elétrico equivalente, fazendo com que os dados sem falha acabem sendo classificados com algum tipo de defeito.

Para o Motor 2, é possível observar a mesma taxa de acerto para as falhas de estator com tensões equilibradas (100%). Ainda, tem-se valores próximos de exatidão na classificação quando comparado aos resultados obtidos pelo uso dos demais classificadores. No caso da falha de estator, o desequilíbrio de tensão faz com que alguns dados sem falha sejam confundidos com o defeito de 3% de curto-circuito nas espiras do estator.

As Tabelas 31 e 32 apresentam os resultados da multiclassificação das falhas, onde são consideradas todas as falhas em um mesmo banco. Vale frisar, que os dados utilizados como entrada do classificador são os mesmos utilizados com os demais classificadores.

**Tabela 31:** Multiclassificação de falhas do Motor 1 utilizando DE/k-NN

MIT 1 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		90,63	100,0	86,62	100,0	93,75	78,13	98,77	70,31	99,43	56,25
Acurácia - amostras sem falha (%)		100,0	100,0	NA	NA	NA	100,0	100,0	NA	NA	NA
Acurácia - amostras com falha (%)		87,50	100,0	NA	NA	NA	72,66	97,60	NA	NA	NA
Identificação de falso positivo (%)		0,00	0,00	NA	NA	NA	0,00	0,00	NA	NA	NA
Identificação de falso negativo (%)		0,00	0,00	NA	NA	NA	0,78	2,40	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	1,56	0,57	NA
	Rotor	5,56		6,94	0,00	0,00	14,06		25,78	0,00	26,25
	Rolamento	6,94		6,94	0,00	6,25	5,47		2,34	0,00	17,50

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

**Tabela 32:** Multiclassificação de falhas do Motor 2 utilizando DE/k-NN

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		85,71	97,73	90,90	100,0	93,75	93,88	97,62	93,75	92,22	95,84
Acurácia - amostras sem falha (%)		93,75	100,0	NA	NA	NA	100,00	100,0	NA	NA	NA
Acurácia - amostras com falha (%)		81,82	95,00	NA	NA	NA	91,89	95,45	NA	NA	NA
Identificação de falso positivo (%)		6,25	0,00	NA	NA	NA	0,00	0,00	NA	NA	NA
Identificação de falso negativo (%)		9,09	5,00	NA	NA	NA	2,70	4,55	NA	NA	NA
Classificação incorreta da falha (%)	Estator	3,03	NA	0,00	0,00	NA	2,70	NA	6,25	0,00	NA
	Rotor	3,03		4,55	0,00	6,25	1,35		0,00	7,78	2,08
	Rolamento	3,03		4,55	0,00	1,35	0,00		0,00	0,00	2,08

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

A partir dos dados apresentados para os motores 1 e 2, observa-se a acurácia mínima de 85,71% para a multiclassificação com tensões equilibradas e 56,25% na identificação de falhas de rotor e rolamento em condições de desequilíbrio de tensão. Por esse motivo, pode-se constatar que o Motor 2 apresentou menos variações do que o Motor 1, onde a classificação das falhas de rotor e rolamento, para o MIT de 2 CV, foi 95,84% com tensões desequilibradas.

A seção a seguir apresenta os resultados da identificação de falhas em MIT, considerando o algoritmo de otimização PSO como estimador de parâmetros.

### 5.3.3 IDENTIFICAÇÃO DE FALHAS UTILIZANDO OS PARÂMETROS ESTIMADOS COM PSO

Esta subseção apresenta os resultados de classificação de falhas utilizando como estimador de parâmetros o PSO, algoritmo que corresponde à família dos algoritmos bio-inspirados. De forma resumida, pode-se afirmar que o PSO é baseado no comportamento de bandos, tais como partículas, vaga-lumes e formigas, para tratar problemas de otimização complexos.

Os parâmetros gerados com o PSO, junto ao pico das correntes de estator, compõem o segundo conjunto de dados a ser analisado pelos três diferentes classificadores, RNA, SVM e k-NN, apresentados nessa ordem, respectivamente.



### 5.3.3.1 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO RNA

O primeiro classificador a ser utilizado foi a RNA. A fim de se permitir uma comparação satisfatória, utilizou-se a mesma topologia da RNA aplicada à classificação de falhas dos dados gerados com o uso do DE. As Tabelas 33 e 34 apresentam os resultados para a análise das falhas individuais, estator, rotor e rolamento.

**Tabela 33:** Classificação de falhas individuais do Motor 1 utilizando PSO/RNA

MIT 1 CV	Tensões Equilibradas			Desequilíbrio de até 2%		
Classificação	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	97,22	98,61	95,00	88,89	97,22
Acurácia - amostras sem falha (%)	100,0	100,0	100,0	93,75	87,50	100,0
Acurácia - amostras com falha (%)	100,0	95,00	97,50	95,83	90,00	95,00
Identificação de falso positivo (%)	0,00	0,00	0,00	6,25	12,50	0,00
Identificação de falso negativo (%)	0,00	5,00	2,50	4,17	10,00	5,00

**Tabela 34:** Classificação de falhas individuais do Motor 2 utilizando PSO/RNA

MIT 2 CV	Tensões Equilibradas			Desequilíbrio de até 2%		
Classificação	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	85,71	100,0	100,0	87,50	100,0
Acurácia - amostras sem falha (%)	100,0	83,33	100,0	100,0	100,0	100,0
Acurácia - amostras com falha (%)	100,0	87,50	100,0	100,0	77,78	100,0
Identificação de falso positivo (%)	0,00	16,67	0,00	0,00	0,00	0,00
Identificação de falso negativo (%)	0,00	12,50	0,00	0,00	22,22	0,00

Iniciando a análise pelos dados apresentados pela Tabela 33, observa-se uma taxa de acerto inferior a 100%, para as falhas de rotor e rolamento, com alimentação equilibrada. Entretanto, os resultados apresentados aproximam-se da taxa máxima de acerto, correspondendo a cerca de 95% para as amostras com defeito de rotor e 97,5% para as amostras com falha de rolamento. Por outro lado, considerando-se o desequilíbrio de tensão, é possível observar a acurácia de 88,89% para rotor e 97,22% para rolamento.

Os resultados apresentados para o Motor 2 apontam 100,0% de acerto para as falhas de estator e rolamento, com e sem desequilíbrio de tensão quando utiliza-se a RNA aplicada aos dados gerados pelo PSO. Entretanto, tratando-se da falha de rotor, observa-se uma acurácia 85,71% com a presença de falsos negativos e positivos, em 12,50% e 16,67%, respectivamente, para tensões equilibradas.

As Tabelas 35 e 36 apresentam os resultados considerando a multiclassificação das falhas. Foram seguidos os mesmos procedimentos da Subseção 5.3.2, que faz a identificação de múltiplas falhas por meio de três multiclassificações distintas, como apresentado na Figura 20.

**Tabela 35:** Multiclassificação de falhas do Motor 1 utilizando PSO/RNA

MIT 1 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		66,67	93,82	65,52	100,0	60,00	72,50	94,50	69,23	100,0	56,25
Acurácia - amostras sem falha (%)		57,14	96,25	NA	NA	NA	66,67	100,0	NA	NA	NA
Acurácia - amostras com falha (%)		55,56	91,84	NA	NA	NA	74,19	89,42	NA	NA	NA
Identificação de falso positivo (%)		42,86	3,75	NA	NA	NA	33,33	0,00	NA	NA	NA
Identificação de falso negativo (%)		3,70	8,16	NA	NA	NA	6,45	10,58	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	0,00	0,00	NA
	Rotor	22,22		25,00	0,00	40,00	6,45		19,23	25,00	
	Rolamento	0,00		9,48	0,00	0,00	12,90		11,54	0,00	18,75

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

**Tabela 36:** Multiclassificação de falhas do Motor 2 utilizando PSO/RNA

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		86,59	92,31	96,97	100,0	93,75	83,87	97,10	98,48	100,0	97,92
Acurácia - amostras sem falha (%)		62,50	100,0	NA	NA	NA	44,44	92,86	NA	NA	NA
Acurácia - amostras com falha (%)		92,42	81,82	NA	NA	NA	100,0	82,35	NA	NA	NA
Identificação de falso positivo (%)		37,50	0,00	NA	NA	NA	55,56	7,14	NA	NA	NA
Identificação de falso negativo (%)		4,55	18,18	NA	NA	NA	0,00	17,65	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	0,00	0,00	NA
	Rotor	4,55		3,03	0,00	4,17	0,00		1,52	2,08	
	Rolamento	3,03		0,00	2,08	0,00	0,00		0,00	0,00	

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

Os resultados mostrados para o Motor 2, apresentam índices de acerto superiores a 92%, apontando que a identificação de falhas pela multiclassificação 2 e 3, conforme Figura 20, é mais eficiente nesse caso. Já para a multiclassificação 1, onde há a utilização de apenas uma RNA foi possível obter uma taxa de acerto máxima de 86,59%.

Para o Motor 1, os resultados mostrados apontam um índice de acerto superior a 90%, apenas quando as falhas de rotor e rolamento não devem ser identificadas de forma separada. Esse fato se explica pela análise das colunas 5 e 10, que apontam a dificuldade em separá-las, cuja taxa de acerto máxima para classificação das falhas de rotor e rolamento foi 60%.

### 5.3.3.2 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO SVM

O segundo classificador utilizado para a identificação de falhas foi o SVM, tendo como dados de entradas as informações advindas da estimação de parâmetros com o PSO, bem como as correntes de pico de estator. Vale ressaltar, que as amostras utilizadas no classificador SVM são as mesmas fornecidas à RNA e, posteriormente, ao k-NN. As Tabelas 37 e 38 apresentam os resultados para a classificação individual das falhas.

**Tabela 37:** Classificação de falhas individuais do Motor 1 utilizando PSO/SVM

MIT 1 CV	Tensões Equilibradas			Desequilíbrio de até 2%		
Classificação	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	97,06	76,00	79,17	95,00	62,50	72,22
Acurácia - amostras sem falha (%)	100,0	75,00	59,38	93,75	28,13	40,63
Acurácia - amostras com falha (%)	94,44	76,92	95,00	95,83	90,00	97,50
Identificação de falso positivo (%)	0,00	25,00	40,63	6,25	71,87	59,37
Identificação de falso negativo (%)	5,56	23,08	15,00	4,17	10,00	2,50

**Tabela 38:** Classificação de falhas individuais do Motor 2 utilizando PSO/SVM

MIT 2 CV	Tensões Equilibradas			Desequilíbrio de até 2%		
Classificação	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	97,06	85,71	95,00	97,06	81,25	91,67
Acurácia - amostras sem falha (%)	100,0	83,33	93,75	100,0	71,43	83,33
Acurácia - amostras com falha (%)	94,44	87,50	95,83	94,44	88,89	100,0
Identificação de falso positivo (%)	0,00	16,67	6,25	0,00	28,57	16,67
Identificação de falso negativo (%)	5,56	12,50	4,17	5,56	11,11	0,00

A partir da análise dos resultados mostrados com relação ao Motor 1, é possível estabelecer duas considerações. A primeira, está relacionada à falha de estator, que apresenta acurácia de 94,44% para as amostras com falha e 100% para as amostras sem falha, totalizando a taxa de acerto de 97,06%.

A segunda consideração, aponta que as falhas de rotor e rolamento apresentam uma taxa de acerto total de 76% e 79,17%, respectivamente. Estes resultados, quando comparados aos obtidos para o estator, indicam que as informações apresentadas ao classificador não são capazes de serem separadas dentro dos hiperplanos estabelecidos pelo SVM.

Já para o Motor 2, é possível constatar que as taxas de acerto apresentadas são superiores a 80%, com tensões equilibradas e desequilibradas. Assim como para o Motor 1, a falha de estator apresentou maior índice de classificações corretas (97,06%), seguida pelos defeitos em rolamento e rotor, respectivamente.

Na sequência das análises dos resultados com a utilização do conjunto PSO/SVM, as Tabelas 39 e 40 apresentam os resultados para a identificação de múltiplas falhas.

**Tabela 39:** Multiclassificação de falhas do Motor 1 utilizando PSO/SVM

MIT 1 CV	Tensões Equilibradas					Tensões Desequilibradas				
Classificação	MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)	56,08	86,11	61,21	100,0	51,85	53,13	63,50	67,97	99,43	51,25
Acurácia - amostras sem falha (%)	46,88	87,50	NA	NA	NA	32,35	81,25	NA	NA	NA
Acurácia - amostras com falha (%)	58,62	85,00	NA	NA	NA	73,92	47,12	NA	NA	NA
Identificação de falso positivo (%)	53,13	12,50	NA	NA	NA	67,65	18,75	NA	NA	NA
Identificação de falso negativo (%)	9,48	15,00	NA	NA	NA	0,00	52,88	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00		0,00	0,00	0,00		1,56	0,00	NA
	Rotor	19,83	NA	16,38	0,00	25,93	13,04	NA	17,97	38,75
	Rolamento	12,07		22,41		22,22	13,04		12,50	10,00

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

**Tabela 40:** Multiclassificação de falhas do Motor 2 utilizando PSO/SVM

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		70,73	65,63	92,42	100,0	95,83	62,22	78,57	87,88	86,90	95,83
Acurácia - amostras sem falha (%)		55,10	83,33	NA	NA	NA	50,00	91,67	NA	NA	NA
Acurácia - amostras com falha (%)		86,36	42,86	NA	NA	NA	66,67	66,67	NA	NA	NA
Identificação de falso positivo (%)		44,90	16,67	NA	NA	NA	50,00	8,33	NA	NA	NA
Identificação de falso negativo (%)		0,00	57,14	NA	NA	NA	22,73	33,33	NA	NA	NA
Classificação incorreta da falha (%)	Estator	3,03	NA	0,00	0,00	NA	9,09	NA	9,09	13,10	NA
	Rotor	6,06		4,55	0,00	4,17	1,52		3,03	8,33	
	Rolamento	4,55		3,03	0,00	0,00	0,00		0,00	0,00	

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

Considerando-se primeiramente as informações apresentadas na Tabela 39, observa-se que apenas a identificação das falhas de estator com rotor ou rolamento (E|RR) apresentam índices superiores a 90%, pois nesse caso não há a presença das amostras saudáveis, e nem a necessidade de separar as falhas de rotor e rolamento. As demais classificações, apresentam taxas de acerto inferiores a 70%, justificado pela dificuldade em separar os diferentes tipos de falhas, em especial o conjunto que contém dados de rotor e rolamento.

Um comportamento semelhante pode ser observado no Motor 2, quando são analisadas as classificações contendo as amostras sem falha. Observa-se o decréscimo nas taxas de acerto para multiclassificação e para a presença de falha, acompanhado de índices superiores a 40% na identificação de falsos positivos.

Por outro lado, as classificações realizadas que não consideram as amostras sem falha, apresentam índices superiores a 90% para dados equilibrados, e 85% para dados desequilibrados.

A seguir são apresentados os resultados obtidos para o classificador k-NN.

### 5.3.3.3 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO K-NN

O último classificador a ser utilizado para a identificação de falhas é o k-NN. Novamente, foram considerados os mesmos dados utilizados nos outros dois classificadores (RNA e SVM), a fim de estabelecer uma comparação factível. As Tabelas 41 e 42 apresentam os resultados das classificações individuais de cada falha: estator, rotor e rolamento.

**Tabela 41:** Classificação de falhas individuais do Motor 1 utilizando PSO/k-NN

MIT 1 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	91,67	93,06	97,22	90,00	86,11	94,44
Acurácia - amostras sem falha (%)	83,33	93,75	93,75	93,75	93,75	93,75
Acurácia - amostras com falha (%)	100,0	92,50	100,0	87,50	80,00	95,00
Identificação de falso positivo (%)	16,67	6,25	6,25	6,25	6,25	6,25
Identificação de falso negativo (%)	0,00	7,50	0,00	12,50	20,00	5,00

**Tabela 42:** Classificação de falhas individuais do Motor 2 utilizando PSO/k-NN

MIT 2 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	82,50	92,86	93,33	91,67	100,0
Acurácia - amostras sem falha (%)	100,0	68,75	83,33	91,67	100,0	100,0
Acurácia - amostras com falha (%)	100,0	91,67	100,0	94,44	83,33	100,0
Identificação de falso positivo (%)	0,00	31,25	16,67	8,33	0,00	0,00
Identificação de falso negativo (%)	0,00	8,33	0,00	5,56	16,67	0,00

Os resultados apresentados para o Motor 1 apontam acurácias superiores a 90%, para tensões equilibradas, com a presença de falso negativo apenas para a falha de rotor. Já para a análise das tensões desequilibradas, observa-se que a falha de rolamento apresentou a melhor taxa de acerto (94,44%) e o menor índice de falso negativo.

Nos aspectos que dizem respeito aos resultados referentes ao Motor 2, observa-se que as menores taxas de acerto, 82,5% e 91,67%, correspondem aos defeitos de rotor. Ainda, para tensões equilibradas, somente a falha de rotor apresentou índices de falso negativo.

As Tabelas 43 e 44 apresentam os resultados relacionados às multiclassificações empregadas.

**Tabela 43:** Multiclassificação de falhas do Motor 1 utilizando PSO/k-NN

MIT 1 CV Classificação	Tensões Equilibradas					Tensões Desequilibradas				
	MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)	64,18	97,75	60,34	100,0	60,00	73,13	95,50	76,92	100,0	62,50
Acurácia - amostras sem falha (%)	81,25	100,0	NA	NA	NA	100,0	100,0	NA	NA	NA
Acurácia - amostras com falha (%)	59,48	95,92	NA	NA	NA	66,41	91,35	NA	NA	NA
Identificação de falso positivo (%)	18,75	0,00	NA	NA	NA	0,00	0,00	NA	NA	NA
Identificação de falso negativo (%)	2,59	4,08	NA	NA	NA	6,25	8,65	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00		0,00	0,00	NA	0,00		0,00	0,00
	Rotor	19,83	NA	14,66	0,00	25,00	17,97	NA	19,23	31,25
	Rolamento	18,10		25,00		15,00	9,38		3,85	0,00

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

**Tabela 44:** Multiclassificação de falhas do Motor 2 utilizando PSO/k-NN

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		71,95	96,15	90,00	100,0	95,83	83,33	96,03	86,36	97,62	97,92
Acurácia - amostras sem falha (%)		18,75	100,0	NA	NA	NA	71,43	100,0	NA	NA	NA
Acurácia - amostras com falha (%)		84,85	92,42	NA	NA	NA	90,91	92,42	NA	NA	NA
Identificação de falso positivo (%)		81,25	0,00	NA	NA	NA	28,57	0,00	NA	NA	NA
Identificação de falso negativo (%)		6,06	7,58	NA	NA	NA	0,00	7,58	NA	NA	NA
Classificação incorreta da falha (%)	Estator	1,52	NA	0,00	0,00	NA	0,00	NA	4,55	0,00	NA
	Rotor	3,03		0,00	0,00	0,00	0,00		4,55	2,38	2,08
	Rolamento	4,55		10,00	0,00	4,17	9,09		4,55	0,00	0,00

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

Iniciando-se a análise da Tabela 43 pelas colunas 5 e 10, constata-se que não foi possível estabelecer um conjunto de dados que permitisse uma diferenciação significativa entre as falhas de rotor e rolamento, pois a acurácia máxima obtida para essa situação foi de 62,5%.

Desta forma, para as classificações em que essa separação é necessária (colunas 1, 3, 6 e 8) os índices de acerto foram inferiores a 80%. Porém, quando não houve a necessidade de realizar esta separação, os índices de acerto foram superiores a 95%.

Os dados apresentados na Tabela 44, apontam que os menores índices de acerto foram 71,95% e 83,33%, respectivamente, e estão relacionados à multiclassificação de todas as falhas em um único classificador (colunas 1 e 6), com maior índice apresentado para falsos positivos. Entretanto, quando não há a necessidade de um classificador com 4 saídas distintas, o índice de acerto é superior a 90% para as tensões equilibradas, e 86% para as tensões desequilibradas. Assim, para esse tipo de classificador, o uso de múltiplos classificadores para a identificação das falhas de estator, rotor e rolamento é considerado importante para contribuir com um melhor resultado.

A subseção a seguir apresenta os resultados de identificação de falha, utilizando como algoritmo de otimização o *Simulated Annealing*.

### 5.3.4 IDENTIFICAÇÃO DE FALHAS UTILIZANDO OS PARÂMETROS ESTIMADOS COM SA

O último algoritmo de otimização a ser analisado é o SA. O *Simulated Annealing* é baseado na técnica do recozimento de metais, na busca da produção de cristais perfeitos, e é aplicado a problemas de otimização global (KIRKPATRICK et al., 1983). Esse método consiste em um algoritmo de otimização que não pertence ao grupo dos algoritmos evolutivos ou bio-inspirados, representando uma terceira classe de AOs.

Assim como o DE e o PSO, o SA foi utilizado para a estimação de parâmetros

dos MITs para, junto às correntes de pico do estator, fornecer informações suficientes, que possibilitem a identificação de falhas em motores de indução, por diferentes classificadores de padrões. Os resultados desta seção estão separados por classificadores e serão apresentados na seguinte ordem, RNA, SVM e k-NN.

#### 5.3.4.1 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO RNA

O primeiro classificador utilizado para a identificação de falhas foi a RNA. Assim como para o uso dos demais AOs, foram fornecidas à rede informações referentes a ensaios com alimentação equilibrada e desequilibrada, além de variação de conjugado. As Tabelas 45 e 46 apresentam o resultado para a classificação das falhas individuais.

**Tabela 45:** Classificação de falhas individuais do Motor 1 utilizando SA/RNA

MIT 1 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	97,06	82,76	95,83	95,00	84,62	76,39
Acurácia - amostras sem falha (%)	100,0	78,57	100,0	93,75	66,67	68,75
Acurácia - amostras com falha (%)	94,44	86,67	91,67	95,83	90,00	82,50
Identificação de falso positivo (%)	0,00	21,43	0,00	6,25	33,33	31,25
Identificação de falso negativo (%)	5,56	13,33	8,33	4,17	10,00	17,50

**Tabela 46:** Classificação de falhas individuais do Motor 2 utilizando SA/RNA

MIT 2 CV Classificação	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	80,00	90,00	90,00	77,78	81,25
Acurácia - amostras sem falha (%)	100,0	100,0	100,0	83,33	66,67	91,67
Acurácia - amostras com falha (%)	100,0	66,67	83,33	94,44	100,0	70,83
Identificação de falso positivo (%)	0,00	0,00	0,00	16,67	33,33	8,33
Identificação de falso negativo (%)	0,00	33,33	16,67	5,56	0,00	29,17

Analisando os aspectos gerais de ambas as tabelas, observa-se que a falha detectada com mais exatidão foi a falha de estator. Já o índice de detecção da falha de rotor foi o menor dentre os três, tanto para as tensões equilibradas, quanto para as tensões desequilibradas.

Tratando-se das tensões equilibradas, pode-se observar que o Motor 1 apresentou uma taxa de 97,06% de acerto para a falha de estator, enquanto que o Motor 2 apresentou uma acurácia de 100%. Já para a falha de rotor, observa-se que a taxa de acerto para o MIT de 1 CV foi 2,76% maior do que para o MIT de 2 CV, que classificou 80% das falhas corretamente. Ainda, para os defeitos de rolamento, o Motor 1 apresentou uma taxa de acerto de 95,83%, enquanto que o Motor 2 apresentou uma taxa de 90%.

Quando considerado o desequilíbrio de tensão, nota-se que a falha de estator mantém o maior índice de acerto, com 95% para o Motor 1 e 90% para o Motor 2. Já

os defeitos de rotor e rolamento apresentaram uma acurácia máxima de 84,62%, acompanhada de até 33% de amostras identificadas como falso positivo e até 29,17% de amostras identificadas como falso negativo.

As Tabelas 47 e 48 apresentam os resultados referentes a multiclassificação aplicada aos motores 1 e 2.

**Tabela 47:** Multiclassificação de falhas do Motor 1 utilizando SA/RNA

MIT 1 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		77,03	81,44	77,59	100,0	70,00	71,88	82,00	76,32	97,72	70,00
Acurácia - amostras sem falha (%)		93,75	85,42	NA	NA	NA	55,56	89,96	NA	NA	NA
Acurácia - amostras com falha (%)		72,41	77,55	NA	NA	NA	78,26	74,04	NA	NA	NA
Identificação de falso positivo (%)		6,25	14,58	NA	NA	NA	44,44	10,04	NA	NA	NA
Identificação de falso negativo (%)		8,62	12,45	NA	NA	NA	8,70	25,96	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	15,79	1,14	NA
	Rotor	15,53		14,66	0,00	22,50	0,00		2,63	10,00	
	Rolamento	3,45		7,76	0,00	27,27	8,70		5,26	1,14	20,00

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
 FNF - Falha e não falha - Sem falha (0) Com falha(1)  
 E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
 E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
 R|R - Rotor(0), Rolamento (1)

**Tabela 48:** Multiclassificação de falhas do Motor 2 utilizando SA/RNA

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		80,00	89,23	74,24	100,0	70,83	68,18	81,75	84,61	100,0	66,67
Acurácia - amostras sem falha (%)		71,43	98,44	NA	NA	NA	60,00	91,67	NA	NA	NA
Acurácia - amostras com falha (%)		84,62	80,30	NA	NA	NA	85,71	72,73	NA	NA	NA
Identificação de falso positivo (%)		28,57	1,56	NA	NA	NA	40,00	8,33	NA	NA	NA
Identificação de falso negativo (%)		0,00	19,70	NA	NA	NA	0,00	27,27	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	0,00	NA	0,00	NA	0,00	0,00	NA
	Rotor	15,38		50,00	0,00	18,75	7,14		0,00	25,00	
	Rolamento	0,00		20,83	0,00	10,42	7,14		15,38	0,00	8,33

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
 FNF - Falha e não falha - Sem falha (0) Com falha(1)  
 E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
 E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
 R|R - Rotor(0), Rolamento (1)

Iniciando a análise dos resultados pela identificação das falhas de rotor e rolamento (colunas 5 e 10), observa-se uma acurácia entre 66,67% e 70,0% para ambos os motores. Por esse motivo, é possível observar que as classificações, cuja separação das falhas de rotor e rolamento é necessária, apresentaram uma taxa máxima de 84,61%.

Ainda, quando observada a classificação para presença de falha (FNF), nota-se uma taxa de acerto máxima de 89,23%, que deve-se ao fato de que o classificador não consegue separar os dados sem falha e com defeitos de rotor e rolamento, devido à sua proximidade, conforme apresentado na Figura 39.

Assim, pode-se considerar que a acurácia para esse caso de estudo tem dois fatores que impactam significativamente no resultado final: a presença das amostras sem falha e a separação das falhas de rotor e rolamento. Quando isso não é necessário, como é o caso da separação da falha de estator com rotor ou rolamento (E|RR), o índice de acerto é superior a 97%, mostrando que a separação desses conjuntos é bem definida.



### 5.3.4.2 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO SVM

O segundo classificador utilizado para identificar as falhas, por meio das informações dos parâmetros estimados pelo SA, é o SVM. As Tabelas 49 e 50 apresentam os resultados das falhas de estator, rotor e rolamento, tratadas individualmente.

**Tabela 49:** Classificação de falhas individuais do Motor 1 utilizando SA/SVM

MIT 1 CV	Tensões Equilibradas			Desequilíbrio de até 2%		
Classificação	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	97,06	84,72	79,17	95,00	68,18	69,44
Acurácia - amostras sem falha (%)	100,0	100,0	58,33	100,0	36,36	53,13
Acurácia - amostras com falha (%)	94,44	72,50	100,0	91,67	100,0	82,50
Identificação de falso positivo (%)	0,00	0,00	41,67	0,00	63,64	46,88
Identificação de falso negativo (%)	5,56	27,50	0,00	8,33	0,00	17,50

**Tabela 50:** Classificação de falhas individuais do Motor 2 utilizando SA/SVM

MIT 2 CV	Tensões Equilibradas			Desequilíbrio de até 2%		
Classificação	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	78,57	75,00	80,00	46,81	50,00
Acurácia - amostras sem falha (%)	100,0	100,0	100,0	75,00	39,13	62,50
Acurácia - amostras com falha (%)	100,0	62,50	60,00	83,33	54,17	37,50
Identificação de falso positivo (%)	0,00	0,00	0,00	25,00	60,87	37,50
Identificação de falso negativo (%)	0,00	37,50	40,00	16,67	45,83	62,50

Analisando-se o comportamento do classificador para ambos os motores, nota-se que as maiores taxas de acerto foram 97,06% e 100% para os Motores 1 e 2, respectivamente, quando analisados os defeitos de estator, com tensões equilibradas. O mesmo ocorre dentre os resultados das tensões desequilibradas, onde as taxas de acerto foram 80% para o MIT de 2 CV e 95% para o MIT de 1 CV.

Por outro lado, as falhas de rotor e rolamento apresentaram resultados inferiores a 85%, considerando tensões equilibradas, e 70%, considerando alimentação desequilibrada.

As Tabelas 51 e 52 apresentam os resultados para a multiclassificação de ambos os motores.

**Tabela 51:** Multiclassificação de falhas do Motor 1 utilizando SA/SVM

MIT 1 CV	Tensões Equilibradas					Tensões Desequilibradas				
Classificação	MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)	62,50	78,57	68,10	98,08	62,80	61,25	73,50	65,91	93,18	62,50
Acurácia - amostras sem falha (%)	34,38	80,00	NA	NA	NA	40,63	90,63	NA	NA	NA
Acurácia - amostras com falha (%)	69,53	77,14	NA	NA	NA	74,22	57,69	NA	NA	NA
Identificação de falso positivo (%)	65,63	20,00	NA	NA	NA	59,38	9,38	NA	NA	NA
Identificação de falso negativo (%)	4,69	22,86	NA	NA	NA	9,38	42,31	NA	NA	NA
Classificação incorreta da falha (%)	Estator	5,47	1,72	1,92	NA	6,25	NA	18,18	1,70	NA
	Rotor	3,91	NA	22,41	0,00	2,34	NA	15,91	5,11	31,25
	Rolamento	16,41	NA	7,76	0,00	37,50	15,63	0,00	0,00	6,25

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
 FNF - Falha e não falha - Sem falha (0) Com falha(1)  
 E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
 E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
 R|R - Rotor(0), Rolamento (1)

**Tabela 52:** Multiclassificação de falhas do Motor 2 utilizando SA/SVM

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		59,26	75,00	74,24	97,62	64,58	50,00	53,17	68,18	100,0	66,67
Acurácia - amostras sem falha (%)		11,11	100,00	NA	NA	NA	21,43	66,67	NA	NA	NA
Acurácia - amostras com falha (%)		76,19	45,83	NA	NA	NA	78,57	40,91	NA	NA	NA
Identificação de falso positivo (%)		88,89	0,00	NA	NA	NA	78,57	33,33	NA	NA	NA
Identificação de falso negativo (%)		0,00	54,17	NA	NA	NA	0,00	59,09	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	0,00	2,78	NA	0,00	NA	4,55	0,00	NA
	Rotor	0,00		19,70	2,08	8,33	0,00		4,55	33,33	
	Rolamento	16,67		6,06	27,08	21,43	22,73		0,00	0,00	

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
 FNF - Falha e não falha - Sem falha (0) Com falha(1)  
 E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
 E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
 R|R - Rotor(0), Rolamento (1)

A partir dos resultados apresentados nas Tabelas 51 e 52, observam-se dois aspectos: há um baixo índice na separação das falhas de rotor e rolamento, com uma acurácia máxima de 66,67%. Esses aspectos refletem nas demais classificações, exceto quando não há a necessidade de separar essas falhas, e nem a presença de amostras saudáveis (resultados das colunas 4 e 9).

### 5.3.4.3 CLASSIFICAÇÃO DAS FALHAS UTILIZANDO K-NN

O último classificador a ser analisado é o k-NN. Inicialmente são apresentados nas Tabelas 53 e 54 os resultados para as falhas de estator, rotor e rolamento identificadas separadamente.

**Tabela 53:** Classificação de falhas individuais do Motor 1 utilizando SA/k-NN

MIT 1 CV	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	97,06	81,94	98,61	92,50	80,56	87,50
Acurácia - amostras sem falha (%)	100,0	93,75	100,0	93,75	93,75	93,75
Acurácia - amostras com falha (%)	94,44	72,50	97,50	91,67	70,00	82,50
Identificação de falso positivo (%)	0,00	6,25	0,00	6,25	6,25	6,25
Identificação de falso negativo (%)	5,56	27,50	2,50	8,33	30,00	17,50

**Tabela 54:** Classificação de falhas individuais do Motor 2 utilizando SA/k-NN

MIT 2 CV	Tensões Equilibradas			Desequilíbrio de até 2%		
	Estator	Rotor	Rolamento	Estator	Rotor	Rolamento
Acurácia - total (%)	100,0	75,00	71,43	83,33	87,23	77,08
Acurácia - amostras sem falha (%)	100,0	62,50	66,67	83,33	95,65	91,67
Acurácia - amostras com falha (%)	100,0	83,33	75,0	83,33	79,17	62,50
Identificação de falso positivo (%)	0,00	37,50	33,33	16,67	4,35	8,33
Identificação de falso negativo (%)	0,00	16,67	25,00	16,67	20,83	37,50

Considerando uma análise geral de ambos os motores, é possível observar que a falha de estator apresentou a acurácia mínima de 97,06%, para tensões equilibradas. Já para o desequilíbrio de tensão, aplicado ao Motor 2, observa-se a queda de 16,67% na taxa de acerto para o mesmo tipo de anomalia. Esse fato dá-se devido as falhas incipientes de 3% que são confundidas com amostras sem falha e vice-versa.

Analisando as demais falhas, observa-se que a falha de rolamento apresentou o maior índice de acerto, com 98,61% para o Motor 1. Já os defeitos de rotor apresentaram a média de 23,75% de falsos negativo, considerando ambos os motores. As Tabelas 55 e 56 apresentam o resultado de diferentes classificações, aplicadas com o banco de dados incluindo todas as falhas.

**Tabela 55:** Multiclassificação de falhas do Motor 1 utilizando SA/k-NN

MIT 1 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		61,49	94,33	64,66	100,0	60,00	68,75	92,00	67,97	98,33	60,00
Acurácia - amostras sem falha (%)		87,50	100,0	NA	NA	NA	100,0	100,0	NA	NA	NA
Acurácia - amostras com falha (%)		54,31	88,78	NA	NA	NA	60,94	84,62	NA	NA	NA
Identificação de falso positivo (%)		12,50	0,00	NA	NA	NA	0,00	0,00	NA	NA	NA
Identificação de falso negativo (%)		8,62	11,22	NA	NA	NA	11,72	15,38	NA	NA	NA
Classificação incorreta da falha (%)	Estator	0,00	NA	3,45	0,00	NA	0,00	NA	13,28	1,67	NA
	Rotor	18,97		23,28	0,00	20,00	14,84		3,13	7,50	
	Rolamento	18,10		8,62	0,00	20,00	12,50		15,63	0,00	32,50

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

**Tabela 56:** Multiclassificação de falhas do Motor 2 utilizando SA/k-NN

MIT 2 CV		Tensões Equilibradas					Tensões Desequilibradas				
Classificação		MC	FNF	E R R	E RR	R R	MC	FNF	E R R	E RR	R R
Acurácia - total (%)		57,32	90,77	77,27	96,43	66,67	68,18	95,24	59,09	95,24	70,83
Acurácia - amostras sem falha (%)		25,00	100,0	NA	NA	NA	75,00	100,0	NA	NA	NA
Acurácia - amostras com falha (%)		65,15	81,82	NA	NA	NA	64,29	90,91	NA	NA	NA
Identificação de falso positivo (%)		75,00	0,00	NA	NA	NA	25,00	0,00	NA	NA	NA
Identificação de falso negativo (%)		10,61	18,18	NA	NA	NA	7,14	9,09	NA	NA	NA
Classificação incorreta da falha (%)	Estator	4,55	NA	0,00	0,00	NA	7,14	NA	4,55	0,00	NA
	Rotor	13,64		13,64	3,57	8,33	7,14		0,00	22,92	
	Rolamento	6,06		9,09	0,00	25,00	14,29		18,18	4,76	6,25

MC - Multiclassificação - Sem falha (0) Estator (1), Rotor(2) e Rolamento(3)  
FNF - Falha e não falha - Sem falha (0) Com falha(1)  
E|R|R - Estator (0), Rotor(1) e Rolamento(2)  
E|RR - Estator (0), Rotor(1) ou Rolamento(1)  
R|R - Rotor(0), Rolamento (1)

A partir da análise dos resultados apresentados para ambos os motores, nota-se que a acurácia máxima para as colunas 5 e 10 (R|R) foi de 70,83%, impactando diretamente nas classificações com a necessidade da separação das falhas de rotor e rolamento. Quando estas falhas devem ser separadas, os resultados obtidos foram inferiores a 78%.

Por outro lado, quando não há a separação destas (colunas FNF e E|RR), foi possível obter taxas de acerto entre 90,77% e 100%. Assim, pode-se constatar que o uso do k-NN com o SA para a identificação de múltiplas falhas é satisfatório quando as falhas de rotor e rolamento não são separadas.

A seção a seguir apresenta o resumo dos resultados, considerando todos os algoritmos de otimização e classificadores utilizados.

#### 5.3.4.4 RESUMO DOS RESULTADOS

Esta seção apresenta o desempenho da metodologia proposta para o diagnóstico de falhas em estator, rotor e rolamento, em dois motores de indução trifásicos, acionados

diretamente da rede, com desequilíbrio de tensão de até 2%.

Foram testadas 9 combinações distintas, entre algoritmos de otimização e classificadores de padrões, conforme pode ser observado na Figura 21. Os algoritmos utilizados foram DE, PSO e SA e, para cada um desses, os parâmetros estimados, junto ao valor de pico das correntes de estator, foram apresentados a três classificadores distintos: RNA, SVM e k-NN.

A classificação da falha ocorreu inicialmente de forma individual, seguida por três multiclassificações distintas, conforme apresentado na Figura 20. Desta forma, nesta seção são apresentados os resultados por classificação para todas as combinações AO/Classificador, a fim de identificar qual conjunto apresentou melhor desempenho, de acordo com o tipo de falha. A Tabela 57 apresenta a acurácia total de cada combinação para a falha de estator.

**Tabela 57:** Acurácia das falhas de estator, considerando o conjunto AO/ Classificador

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
DE/RNA	100,0%	97,50%	100,0%	100,0%
DE/SVM	100,0%	96,25%	100,0%	100,0%
DE/k-NN	100,0%	90,00%	100,0%	86,67%
PSO/RNA	100,0%	95,00%	100,0%	100,0%
PSO/SVM	97,06%	95,00%	97,06%	97,06%
PSO/k-NN	91,67%	90,00%	100,0%	93,33%
SA/RNA	97,06%	95,00%	100,0%	90,00%
SA/SVM	97,06%	95,00%	100,0%	80,00%
SA/k-NN	97,06%	92,50%	100,0%	83,33%

A partir dos resultados apresentados, é possível observar que o melhor conjunto para a falha de estator foi DE/RNA, onde a acurácia mínima para essa combinação foi 97,50% atribuída ao Motor 1, com desequilíbrio de tensão. Por outro lado, o conjunto que apresentou os piores resultados foi SA/SVM, onde a acurácia mínima foi de 80,00%. A Tabela 58 apresenta o resumo dos resultados obtidos para a falha de rotor.

**Tabela 58:** Acurácia das falhas de rotor, considerando o conjunto AO/ Classificador

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
DE/RNA	100,0%	95,45%	91,67%	91,67%
DE/SVM	100,0%	88,89%	89,58%	91,67%
DE/k-NN	100,0%	88,89%	89,58%	90,91%
PSO/RNA	97,22%	88,89%	85,71%	87,50%
PSO/SVM	76,00%	62,50%	85,71%	81,25%
PSO/k-NN	93,06%	86,11%	82,50%	91,67%
SA/RNA	82,76%	84,62%	80,00%	77,78%
SA/SVM	84,72%	68,18%	78,57%	46,81%
SA/k-NN	81,94%	80,56%	75,00%	87,23%

Por meio dos dados apresentados na Tabela 58, observa-se que o melhor conjunto para a classificação desse tipo de falha foi DE/RNA, onde a taxa de acerto máxima para o

Motor 1 foi de 100% e para o Motor 2, manteve-se em 91,67%. Já a combinação SA/SVM, apresentou resultados inferiores a 85% em todos os casos, com uma acurácia mínima de 46,81% para o Motor 2, com tensões desequilibradas. A Tabela 59 apresenta as taxas de acerto para a identificação da falha de rolamento.

**Tabela 59:** Acurácia das falhas de rolamento, considerando o conjunto AO/ Classificador

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
DE/RNA	100,0%	98,61%	97,50%	100,0%
DE/SVM	100,0%	83,33%	97,50%	100,0%
DE/k-NN	100,0%	94,44%	95,00%	97,22%
PSO/RNA	98,61%	97,22%	100,0%	100,0%
PSO/SVM	79,17%	72,22%	95,00%	91,67%
PSO/k-NN	97,22%	94,44%	92,86%	100,0%
SA/RNA	95,83%	76,39%	90,00%	81,25%
SA/SVM	79,17%	69,44%	75,00%	50,00%
SA/k-NN	98,61%	87,50%	71,43%	77,08%

Analisando-se os dados apresentados na Tabela 59, observa-se que o melhor conjunto para a identificação desse tipo de falha é o DE/RNA, com uma taxa de acerto que variou entre 97,50% e 100,0%. Por outro lado, a combinação que apresentou os menores índices de acerto foi SA/SVM, onde a acurácia mínima foi de 50,00% para o Motor 2, com tensões desequilibradas, e a taxa de acerto máxima foi de 79,17%, atribuída ao Motor 1, com tensões equilibradas. A Tabela 60 apresenta os resultados para a Multiclassificação 1, conforme Figura 20, onde são considerados em um mesmo banco de dados as falhas de estator, rotor e rolamento, bem como as amostras sem falha.

**Tabela 60:** Acurácia da Multiclassificação 1 (MC), considerando o conjunto AO/ Classificador

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
DE/RNA	96,80%	80,00%	96,55%	94,74%
DE/SVM	83,33%	66,67%	86,73%	81,63%
DE/k-NN	90,63%	78,13%	85,71%	93,88%
PSO/RNA	66,67%	72,50%	86,59%	83,87%
PSO/SVM	56,08%	53,13%	70,73%	62,22%
PSO/k-NN	64,18%	73,13%	71,95%	83,33%
SA/RNA	77,03%	71,88%	80,00%	68,18%
SA/SVM	62,50%	61,25%	59,26%	50,00%
SA/k-NN	61,49%	68,75%	57,32%	68,18%

De acordo com os resultados apresentados na Tabela 60, o conjunto DE/RNA apresentou os melhores resultados para a Multiclassificação 1, com uma taxa de acerto aproximada de 96% para ambos os motores estudados.

Com relação aos resultados de menores taxas de acerto, é possível observar que, para o Motor 1, as piores acurácias ocorreram para a combinação PSO/SVM, com 56,08% de acerto para tensões equilibradas, e 53,13% para tensões desequilibradas. Já para o Motor 2, a combinação SA/SVM apresentou os menores resultados, com 59,26% para tensões

equilibradas, e 50% para tensões desequilibradas. A Tabela 61 apresenta os resultados para a identificação de falha e não falha (FNF), utilizada como parte da classificação nas Multiclassificações 2 e 3.

**Tabela 61:** Acurácia da presença de falha (FNF), considerando o conjunto AO/ Classificador

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
DE/RNA	100,0%	97,04%	91,54%	91,08%
DE/SVM	67,35%	91,13%	82,54%	82,54%
DE/k-NN	100,0%	98,77%	97,73%	97,62%
PSO/RNA	93,82%	94,50%	92,31%	97,10%
PSO/SVM	86,11%	63,50%	65,63%	78,57%
PSO/k-NN	97,75%	95,50%	96,15%	96,03%
SA/RNA	81,44%	82,00%	89,23%	81,75%
SA/SVM	78,57%	73,50%	75,00%	53,17%
SA/k-NN	94,33%	92,00%	90,77%	95,24%

A partir da análise dos dados apresentados na Tabela 61, observa-se que a melhor combinação para essa classificação foi DE/k-NN, onde a menor taxa de acerto foi de 97,62%, obtida com o Motor 2 em tensões desequilibradas, e a melhor acurácia foi 100%, atribuída ao Motor 1 com tensões equilibradas. Em contrapartida, observa-se, em uma análise geral, que o pior conjunto para essa classificação foi o SA/SVM, onde as taxas de acerto variaram entre 53,17% e 78,57%. A Tabela 62 apresenta os resultados para a classificação das falhas de estator, rotor e rolamento, desconsiderando as amostras sem falha, finalizando a classificação estabelecida para a Multiclassificação 2, apresentada em verde na Figura 20.

**Tabela 62:** Acurácia da classificação das falhas de estator, rotor e rolamento (E|R|R), considerando o conjunto AO/ Classificador

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
DE/RNA	90,28%	76,92%	96,97%	96,96%
DE/SVM	77,78%	72,73%	96,97%	93,75%
DE/k-NN	86,62%	70,31%	90,90%	93,75%
PSO/RNA	65,52%	69,23%	96,97%	98,48%
PSO/SVM	61,21%	67,97%	92,42%	87,88%
PSO/k-NN	60,34%	76,92%	90,00%	86,36%
SA/RNA	77,59%	76,32%	74,24%	84,61%
SA/SVM	68,10%	65,91%	74,24%	68,18%
SA/k-NN	64,66%	67,97%	77,27%	59,09%

A partir dos dados apresentados na Tabela 62, nota-se que os melhores resultados foram obtidos com o conjunto DE/RNA, com uma taxa aproximada de 97,00% para o Motor 2, e 90,28% para o Motor 1, com tensões equilibradas. Já o conjunto SA/k-NN apresentou, em geral, as menores acurácias quando analisado ambos os motores, com uma taxa de acerto máxima de 67,97% para o Motor 1, e uma acurácia mínima de 59,09% para o Motor 2.

A Tabela 63 apresenta as taxas de acerto obtidas para a classificação das falhas de estator ou rotor e rolamento, utilizada na Multiclassificação 3.

**Tabela 63:** Acurácia da classificação das falhas de estator ou rotor e rolamento (E|RR), considerando o conjunto AO/ Classificador

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
DE/RNA	100,0%	99,43%	100,0%	97,78%
DE/SVM	100,0%	99,43%	100,0%	81,82%
DE/k-NN	100,0%	99,43%	100,0%	92,22%
PSO/RNA	100,0%	100,0%	100,0%	100,0%
PSO/SVM	100,0%	99,43%	100,0%	86,90%
PSO/k-NN	100,0%	100,0%	100,0%	97,62%
SA/RNA	100,0%	97,72%	100,0%	100,0%
SA/SVM	98,08%	93,18%	97,62%	100,0%
SA/k-NN	100,0%	98,33%	96,43%	95,24%

Para esse tipo de classificação, observa-se que o conjunto PSO/RNA apresentou a taxa máxima para ambos os motores, com e sem desequilíbrio de tensão. Ainda, a pior acurácia obtida foi de 81,82% para o Motor 2, operando com tensões desequilibradas, no conjunto DE/SVM. É importante observar que, essa classificação apresenta a maior quantidade de taxas máximas de acertos dentre as multiclassificações realizadas até o momento, pois conforme mostrado na Figura 39, as falhas de estator ou rotor e rolamento possuem características distintas.

A Tabela 64 apresenta a última classificação da Multiclassificação 3, ou seja, a separação das falhas de rotor e rolamento.

**Tabela 64:** Acurácia da classificação das falhas de rotor e rolamento (R|R), considerando o conjunto AO/ Classificador

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
DE/RNA	92,85%	81,25%	97,92%	97,92%
DE/SVM	91,66%	62,50%	97,92%	97,92%
DE/k-NN	93,75%	56,25%	93,75%	95,84%
PSO/RNA	60,00%	56,25%	93,75%	97,92%
PSO/SVM	51,85%	51,25%	95,83%	95,83%
PSO/k-NN	60,00%	62,50%	95,83%	97,92%
SA/RNA	70,00%	70,00%	70,83%	66,67%
SA/SVM	62,80%	62,50%	64,58%	66,67%
SA/k-NN	60,00%	60,00%	66,67%	70,83%

Considerando os resultados apresentados na Tabela 64, o melhor conjunto para a identificação das falhas de rotor e rolamento é o DE/RNA, que apresentou uma acurácia de 97,92% para o Motor 2, e 92,85% para o Motor 1, com tensões equilibradas.


Já o conjunto PSO/SVM apresentou as piores taxas de acerto para o Motor 1, com cerca de 51,00% a 52,00%. Enquanto que para o Motor 2, a combinação que apresentou menores índices de acerto foi a SA/SVM, com 64,58% para o Motor 2, com tensões equilibradas, e 66,67%, para tensões desequilibradas.

Além da análise individual de cada falha para as combinações AO/Classificador é válido apresentar de forma resumida os melhores e os piores resultados, além do valor médio das classificações obtido por cada combinação AO/Classificador, a fim de verificar o comportamento de cada conjunto utilizado.

**Tabela 65:** Desempenho dos conjuntos AO/ Classificador

Acurácia	Motor 1			Motor 2			Geral		
	Máx(%)	Mín(%)	Média(%)	Máx(%)	Mín(%)	Média(%)	Máx(%)	Mín(%)	Média(%)
DE/RNA	100,0	90,28	97,00	100,0	76,92	93,44	100,0	76,92	<b>95,22</b>
DE/SVM	100,0	67,35	91,96	100,0	62,50	86,97	100,0	62,50	<b>89,46</b>
DE/k-NN	100,0	85,71	95,23	99,43	56,25	89,02	100,0	56,25	<b>92,12</b>
PSO/RNA	100,0	60,00	89,82	100,0	56,25	89,90	100,0	56,25	<b>89,86</b>
PSO/SVM	100,0	51,85	81,87	99,43	51,25	77,90	100,0	51,25	<b>79,88</b>
PSO/k-NN	100,0	60,00	86,63	100,0	62,50	89,05	100,0	60,00	<b>87,84</b>
SA/RNA	100,0	70,00	86,50	100,0	66,67	81,51	100,0	66,67	<b>84,00</b>
SA/SVM	100,0	59,26	78,45	100,0	46,81	68,99	100,0	46,81	<b>73,72</b>
SA/k-NN	100,0	57,32	80,81	98,33	59,09	80,24	100,0	57,32	<b>80,53</b>

A partir dos dados apresentados na Tabela 65, observa-se que o conjunto que apresentou menor variação na taxa de acerto e melhor média dentre todos os resultados foi o DE/RNA, com uma taxa de acerto média de 95,22%. Já a combinação SA/SVM apresentou a menor acurácia média, com 73,72% para os casos analisados neste trabalho. A Figura 40 apresenta o desempenho de cada combinação, de acordo com a taxa de acerto obtida para cada uma das classificações realizadas.



**Figura 40:** Classificação por tipo de combinação AO/Classificador

**Fonte:** Autoria própria

Assim, pode-se concluir que a melhor combinação a ser implementada é a utilização do DE como algoritmo de otimização e da RNA como classificador de padrões.



Pelos resultados obtidos, optou-se por desenvolver o sistema embarcado em um *hardware* dedicado, utilizando-se o DE e a RNA para a identificação de falhas de estator. Os resultados referentes à implementação da metodologia em *hardware* são apresentados na Seção 5.3.5, a seguir.

### 5.3.5 IMPLEMENTAÇÃO DA METODOLOGIA PROPOSTA EM *HARDWARE*

A utilização de um sistema embarcado permite o monitoramento *online* da falha, o que é uma grande vantagem, principalmente quando se trata da falha de estator, que possui rápido avanço em sua severidade.

O DSP é um *hardware* robusto e consolidado que permite aplicações em ambientes hostis, e por esse motivo, foi utilizado nesta Tese. O modelo escolhido foi o TMS320F28379D da *Texas Instruments* <sup>®</sup>.

Conforme tratado na metodologia, foram coletados sinais de tensão e corrente, e o módulo da velocidade foi inserido manualmente. Embora a DSP possua 16 canais de conversão A/D, no modelo utilizado somente 3 canais são adquiridos simultaneamente. Para a realização das demais aquisições há um pequeno atraso, que varia de acordo com suas configurações. Assim, seria possível a aquisição de apenas as correntes das fases A e B, pois o terceiro canal corresponde à tensão da fase A.

Assim, foi analisada a utilização apenas da corrente da fase A, por conter informações suficientes considerando o banco de dados já apresentados nessa Tese. Além disso, na busca de otimizar o sistema embarcado, foram realizados testes considerando a utilização apenas do parâmetro  $L_M$ , combinado à corrente  $I_A$ .

Dessa forma, o treinamento da RNA ocorreu no MATLAB contendo como entrada apenas o pico da corrente da fase A e o valor da indutância de magnetização, ambos normalizados. Os resultados dos testes obtidos no ambiente computacional foi de 100% para ambos os motores. Na sequência foi realizado o desenvolvimento do algoritmo para o sistema embarcado contendo a aquisição dos sinais, a extração das características de 3 períodos do conjunto adquirido, e a estimação de parâmetros para o vetor de referência com o DE. A RNA foi desenvolvida para 2 entradas, 10 neurônios na camada intermediária e 1 neurônio na camada de saída. Além disso, foi utilizada a função de ativação tangente hiperbólica.

O processo de estimação de parâmetros para a obtenção do vetor de referência foi similar ao implementado computacionalmente. Entretanto, por tratar-se de um *hardware*

com capacidade de processamento inferior ao computador utilizado, buscou-se verificar a possibilidade de reduzir o número de médias realizadas, mas mantendo-se a mesma qualidade computacional. Foram feitas então 10 estimações, apresentadas nas Tabelas 66 e 67.

**Tabela 66:** Valores de referência para o MIT de 1 CV, utilizando o DE embarcado na DSP

Estimação	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO_{vazio}$	$FO_{nominal}$	$FO_{total}$
1	12,2334	0,0275	5,7486	0,0762	0,4317	0,0333	0,0123	0,0456
2	12,0569	0,0452	4,7547	0,0222	0,4186	0,0326	0,0107	0,0433
3	12,4793	0,0665	4,5815	0,0233	0,4148	0,0316	0,0109	0,0425
4	12,7030	0,0384	5,0474	0,0408	0,4581	0,0325	0,0134	0,0459
5	12,6520	0,0509	4,7800	0,0658	0,4150	0,0324	0,0121	0,0445
6	12,0473	0,0584	5,4944	0,0604	0,3991	0,0262	0,0236	0,0498
7	12,6445	0,0683	4,4095	0,0645	0,4167	0,0316	0,0119	0,0435
8	12,2086	0,0633	5,2975	0,0457	0,4226	0,0248	0,0233	0,0481
9	12,6151	0,0799	4,0806	0,0392	0,4174	0,0402	0,0095	0,0497
10	12,6334	0,0784	4,8629	0,0479	0,4198	0,0316	0,0125	0,0442

**Tabela 67:** Valores de referência para o MIT de 2 CV, utilizando o DE embarcado na DSP

Estimação	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$	$FO_{vazio}$	$FO_{nominal}$	$FO_{total}$
1	8,3796	0,0242	2,0787	0,0512	0,2920	0,0939	0,0577	0,1516
2	8,9945	0,0435	1,8834	0,0179	0,2678	0,0939	0,0366	0,1305
3	9,0010	0,0100	2,3063	0,0689	0,3051	0,0939	0,0319	0,1633
4	7,0042	0,0177	2,4050	0,0526	0,2950	0,0753	0,0419	0,1172
5	7,0447	0,0395	2,0674	0,0183	0,2613	0,0783	0,0402	0,1185
6	7,8823	0,0348	1,9319	0,0486	0,2797	0,0939	0,0448	0,1386
7	7,0010	0,0500	1,8358	0,0174	0,2578	0,0759	0,3366	0,4125
8	7,1362	0,0171	2,4793	0,0590	0,2894	0,0761	0,1030	0,1791
9	8,9299	0,0336	1,9775	0,0392	0,2854	0,0943	0,0531	0,1474
10	7,4744	0,0424	2,0060	0,0142	0,2536	0,0813	0,0424	0,1238

A partir dos resultados apresentados para o Motor 1 pode-se observar que as maiores discrepâncias apresentadas com relação à Tabela 9 estão relacionadas com as indutâncias de dispersão e os valores mais próximos estão relacionados às resistências. Com relação à indutância de magnetização, é possível observar uma proximidade entre os valores apresentados de ambas as tabelas, com variação máxima de 10%. A Tabela 68 apresenta o vetor final utilizado na DSP como referência para a classificação da falha de estator.

**Tabela 68:** Vetores de referência para identificação da falha utilizando o DE embarcado na DSP

Parâmetros	$R_1(\Omega)$	$L_1(H)$	$R_2(\Omega)$	$L_2(H)$	$L_M(H)$
MIT 1	12,4273	0,0577	4,8629	0,0479	0,4199
MIT 2	7,8846	0,0313	2,0972	0,0387	0,2787

A partir da análise da Tabela 68 é possível verificar a proximidade dos parâmetros

estimados na DSP com os obtidos computacionalmente, conforme Tabela 10, principalmente quando se compara o valor da indutância de magnetização.

Após a estimação do vetor de referência iniciou-se o processo de classificação da falha. Como mencionado no início da seção, o treinamento da rede foi realizado no MATLAB e a matriz contendo os pesos sinápticos foi inserida no DSP. A mesma matriz foi utilizada na classificação dos padrões dos Motores 1 e 2.

Com relação à geração da matriz do classificador há uma consideração essencial a ser feita. Durante o processo de identificação da falha, apresentado na Seção 5.3, foi utilizada a ferramenta WEKA, que contém os três classificadores de padrões. Entretanto, ao se fazer a extração dos pesos sinápticos da matriz para a RNA houve inconsistência, pois esperava-se uma saída binária (0 ou 1) e foi apresentada uma matriz com duas saídas combinada. Assim, considerando-se que os algoritmos que compõem o *software* possuem especificações e otimizações não apresentadas ao usuário, não foi possível utilizar a matriz fornecida na DSP. Dessa forma, optou-se por desenvolver uma RNA no MATLAB, onde todos os procedimentos e etapas eram conhecidos.

A Tabela 69 apresenta os resultados para ambos os motores, considerando variação de conjugado e de tensão.

**Tabela 69:** Classificação da falha de estator utilizando a RNA embarcada na DSP

Tensões	Motor 1		Motor 2	
	Equilibradas	Desequilibradas	Equilibradas	Desequilibradas
Acurácia - total (%)	100,0	100,0	100,0	100,0
Acurácia - amostras sem falha (%)	100,0	100,0	100,0	100,0
Acurácia - amostras com falha (%)	100,0	100,0	100,0	100,0
Identificação de falso positivo (%)	0,00	0,00	0,00	0,00
Identificação de falso negativo (%)	0,00	0,00	0,00	0,00

Os resultados apresentados mostram a confiabilidade com relação à identificação *online* das falhas de estator. Ainda que os resultados apresentados para os parâmetros estimados com a DSP possam ter valores diferentes dos obtidos computacionalmente, o comportamento da implementação em ambos os meios (computacional e embarcado) foi o mesmo. Assim, uma das contribuições desta Tese consiste em apresentar a implementação do DE e da RNA embarcados em *hardware* de relativo baixo custo para a identificação de falhas em máquinas elétricas. A seguir são apresentadas as conclusões do capítulo.

### 5.3.6 CONCLUSÃO DO CAPÍTULO

Este capítulo apresentou os resultados referentes à metodologia proposta para esta Tese, que engloba a identificação de falhas de estator, rotor e rolamento em motores

de indução trifásicos.

A proposta desta Tese foi desenvolver um método de identificação de falhas em MITs, a partir da análise dos parâmetros do circuito elétrico equivalente da máquina, especialmente a variação da indutância de magnetização.

Para a estimação de parâmetros foram utilizados 3 algoritmos de otimização, a saber: DE, PSO e SA. Os erros obtidos pelos algoritmos foi de até 2% quando comparados as correntes fornecidas experimentalmente pelo MIT. Pode-se concluir que para estimação de parâmetros o DE e o PSO apresentaram desempenho similar com relação aos valores de cada parâmetro e ao erro obtido. No entanto, o DE apresentou 0,47% de erro na estimação do Motor 1, o menor valor. Por outro lado, o PSO apresentou uma estimação mais rápida em questão de número de iterações, que variou entre 2 e 60. Já o SA, embora tenha apresentado um erro de 0,48% para o Motor 1, não conseguiu convergir para um vetor dentro do erro esperado para o Motor 2, apresentando uma diferença de até 55% entre as curvas estimadas e experimentais, o que é visto como uma desvantagem para o método.

Em uma análise geral, os melhores resultados apresentados foram acima de 90% para todos os casos equilibrados e para a maior parte dos casos com desequilíbrio de tensão, exceto multiclassificação e separação das falhas de rotor e rolamento.

Por fim, quando analisado o sistema embarcado, foi realizada a implementação das metodologias que apresentaram melhores resultados para a falha com melhor classificação. Os resultados apresentados mostraram a viabilidade do monitoramento *online*, para a identificação de falhas de estator, com a aquisição de um sinal de tensão e corrente junto ao módulo da velocidade.

Assim, os resultados apresentados nesta Tese mostram-se eficientes para o monitoramento *offline* e *online*, sendo capaz de diagnosticar falhas individuais e múltiplas falhas. Ainda, a metodologia proposta pode ser aplicada a motores sob diversas condições de conjugado de carga, mas com limitado desequilíbrio de tensão.

O Capítulo 6 apresenta as conclusões desta Tese e as perspectivas para trabalhos futuros.

## 6 CONCLUSÃO

Este trabalho apresenta uma metodologia alternativa para o diagnóstico de falhas de curto-circuito nas espiras de estator, desgaste de rolamento e barras quebradas de rotor de MITs com alimentação senoidal, tendo como base o uso dos algoritmos de otimização DE, PSO e SA e dos classificadores de padrões RNA, SVM e k-NN. Para maior abrangência da proposta, foram aplicados diferentes níveis de falhas e diversos valores de conjugado de carga, além de um desequilíbrio de tensão de até 2%.

A primeira etapa apresentou a estimativa dos parâmetros do MIT por meio de AOs, onde se utilizou o modelo clássico do motor em regime permanente. Os referidos parâmetros serviram de entrada aos classificadores de padrões, os quais foram responsáveis por fazer a classificação do estado de operação da máquina. A estimação dos parâmetros foi realizada em dois instantes de cargas diferentes, ou seja, trabalhando-se em regime permanente de operação a vazio e de conjugado de carga nominal. Dentre as análises realizadas, observou-se que o DE apresentou erros menores relacionados à FO.

Após a estimação dos parâmetros reais da máquina para a criação de um vetor de referência, foi realizado um conjunto de 7 combinações de estimações diferentes. A melhor combinação para uma identificação geral e específica das falhas foi obtida por meio da variação da indutância de magnetização.

Entretanto, como foi observada certa semelhança entre as falhas de 3% de curto-circuito de estator com o motor operando sem falhas, optou-se por adicionar o valor de pico da corrente junto aos dados estimados para que ambos servissem de entrada aos classificadores.

Para a classificação de padrões, foram utilizados três classificadores distintos, com o objetivo de verificar qual apresentaria o melhor desempenho na identificação de falhas, de acordo com a metodologia proposta. De forma geral, foi possível observar que o melhor classificador aplicado foi a RNA, seguido do k-NN e SVM, respectivamente. Uma grande vantagem da metodologia proposta é quantidade de dados que devem ser fornecidos por

amostra para a classificação de falhas. Os classificadores trabalharam com 8 pontos de entrada, sendo 5 parâmetros do circuito elétrico equivalente e 3 picos de corrente.

Outra aspecto da metodologia proposta foi a implementação em um sistema embarcado em DSP, possibilitando o monitoramento *online* da falha de estator.

Assim, a metodologia apresentada nesta Tese mostrou-se viável na identificação de falhas, tanto individuais quanto em multiclassificação, sendo o melhor conjunto encontrado o uso do DE junto à RNA. A seguir são apresentadas as perspectivas de trabalhos futuros.

## 6.1 TRABALHOS FUTUROS

Considerando os resultados promissores apresentados nessa Tese e a possibilidade de investigação de outras vertentes, sugere-se como trabalhos futuros:

- Embarcar a metodologia proposta para as demais falhas individuais e multiclassificação de falhas em um DSP;
- Aplicar o sistema proposto com acionamento por inversor de frequência;

## 6.2 PRODUÇÃO CIENTÍFICA

Durante o desenvolvimento do trabalho de doutorado foram realizadas publicações relacionadas à pesquisa desenvolvida, conforme apresentado a seguir:

- Trabalhos correlatos - Autor principal
  - GUEDES, J. J.; CASTOLDI, M. F.; GOEDTEL, A.; AGULHARI, C. M.; SANCHES, D. S. Differential evolution applied to line-connected induction motors stator fault identification. **Soft Computing**, 2018. DOI: 10.1007/s00500-018-3674-z.
  - GUEDES, J. J.; CASTOLDI, M. F.; GOEDTEL, A.; AGULHARI, C. M.; SANCHES, D. S. Parameters estimation of three-phase induction motors using differential evolution. **Electric Power Systems Research**, 2017. DOI: 10.1016/j.epsr.2017.08.033.
- Participação em trabalhos como colaborador

- SANTOS, H. O.; BERNARDES, I. O.; BUZANELLI, J. H.; GUEDES, J. J.; CASTOLDI, M. F.; GOEDTEL, A. Estimador de velocidade de um motor de indução trifásico utilizando Filtro de Kalman Estendido otimizado por algoritmo de enxame de vagalumes. **Congresso Brasileiro de Automática (CBA)**, 2018, João Pessoa - Brasil.
- BOSCO, M. C.; GUEDES, J. J.; CASTOLDI, M. F.; GOEDTEL, A.; SILVA, E. R. P.; BUZACHERO, L. F. S. Estimation of parameters and tuning of a speed PI of permanent magnet DC motor using differential evolution. **2017 IEEE International Electric Machines and Drives Conference (IEMDC)**, 2017, Miami - EUA. DOI: 10.1109/iemdc.2017.8002318.

## REFERÊNCIAS

- ABDALLAH, H.; BENATMAN, K. Stator winding inter-turn short-circuit detection in induction motors by parameter identification. **IET Electric Power Applications**, IET, v. 11, n. 2, p. 272–288, 2017.
- AHAMED, S. K. et al. 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.
- AKBABA, M.; FAKHRO, S. New model for single-unit representation of induction motor loads, including skin effect, for power system transient stability studies. In: IET. **IEE Proceedings B (Electric Power Applications)**. [S.l.], 1992. v. 139, n. 6, p. 521–533.
- ALEXANDER, C. K.; SADIKU, M. N. **Fundamentos de circuitos elétricos**. [S.l.]: AMGH Editora, 2013.
- ALPAYDIN, E. **Introduction to machine learning**. [S.l.]: MIT press, 2009.
- ALTHOBIANI, F.; BALL, A.; CHOI, B.-K. 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.
- AMEZQUITA-SANCHEZ, J. et al. Fractal dimension and fuzzy logic systems for broken rotor bar detection in induction motors at start-up and steady-state regimes. **Measurement Science and Technology**, v. 28, n. 7, 2017.
- ANTONINO-DAVIU, J. et al. Scale invariant feature extraction algorithm for the automatic diagnosis of rotor asymmetries in induction motors. **IEEE Transactions on Industrial Informatics**, v. 9, n. 1, p. 100–108, Feb 2013.
- ARAUJO, B. et al. Synchronous machine parameters evaluation with a hybrid particle swarm optimization algorithm. **Electric Power Components and Systems**, v. 45, n. 17, p. 1962–1971, 2017.
- 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. et al. Stator short-circuit diagnosis in induction motors using mutual information and intelligent systems. **IEEE Transactions on Industrial Electronics**, v. 66, n. 4, p. 3237–3246, 2019.



- Bednarz, S. A.; Dybkowski, M. On-line detection of the rotor faults in the induction motor drive using parameter estimator. In: **2018 International Symposium on Electrical Machines (SME)**. [S.l.: s.n.], 2018. p. 1–5.
- BELLINI, A. et al. Advances in diagnostic techniques for induction machines. **IEEE Transactions on Industrial Electronics**, v. 55, n. 12, p. 4109–4126, 2008.
- BERGMAN, S. **The kernel function and conformal mapping**. [S.l.]: American Mathematical Soc., 1970.
- BERZOY, A.; MOHAMED, A. A.; MOHAMMED, O. Complex-vector model of interturn failure in induction machines for fault detection and identification. **IEEE Transactions on Industry Applications**, IEEE, v. 53, n. 3, p. 2667–2678, 2017.
- BESSAM, B. et al. Detection of broken rotor bar faults in induction motor at low load using neural network. **ISA Transactions**, v. 64, p. 241 – 246, 2016.
- BHOWMICK, D.; MANNA, M.; CHOWDHURY, S. K. Online estimation and analysis of equivalent circuit parameters of three phase induction motor using particle swarm optimization. In: IEEE. **2016 IEEE 7th Power India International Conference (PIICON)**. [S.l.], 2016. p. 1–5.
- BISHOP, C. M. **Pattern recognition and machine learning**. [S.l.]: springer, 2006.
- BRATTON, D.; KENNEDY, J. Defining a standard for particle swarm optimization. In: IEEE. **2007 IEEE swarm intelligence symposium**. [S.l.], 2007. p. 120–127.
- BRITO, J. N. et al. **Desenvolvimento de um sistema inteligente híbrido para diagnóstico de falhas em motores de indução trifásicos**. Tese (Doutorado) — Campinas, SP, 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.
- CAMARENA-MARTINEZ, D. et al. Empirical mode decomposition and neural networks on fpga for fault diagnosis in induction motors. **The Scientific World Journal**, v. 2014, 2014.
- ÇANAKOĞLU, A. İ. et al. Induction motor parameter estimation using metaheuristic methods. **Turkish Journal of Electrical Engineering & Computer Sciences**, The Scientific and Technological Research Council of Turkey, v. 22, n. 5, p. 1177–1192, 2014.
- CAPOLINO, G.-A.; ANTONINO-DAVIU, J.; RIERA-GUASP, M. Modern diagnostics techniques for electrical machines, power electronics, and drives. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1738–1745, 2015.
- ČERNÝ, V. Thermodynamical approach to the traveling salesman problem: An efficient simulation algorithm. **Journal of optimization theory and applications**, Springer, v. 45, n. 1, p. 41–51, 1985.
- CERRADA, M. et al. A review on data-driven fault severity assessment in rolling bearings. **Mechanical Systems and Signal Processing**, Elsevier, v. 99, p. 169–196, 2018.

CHAPMAN, S. J. **Fundamentos de máquinas elétricas**. [S.l.]: AMGH Editora, 2013.

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.

DALVAND, F.; KALANTAR, A.; SAFIZADEH, M. S. A novel bearing condition monitoring method in induction motors based on instantaneous frequency of motor voltage. **IEEE Transactions on Industrial Electronics**, v. 63, n. 1, p. 364–376, Jan 2016.

DAS, S. et al. 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.

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.

DELGADO-ARREDONDO, P. A. et al. Methodology for fault detection in induction motors via sound and vibration signals. **Mechanical Systems and Signal Processing**, v. 83, p. 568 – 589, 2017.

DEVI, N. R.; SARMA, D. V. S.; RAO, P. V. R. Detection of stator incipient faults and identification of faulty phase in three-phase induction motor–simulation and experimental verification. **IET Electric Power Applications**, IET, v. 9, n. 8, p. 540–548, 2015.

DIAS, C.; SOUSA, C. de. A neuro-fuzzy approach for locating broken rotor bars in induction motors at very low slip. **Journal of Control, Automation and Electrical Systems**, v. 29, n. 4, p. 489–499, 2018. Cited By 0.

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 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.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. [S.l.]: John Wiley & Sons, 2012.

- EBERHART, R. C.; SHI, Y. Comparing inertia weights and constriction factors in particle swarm optimization. In: IEEE. **Proceedings of the 2000 congress on evolutionary computation. CEC00 (Cat. No. 00TH8512)**. [S.l.], 2000. v. 1, p. 84–88.
- EFTEKHARI, M. et al. Online detection of induction motor's stator winding short-circuit faults. **IEEE Systems Journal**, IEEE, v. 8, n. 4, p. 1272–1282, 2014.
- ELBES, M. et al. A survey on particle swarm optimization with emphasis on engineering and network applications. **Evolutionary Intelligence**, Springer, p. 1–17, 2019.
- ENGELBRECHT, A. P.; PAMPARA, G. Binary differential evolution strategies. In: IEEE. **2007 IEEE Congress on Evolutionary Computation**. [S.l.], 2007. p. 1942–1947.
- EPE, . Balanço energético nacional 2018 - ano base 2017 - relatório final. **Empresa de Pesquisa Energetica - Ministério de Minas e Energia**, p. 294, 2018.
- 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-CALVA, T. A.; MORINIGO-SOTELO, D.; ROMERO-TRONCOSO, R. de J. Non-uniform time resampling for diagnosing broken rotor bars in inverter-fed induction motors. **IEEE Transactions on Industrial Electronics**, v. 64, n. 3, p. 2306–2315, March 2017.
- GARCIA-PEREZ, A. et al. 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. et al. 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.
- GARNER, S. R. et al. Weka: The waikato environment for knowledge analysis. In: **Proceedings of the New Zealand computer science research students conference**. [S.l.: s.n.], 1995. p. 57–64.
- 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.
- GIRI, R. et al. Offline parameter estimation of induction motor using a meta heuristic algorithm. In: SPRINGER. **International Conference on Swarm, Evolutionary, and Memetic Computing**. [S.l.], 2010. p. 523–530.
- GLOWACZ, A. Acoustic based fault diagnosis of three-phase induction motor. **Applied Acoustics**, v. 137, p. 82–89, 2018.
- 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.

GNANAPRAKASAM, C.; CHITRA, K. Soft-computing based digital filter design to analyze vibration signals of induction motor. In: . [S.l.: s.n.], 2017. v. 2017-January, p. 1–4.

GODOY, W. et al. Evaluation of stator winding faults severity in inverter-fed induction motors. **Applied Soft Computing Journal**, Elsevier, v. 32, p. 420–431, 2015.

GODOY, W. et al. Detection of broken rotor bars faults in inverter-fed induction motors. In: IEEE. **2018 XIII International Conference on Electrical Machines (ICEM)**. [S.l.], 2018. p. 1803–1808.

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. et al. Detection of broken rotor bars faults in inverter-fed induction motors. In: **2018 XIII International Conference on Electrical Machines (ICEM)**. [S.l.: s.n.], 2018. p. 1803–1808. ISSN 2381-4802.

GODOY, W. F. et al. 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.

GONGORA, W. et al. Neural approach for bearing fault detection in three phase induction motors. In: IEEE. **2013 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)**. [S.l.], 2013. p. 566–572.

GRACIOLA, C. L. et al. 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.; CASTOLDI, M. F.; GOEDEL, A. Temperature influence analysis on parameter estimation of induction motors using differential evolution. **IEEE Latin America Transactions**, IEEE, v. 14, n. 9, p. 4097–4105, 2016.

GUEDES, J. J. et al. Differential evolution applied to line-connected induction motors stator fault identification. **Soft Computing**, Springer, p. 1–10, 2018.

GUEDES, J. J. et al. Parameters estimation of three-phase induction motors using differential evolution. **Electric Power Systems Research**, Elsevier, v. 154, p. 204–212, 2018.

GYFTAKIS, K. N. et al. Comparative experimental investigation of broken bar fault detectability in induction motors. **IEEE Transactions on Industry Applications**, v. 52, n. 2, p. 1452–1459, March 2016.

HAYKIN, S. **Neural Networks and Learning Machines**. [S.l.]: Prentice Hall PTR, 2008.

- HENAO, H. et al. 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.
- HOU, Z. et al. Quantitative broken rotor bar fault detection for closed-loop controlled induction motors. **IET Electric Power Applications**, v. 10, n. 5, p. 403–410, 2016.
- IEEE. Ieee standard test procedure for polyphase induction motors and generators. **IEEE Std 112-2017 (Revision of IEEE Std 112-2004)**, p. 1–115, Feb 2018.
- JIGYASU, R.; MATHEW, L.; SHARMA, A. Multiple faults diagnosis of induction motor using artificial neural network. **Communications in Computer and Information Science**, v. 955, p. 701–710, 2019.
- JúNIOR, A. et al. The design of multiple linear regression models using a genetic algorithm to diagnose initial short-circuit faults in 3-phase induction motors. **Applied Soft Computing Journal**, v. 63, p. 50–58, 2018.
- JUNEJA, M.; NAGAR, S. Particle swarm optimization algorithm and its parameters: A review. In: IEEE. **2016 International Conference on Control, Computing, Communication and Materials (ICCCCM)**. [S.l.], 2016. p. 1–5.
- KENNEDY, J. Particle swarm optimization. **Encyclopedia of machine learning**, Springer, p. 760–766, 2010.
- KHANG, H. V.; PAWLUS, W.; ROBBERSMYR, K. G. Identification of parameters and harmonic losses of a deep-bar induction motor. In: IEEE. **2017 Seventh International Conference on Information Science and Technology (ICIST)**. [S.l.], 2017. p. 194–199.
- KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by simulated annealing. **science**, American Association for the Advancement of Science, v. 220, n. 4598, p. 671–680, 1983.
- 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. et al. **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.
- LEE, K. Y.; EL-SHARKAWI, M. A. **Modern heuristic optimization techniques: theory and applications to power systems**. [S.l.]: John Wiley & Sons, 2008.
- LEITE, V. et al. Detection of localized bearing faults in induction machines by spectral kurtosis and envelope analysis of stator current. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1855–1865, March 2015.

LIU, Y.; BAZZI, A. M. A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art. **ISA Transactions**, v. 70, p. 400 – 409, 2017. ISSN 0019-0578.

LIU, Y.; BAZZI, A. M. A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art. **ISA transactions**, Elsevier, v. 70, p. 400–409, 2017.

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. et al. Bearing fault identification of three-phase induction motors bases on two current sensor strategy. **Soft Computing**, Springer, p. 1–13, 2016.

MAJUMDAR, P. et al. State-space model based induction motor stator winding inter-turn fault detection technique. **Lecture Notes in Networks and Systems**, v. 41, p. 225–236, 2019.

MARTIN-DIAZ, I. et al. Hybrid algorithmic approach oriented to incipient rotor fault diagnosis on induction motors. **ISA transactions**, Elsevier, v. 80, p. 427–438, 2018.

MARTÍNEZ-MORALES, J. D.; PALACIOS-HERNÁNDEZ, E. R.; CAMPOS-DELGADO, D. Multiple-fault diagnosis in induction motors through support vector machine classification at variable operating conditions. **Electrical Engineering**, Springer, v. 100, n. 1, p. 59–73, 2018.

MARTÍNEZ-MORALES, J.; PALACIOS-HERNÁNDEZ, E.; CAMPOS-DELGADO, D. Multiple-fault diagnosis in induction motors through support vector machine classification at variable operating conditions. **Electrical Engineering**, v. 100, n. 1, p. 59–73, 2018.

MEDOUED, A. et al. 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.

METROPOLIS, N. et al. Equation of state calculations by fast computing machines. **The journal of chemical physics**, AIP, v. 21, n. 6, p. 1087–1092, 1953.

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.

MIRZAEVA, G.; SAAD, K. I.; JAHROMI, M. G. Comprehensive diagnostics of induction motor faults based on measurement of space and time dependencies of air gap flux. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 2657–2666, May 2017.

MONFARED, O. A.; DOROUDI, A.; DARVISHI, A. Diagnosis of rotor broken bars faults in squirrel cage induction motor using continuous wavelet transform. **COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering**, v. 38, n. 1, p. 167–182, 2019. Cited By 0.

- MOOSAVIAN, A. et al. A comparison between ann, svm and least squares svm: Application in multi-fault diagnosis of rolling element bearing. **International Journal of Acoustics and Vibrations**, v. 23, p. 432–440, 2018.
- 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**, 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.
- PALÁCIOS, R. et al. Diagnosis of stator faults severity in induction motors using two intelligent approaches. **IEEE Transactions on Industrial Informatics**, v. 13, n. 4, p. 1681–1691, 2017.
- PALÁCIOS, R. C. et al. A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. **Electric Power Systems Research**, v. 127, p. 249–258, 2015.
- PALÁCIOS, R. H. C. et al. 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. H. C. et al. 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.
- PAMPARA, G.; ENGELBRECHT, A. P.; FRANKEN, N. Binary differential evolution. In: IEEE. **2006 IEEE International Conference on Evolutionary Computation**. [S.l.], 2006. p. 1873–1879.
- PANDARAKONE, S. E.; MIZUNO, Y.; NAKAMURA, H. Distinct fault analysis of induction motor bearing using frequency spectrum determination and support vector machine. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 3049–3056, May 2017.
- PATEL, R.; GIRI, V. Ann based performance evaluation of bdi for condition monitoring of induction motor bearings. **Journal of The Institution of Engineers (India): Series B**, v. 98, n. 3, p. 267–274, 2017.
- PICAZO-RóDENAS, M. J. et al. Combination of noninvasive approaches for general assessment of induction motors. **IEEE Transactions on Industry Applications**, v. 51, n. 3, p. 2172–2180, May 2015.
- PLATT, J. Sequential minimal optimization: A fast algorithm for training support vector machines. 1998.
- PRICE, K.; STORN, R. M.; LAMPINEN, J. A. **Differential evolution: a practical approach to global optimization**. [S.l.]: Springer Science & Business Media, 2006.
- RAJAMANY, G.; SRINIVASAN, S. An artificial neural networks application for the automatic detection of severity of stator inter coil fault in three phase induction motor. **Journal of Electrical Engineering and Technology**, v. 12, n. 6, p. 2219–2226, 2017.

- RAJINDER; SREEJETH, M.; SINGH, M. Sensitivity analysis of induction motor performance variables. In: . [S.l.: s.n.], 2017.
- RAMIREZ-NUNEZ, J. et al. Evaluation of the detectability of electromechanical faults in induction motors via transient analysis of the stray flux. **IEEE Transactions on Industry Applications**, v. 54, n. 5, p. 4324–4332, 2018.
- RAMIREZ-NUNEZ, J. A. et al. Evaluation of the detectability of electromechanical faults in induction motors via transient analysis of the stray flux. **IEEE Transactions on Industry Applications**, IEEE, v. 54, n. 5, p. 4324–4332, 2018.
- RAMOS, A. R. et al. An approach to multiple fault diagnosis using fuzzy logic. **Journal of Intelligent Manufacturing**, Springer, p. 1–11, 2016.
- RESENDIZ-OCHOA, E. et al. Induction motor failure analysis: An automatic methodology based on infrared imaging. **IEEE Access**, v. 6, p. 76993–77003, 2018.
- RIERA-GUASP, M.; ANTONINO-DAVIU, J.; CAPOLINO, G.-A. Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: State of the art. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1746–1759, 2015.
- RODRIGUEZ-GUERRERO, M. et al. Hybrid approach based on ga and pso for parameter estimation of a full power quality disturbance parameterized model. **IEEE Transactions on Industrial Informatics**, v. 14, n. 3, p. 1016–1028, 2018.
- ROSHANFEKR, R.; JALILIAN, A. Analysis of rotor and stator winding inter-turn faults in wrim using simulated mec model and experimental results. **Electric Power Systems Research**, Elsevier, v. 119, p. 418–424, 2015.
- SAMANTA, B.; NATARAJ, C. Use of particle swarm optimization for machinery fault detection. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 22, n. 2, p. 308–316, 2009.
- SANTOS, T. H. dos 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. et al. A comparative assessment of brazilian electric motors performance with minimum efficiency standards. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 41, p. 308 – 318, 2015.
- SEDIKI, H. et al. Adaline approach for induction motor mechanical parameters identification. **Mathematics and Computers in Simulation**, v. 90, p. 86–97, 2013.
- SEERA, M. et al. 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.



- SHARMA, A. et al. Bearing fault diagnosis using weighted k-nearest neighbor. In: . [S.l.: s.n.], 2018. p. 1132–1137.
- SHARMA, P. et al. A review on scale factor strategies in differential evolution algorithm. In: **Soft Computing for Problem Solving**. [S.l.]: Springer, 2019. p. 925–943.
- SIDDIQUE, A.; YADAVA, G.; SINGH, B. A review of stator fault monitoring techniques of induction motors. **IEEE transactions on energy conversion**, IEEE, v. 20, n. 1, p. 106–114, 2005.
- SILVA, I. N. d. et al. **Artificial Neural Network - A Pratical Course**. [S.l.]: Springer, 2017.
- SINGH, A. et al. A review of induction motor fault modeling. **Electric Power Systems Research**, Elsevier, v. 133, p. 191–197, 2016.
- SINGH, G.; NAIKAN, V. Detection of half broken rotor bar fault in vfd driven induction motor drive using motor square current music analysis. **Mechanical Systems and Signal Processing**, v. 110, p. 333–348, 2018.
- SINGH, M.; SHAIK, A. G. Faulty bearing detection, classification and location in a three-phase induction motor based on stockwell transform and support vector machine. **Measurement**, Elsevier, v. 131, p. 524–533, 2019.
- SINGH, S.; KUMAR, N. Detection of bearing faults in mechanical systems using stator current monitoring. **IEEE Transactions on Industrial Informatics**, v. 13, n. 3, p. 1341–1349, June 2017.
- 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.
- SOLEIMANI, M.; ALIZADEH, M.; MOALLEM, M. Economical replacement decision for induction motors in industry. In: . [S.l.: s.n.], 2018. v. 2018-February, p. 1–6.
- SUETAKE, M. **Sistemas inteligentes para monitoramento e diagnósticos de falhas em motores de indução trifásicos**. Tese (Doutorado) — Universidade de São Paulo, 2012.
- SUN, G.; LAN, Y.; ZHAO, R. Differential evolution with gaussian mutation and dynamic parameter adjustment. **Soft Computing**, Springer, v. 23, n. 5, p. 1615–1642, 2019.
- SURAJ, Z.; DELIMATA, P. On k-nn method with preprocessing. **Fundamenta Informaticae**, IOS press, v. 69, n. 3, p. 343–358, 2006.
- TALBI, E.-G. **Metaheuristics: from design to implementation**. [S.l.]: John Wiley & Sons, 2009.
- TANABE, R.; ISHIBUCHI, H. Review and analysis of three components of the differential evolution mutation operator in moea/d-de. **Soft Computing**, Springer, p. 1–15, 2019.
- TIAN, X. et al. Parameter identification of a nonlinear model using an improved version of simulated annealing. **International Journal of Distributed Sensor Networks**, v. 15, n. 2, 2019.

- TOMASZEK, L.; ZELINKA, I. On static control of the differential evolution. In: SPRINGER. **International Conference on Intelligent Computing and Applications**. [S.l.], 2019. p. 19–31.
- TREETRONG, J. et al. Parameter estimation for electric motor condition monitoring. **Advances in Vibration Engineering**, The Vibration Institute of India, v. 11, n. 1, p. 75–84, 2012.
- TREJO-CABALLERO, G. et al. Multiple signal classification based on automatic order selection method for broken rotor bar detection in induction motors. **Electrical Engineering**, v. 99, n. 3, p. 987–996, 2017.
- TRIGEASSOU, J.-C. **Electrical Machines Diagnosis**. [S.l.]: John Wiley & Sons, 2013.
- TSUZUKI, M. d. S. G.; MARTINS, T. de C. **Simulated annealing: strategies, potential uses and advantages**. [S.l.]: Nova Science Publishers, Incorporated, 2014.
- UMANS, S. D. **Máquinas Eléctricas de Fitzgerald e Kingsley-7**. [S.l.]: AMGH Editora, 2014.
- 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.
- VAPNIK, V. **The nature of statistical learning theory**. [S.l.]: Springer science & business media, 2013.
- VINOTHRAJ, C.; KUMAR, N. P.; ISHA, T. Bearing fault analysis in induction motor drives using finite element method. **International Journal of Engineering and Technology(UAE)**, v. 7, n. 3, p. 30–34, 2018.
- WANG, L. et al. A novel modified binary differential evolution algorithm and its applications. **Neurocomputing**, Elsevier, v. 98, p. 55–75, 2012.
- WANG, L.; LIU, Y. Application of simulated annealing particle swarm optimization based on correlation in parameter identification of induction motor. **Mathematical Problems in Engineering**, v. 2018, 2018.
- XU, B.; SUN, L.; LI, H. A detection method for rotor fault in induction motors based on high frequency resolution spectrum estimation technique and optimization algorithm. In: CHINESE SOCIETY FOR ELECTRICAL ENGINEERING. **Zhongguo Dianji Gongcheng Xuebao(Proceedings of the Chinese Society of Electrical Engineering)**. [S.l.], 2013. v. 33, n. 3, p. 140–147.
- YANG, L.; LI, Z.-D. Inverse analysis of rock creep model parameters based on improved simulated annealing differential evolution algorithm. **Geotechnical and Geological Engineering**, v. 37, n. 2, p. 639–649, 2019.

YANG, X.-S. **Engineering optimization: an introduction with metaheuristic applications**. [S.l.]: John Wiley & Sons, 2010.

YANG, X.-S. et al. **Swarm intelligence and bio-inspired computation: theory and applications**. [S.l.]: Newnes, 2013.

YEKTANIROUMAND, T.; AZARI, M. N.; GHOLAMI, M. Optimal rotor fault detection in induction motor using particle-swarm optimization optimized neural network. **International Journal of Engineering, Transactions B: Applications**, v. 31, n. 11, p. 1876–1882, 2018.

YETGIN, A. G. Effects of induction motor end ring faults on motor performance. experimental results. **Engineering Failure Analysis**, v. 96, p. 374 – 383, 2019. ISSN 1350-6307.

ZHANG, X.; SONG, Q. Predicting the number of nearest neighbors for the k-nn classification algorithm. **Intelligent Data Analysis**, IOS Press, v. 18, n. 3, p. 449–464, 2014.

ZHANG, Y. et al. Binary differential evolution with self-learning for multi-objective feature selection. **Information Sciences**, Elsevier, v. 507, p. 67–85, 2020.