UNIVERSIDADE DE SÃO PAULO–USP
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

WYLLIAM SALVIANO GONGORA

**IDENTIFICAÇÃO DE FALHAS ELÉTRICAS EM
MOTORES DE INDUÇÃO TRIFÁSICOS POR
INJEÇÃO DE SINAL DE REFERÊNCIA**

São Carlos
2019

Wylliam Salviano Gongora

**Identificação de Falhas Elétricas em Motores
de Indução Trifásicos por Injeção de Sinal de
Referência**

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

Área de concentração: Sistemas Dinâmicos

Orientador: Ivan Nunes da Silva

Coorientador: Alessandro Goedel

São Carlos

2019

Trata-se da versão corrigida da tese. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da
EESC/USP com os dados inseridos pelo(a) autor(a).

G635i Gongora, Wylliam Salviano
 Identificação de Falhas Elétricas em Motores de
Indução Trifásicos por Injeção de Sinal de Referência /
Wylliam Salviano Gongora; orientador Ivan Nunes da
Silva; coorientador Alessandro Goedtel. São Carlos,
2019.

Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Elétrica e Área de Concentração em Sistemas
Dinâmicos -- Escola de Engenharia de São Carlos da
Universidade de São Paulo, 2019.

1. Motor de indução trifásico. 2. Inversor de
frequência. 3. Inteligência computacional. 4.
Multiclassificador de falhas. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **WYLLIAM SALVIANO GONGORA.**

Título da tese: "Identificação de falhas elétricas em motores de indução trifásicos por injeção de sinal de referência".

Data da defesa: 06/05/2019.

Comissão Julgadora:

Prof. Associado **Ivan Nunes da Silva**
(Orientador)

(Escola de Engenharia de São Carlos/EESC)

Prof. Dr. **Manoel Luis de Aguiar**

(Escola de Engenharia de São Carlos/EESC)

Prof. Dr. **Alessandro Goedel**

(Universidade Tecnológica Federal do Paraná/UTFPR)

Prof. Dr. **Claudionor Francisco do Nascimento**

(Universidade Federal de São Carlos/UFSCar)

Profa. Dra. **Anna Diva Plasencia Lotufo**

(Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP-Ilha Solteira)

Resultado:

APROVADO

Aprovado

Aprovado

APROVADO

APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:

Prof. Associado **Ivan Nunes da Silva**

Presidente da Comissão de Pós-Graduação:

Prof. Titular **Murilo Araujo Romero**

*Este trabalho é dedicado a minha esposa Gioselle, ao meu filho Joaquim e a meus pais.
Se tenho por quem lutar, nunca me verão desistir.*

Agradecimentos

Os agradecimentos principais são ao meu Orientador Professor Dr Ivan Nunes da Silva que soube reconhecer e aceitou a possibilidade de um trabalho mesmo quando o tempo não estava a nosso favor e ao Professor Dr. Alessandro Goedtel que me disse que sempre acreditou em meu potencial e sabia do que eu era capaz.

Agradeço aos meus familiares pela compreensão das ausências e retiradas da vida cotidiana para imersão nos estudos e viagens constantes. A minha esposa Gioselle A. W. Gongora e meu filho Joaquim A. Gongora que na simplicidade e pureza de seus sorrisos me motivaram a continuar.

Agradecimentos especiais são direcionados aos colegas de laboratório e pesquisas Professor Dr. Tiago Henrique Santos e Professor MsC. Clayton Graciola que me proporcionaram as ideias bases para o desenvolvimento desta pesquisa em um dos vários momentos que pudemos desfrutar de nossa amizade fazendo o que também gostamos muito além de pesquisar e desenvolver ideias.

Agradeço aos Colegas e ao Instituto Federal do Paraná pelo apoio e compreensão nos tantos momentos em que as atividades diárias convergiam as atividades de pesquisa.

Este trabalho conta também com o aporte financeiro da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná (Processo N^o 06/56093 – 3), do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Processos N^o 474290/2008-5, 473576/2011-2, 552269/2011-5, 405228/2016-3) e da Fundação de Amparo a Pesquisa do Estado de São Paulo - FAPESP (Processo N^o 2011/17610-0).

*“Na verdade não me preocupa que queiram roubar minhas ideias,
me preocupa que eles não as tenham.”
(Nikola Tesla)*

Resumo

Gongora, Wylliam Salviano **Identificação de Falhas Elétricas em Motores de Indução Trifásicos por Injeção de Sinal de Referência**. 100 p. Tese de doutorado – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2019.

As máquinas elétricas rotativas são hoje a principal forma de transformação da energia elétrica em mecânica motriz e os motores de indução trifásicos têm grande relevância dentro do setor produtivo. A garantia de um correto funcionamento torna-se vital para eficácia e competitividade da empresa dentro do setor fabril. Assim sendo, um correto diagnóstico e classificação de falhas de funcionamento dos motores em operação pode fornecer maior segurança no processo de tomada de decisão sobre a manutenção, aumentar a produtividade e eliminar os riscos e os danos aos processos como um todo. A proposição deste trabalho baseia-se na análise das correntes de estator no domínio da frequência com sinais injetados na máquina juntamente com a modulação de alimentação para o diagnóstico do motor sem defeitos, com falhas de curto-circuito nos enrolamentos do estator e com falhas de rotor. A proposta é validada numa ampla faixa de frequências de operação bem como de regimes de conjugado de carga. São analisados os desempenhos individuais de cinco técnicas de classificadores de padrões, sendo proposta a utilização de: *i)* Perceptron Multicamadas, *ii)* Máquina de Vetores de Suporte, *iii)* *k*-Vizinhos Próximos, *iv)* Árvore de Decisão C 4.5 e *v)* *Naive Bayes*. Complementarmente, é desenvolvido um comparativo dos métodos de classificação de padrões para avaliar a precisão de classificação frente aos diversos níveis de severidade das falhas. Resultados experimentais com motor de 1 cv são apresentados para validar a proposta.

Palavras-chave: Motor de indução trifásico, inversor de frequência, inteligência computacional, multiclassificador de falhas.

Abstract

Gongora, Wylliam Salviano **Identification of Electrical Faults in Three-phase Induction Motors by Reference Signal Injection.** 100 p. Ph.D. Thesis – São Carlos School of Engineering, University of São Paulo, 2019.

Rotating electric machines are today the main form of transformation of electrical energy in motor mechanics and three-phase induction motors have great relevance within the productive sector. Thus a correct diagnosis and classification of failures of the engines in operation can provide security in the decision making process on maintenance, increase productivity and eliminate risks and damages to processes as a whole. The purpose of this paper is based on the analysis of the stator currents in the frequency domain with signals injected into the machine together with the power modulation for the diagnosis of motor faultless, stator winding short-circuit faults and rotor faults. Considering also, for validation of the proposal is validated on a broad range frequency of operation as well as load torque. We analyze the individual performances of five standard classifier techniques, proposing the use of: *i*) Multilayers Perceptron, *ii*) Support Vector Machine, *iii*) *k*-Nearest Neighbor, *iv*) C 4.5 Decision Tree and *v*) Naive Bayes. Complementarily, a comparison of the methods of classification of standards is developed to evaluate the accuracy of classification against the different levels of severity of the failures. Experimental results with 735,5w and 1.471 w engines are presented to validate the proposal.

Keywords: Three-phase induction motor, frequency inverter, computational intelligence, fault multi-classifier.

Lista de ilustrações

Figura 1	Fluxograma dos tipos de manutenção	26
Figura 2	Distribuição das causas e efeitos nas falhas relacionadas aos MIT	27
Figura 3	Comparativo de estudos em ocorrência de falhas em MITs	28
Figura 4	Percentual de falhas em MITs segundo EPRI	36
Figura 5	Motor de estator rebobinado com <i>taps</i>	39
Figura 6	Rotor com quebra forçada das barras	40
Figura 7	Comparação de sinais de corrente de fase	47
Figura 8	Deteção da falha através da corrente do estator utilizando <i>FFT</i>	49
Figura 9	Exemplificação da rede perceptron multicamadas	52
Figura 10	Exemplificação da classificação por <i>k-nn</i>	53
Figura 11	Exemplificação de classificação por <i>SVM</i>	54
Figura 12	Exemplificação da classificação por <i>C4.5</i>	55
Figura 13	Exemplificação da classificação por <i>NB</i>	56
Figura 14	Esquemático proposto	62
Figura 15	Bancada de ensaios	63
Figura 16	Fluxo de informação para processamento dos dados	64
Figura 17	Modulação do Sinal Harmônico de Referência de Busca - SHRB	66
Figura 18	Comparativo percentual de desempenho por SI	76
Figura 19	Comparação de estruturas de árvores de decisão	99

Lista de tabelas

Tabela 1	Classificação das falhas por origem	36
Tabela 2	Amostra de dados	67
Tabela 3	Resultado final da classificação pelo algoritmo PMC	68
Tabela 4	Resultado final da classificação pelo algoritmo k -nn	69
Tabela 5	Resultado final da classificação pelo algoritmo SVM	70
Tabela 6	Resultado final de classificação pelo algoritmo C4.5	70
Tabela 7	Resultado final de classificação pelo algoritmo NB	71
Tabela 8	Resultados comparativos entre os SI	72
Tabela 9	Matrizes de confusão dos algoritmos PMC, C4.5 e NB	74
Tabela 10	Índices de Sensibilidade e Especificidade para PMC, C4.5 e NB	75
Tabela 11	Comparativo entre trabalhos correlatos	76
Tabela 12	Resultados comparativos entre os SI	77
Tabela 13	Resultados para o algoritmo SVM com variação do calibrador	96
Tabela 14	Resultado para algoritmo k -nn com variação de $k = 5$ vizinho	97
Tabela 15	Resultado para algoritmo PMC com variação do número de neurônios	98
Tabela 16	Matriz de confusão da abordagem PMC com variação do número de neurônios	98
Tabela 17	Resultado para algoritmo C4.5 com variação na poda	99
Tabela 18	Resultado para algoritmo NB com variação do <i>kernel</i>	100

Lista de siglas

C4.5 *Decision Tree*

CSA *Current Signature Analysis*

DAQ *Data Acquisition Board*

DFT *Discrete Fourier Transform*

EPRI *Electric Power Research Institute*

FT *Fourier Transform*

FFT *Fast Fourier Transform*

IEEE *Institute of Electric and Electronic Engineers*

IHM *Interface Homem Máquina*

k-nn *k- nearest neighbor*

LibSVM *Library for Support Vector Machines*

MCSA *Motor Current Signature Analysis*

MIT *Motores de Indução Trifásicos*

MAE *Mean Absolute Error*

MSE *Mean Squared Error*

NB *Naive Bayes*

PMC *Perceptron Multicamadas*

PDS *Processamento Digital de Sinais*

PWM *Pulse Width Modulation*

RNA Rede Neural Artificial

RMSE *Root Mean Squared Error*

SI Sistemas Inteligentes

SVM *Support Vector Machine*

SMO *Sequential Minimal Optimization*

SHRB Sinal Harmônico de Referência de Busca

WEKA *Waikato Environment for Knowledge Analysis*

VSA *Voltage Signature Analysis*

Sumário

1	INTRODUÇÃO	25
1.1	MOTIVAÇÃO	27
1.2	JUSTIFICATIVA	28
1.3	OBJETIVO	31
1.3.1	Objetivo geral	31
1.3.2	Objetivos específicos	32
1.4	ORGANIZAÇÃO DO TRABALHO	32
2	ASPECTOS RELACIONADOS AS FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS	35
2.1	ASPECTOS GERAIS DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS	35
2.2	FALHAS ELÉTRICAS	37
2.2.1	Falhas de estator	37
2.2.2	Emulação de falha de curto circuito no estator	38
2.2.3	Falhas de rotor	39
2.2.4	Reprodução do defeito de barras quebradas	40
2.3	CONSIDERAÇÕES PARA MOTORES ACIONADOS POR INVERSORES DE FREQUÊNCIA	41
2.4	CONCLUSÃO DO CAPÍTULO	42
3	METODOLOGIA PARA IDENTIFICAÇÃO DE FALHAS EM MIT	43
3.1	ASPECTOS RELACIONADOS À ANÁLISE ESPECTRAL E TRANSFORMADA DE FOURIER	43
3.1.1	Transformada contínua de Fourier	44
3.1.2	Transformada rápida de Fourier	45
3.2	DETECÇÃO DA FALHA UTILIZANDO A CORRENTE DO ESTATOR	46
3.2.1	Análise de assinatura da corrente do motor	47

3.3	EQUACIONAMENTO DAS FREQUÊNCIAS DE FALHAS	49
3.4	CLASSIFICADORES INTELIGENTES DE PADRÕES	51
3.4.1	Perceptron multicamadas	51
3.4.2	<i>k-nn</i>	53
3.4.3	<i>Support Vector Machines</i> - SVM	54
3.4.4	Árvores de decisão	55
3.4.5	Naive Bayes - NB	56
3.5	MÉTRICA DE AVALIAÇÃO DE CLASSIFICADORES	57
3.5.1	Acurácia	57
3.5.2	Coeficiente <i>kappa</i>	58
3.5.3	Sensibilidade e especificidade	58
3.5.4	Erro absoluto médio	59
3.5.5	Raiz quadrada do erro quadrático médio	59
3.6	CONCLUSÃO DO CAPÍTULO	59
4	METODOLOGIA DE INJEÇÃO DE SINAL HARMÔNICO DE REFERÊNCIA DE BUSCA	61
4.1	METODOLOGIA PROPOSTA	62
4.2	FLUXO DE INFORMAÇÃO DO PROCESSAMENTO	64
4.3	MODULAÇÃO DO SINAL HARMÔNICO DE REFERÊNCIA DE BUSCA .	65
4.4	CONDIÇÕES GERAIS DE EXECUÇÃO DA PROPOSTA	67
4.4.1	Resultados de avaliação PMC	68
4.4.2	Resultados de avaliação <i>k-nn</i>	69
4.4.3	Resultados de avaliação SVM	69
4.4.4	Resultados de avaliação C4.5	69
4.4.5	Resultados de avaliação NB	70
4.5	DISCUSSÕES E RESULTADOS	71
4.5.1	Classificador de severidade	71
4.5.2	Classificador simples	73
4.5.3	Comparativo de desempenho por ZeroR	75
4.5.4	Comparação com trabalhos correlatos	76
4.6	CONCLUSÃO DO CAPÍTULO	78
5	CONCLUSÃO	81
5.1	TRABALHOS FUTUROS	84
5.2	PUBLICAÇÕES ASSOCIADAS	84

Apêndices **93**

APÊNDICE A OUTRAS ANÁLISES DOS SISTEMAS INTELIGENTES **95**

A.1	APONTAMENTOS SOBRE SVM E k-nn	95
A.1.1	Resultados de avaliação SVM	95
A.1.2	Resultados de avaliação <i>k-nn</i>	96
A.2	ALTERNATIVAS PARA PMC, C4.5 E NB	97
A.2.1	Resultados de avaliação PMC	97
A.2.2	Resultados de avaliação C4.5	98
A.2.3	Resultados de avaliação NB	99
A.3	RESULTADOS ALTERNATIVOS	100

INTRODUÇÃO

Ao fazer uma análise sistêmica de um processo de manutenção em Motores de Indução Trifásicos (MIT) deve-se observar o contexto da aplicação das máquinas no cenário elétrico e seu papel dentro dos processos das quais fazem parte. Outrossim, deve-se entender as adversidades a que estão sujeitas e anomalias presentes nessas aplicações para poder classificar os tipos de falhas e seu estado de degradação a fim de intervir quando necessário e de modo a propor uma manutenção coerente e eficaz. O perfeito estado de funcionamento do equipamento é essencial para as técnicas de controle bem como para o melhor desempenho da produção fabril (TRAN et al., 2013b; LEME, 2017).

É perceptível a ascensão das máquinas elétricas rotativas como principal forma de transformação da energia elétrica em mecânica motriz (GRITLI et al., 2017). Porém, por suas características construtivas, elas compõem um sistema dinâmico e equilibrado (ONG, 1998). Em se tratando de um equipamento composto de muitas partes e adaptado a uma variedade de aplicações, esse tem a interação mútua entre a parte elétrica e a mecânica (ONG, 1998). Assim sendo, a identificação de falhas não é uma ciência trivial e direta. Muitas vertentes se desdobram nos preceitos e técnicas de processamento de sinais para a identificação e ou classificação da presença de anormalidades de funcionamento desse equipamento (SOBRINHO, 2015; LEME, 2017).

Dentre as técnicas convencionais já propostas, a modalidade de manutenção preditiva aplica o conceito apresentado de acompanhamento das condições da máquina e intervenção programadas na iminência de uma falha (ALMEIDA, 2018). Esta é apenas uma parte do conceito de manutenção planejada, conforme visto na Figura 1 (SILVA; ANDRADE, 2016).

A metodologia preditiva de falhas é atrativa aos olhos da otimização uma vez que tem o intuito de identificar as condições exatas de funcionamento do equipamento para uma intervenção adequada como afirma também Ishizaka e Nemery (2014). Assim, observam-se as crescentes pesquisas deste assunto e as constituições de novas tecnologias para detecção de falhas em MIT, corroborando para o surgimento continuado de métodos, processos e tecnologias empregadas para este fim (SINGH et al., 2016). Há também uma vertente de pesquisas voltadas à detecção precoce da falta com aplicação de algoritmos simplificados de análise diversificadas e sensori-

Figura 1: Fluxograma dos tipos de manutenção

amento de baixo custo (CARNERO, 2014; LEME, 2017).

Então, tornam-se dinâmico e crescente as proposições de metodologias de monitoramento das condições de operação de um MIT, possibilitando o diagnóstico de falhas e previsão das suas condições de operação. Tal fato se deve a considerável influência do MIT sobre a continuidade operacional de muitos processos industriais (GONGORA et al., 2013). Conforme Santos, Silva e Suetake (2012a), a confiabilidade é um ponto fundamental a ser considerado, inclusive nos levantamentos de valores e custos de produção. Assim, uma parada não programada ocasionada por falha pode representar de 15% a 40% deste valor final (ALMEIDA, 2018).

Neste contexto, este trabalho propõe a investigação e estruturação de uma técnica de processamento de sinais elétricos para identificação de múltiplas falhas nos MIT. Mais especificamente, propõe-se uma metodologia alternativa às convencionais, baseada na injeção de sinais de referência na alimentação do motor. Assim, por meio da extração de características dos sinais elétricos no domínio da frequência, têm-se então informações sobre o estado de funcionamento do motor. Como consequência, cria-se uma matriz de dados a qual será interpretada por classificadores inteligentes; a saber: *i) Perceptorn Multicamadas (Multilayers Perceptron)*, *ii) Máquina de Vetores de Suporte (Support Vector Machine)*, *iii) k- Vizinhos Próximos (k-Nearest Neighbor)*, *iv) Árvore de Decisão - C 4.5 (Decision Tree)* e *v) Naive Bayes*.

Ainda, este trabalho visa utilizar o próprio módulo inversor de frequência usado em sua alimentação e controle para gerar as componentes harmônicas colocadas em uma sinal de referência a ser injetado na máquina. Uma vez estabelecida a referência harmônica desejada esta é modulada e alimentará a máquina a qual responderá com um sinal de corrente distorcido durante esse curto intervalo de tempo de operação.

1.1 MOTIVAÇÃO

Os motores elétricos, como qualquer equipamento, estão sujeitos a falhas provenientes de suas peças componentes e que podem-se dividir em função de sua origem em dois grupos distintos: falhas elétricas e falhas mecânicas (GRITLI et al., 2017).

A presença de algum tipo de falha nas máquinas de indução acarretam em mudanças de interação do fluxo entre o estator e o rotor o que resulta em mudanças no campo magnético, na vibração da máquina, na temperatura de operação, nos ruídos audíveis, dentre outros distúrbios (DÍAZ et al., 2018). Inclusive, mesmo para falhas de origem mecânica, podem ser observadas alterações nas grandezas elétricas tais como a tensão e a corrente. As falhas internas ocasionam fenômenos perceptíveis externamente à máquina tais como vibrações, aumento da temperatura na carcaça e mudanças nos sinais de corrente de linha de alimentação do motor (GONGORA et al., 2013).

A complexidade da caracterização das falhas em máquinas elétricas pode ser melhor compreendida ao observar a Figura 2 que apresenta um diagrama das principais causas capazes de resultar nas falhas mecânicas de rotor e as falhas elétricas de estator, bem como em alguns casos nos quais as causas podem acarretar no desenvolvimento de falhas em ambos os tipos citados. Esta sub-classificação dos principais tipos de falhas no MIT co-relacionados a estes dois grandes campos é baseada nos trabalhos de Singh e Kumar (2016) e Gritli et al. (2017).

Figura 2: Distribuição das causas e efeitos nas falhas relacionadas aos MIT

Das falhas a que estão sujeitos os motores de indução destacam-se as que modificam, além do funcionamento adequado do motor, os sinais elétricos do seu acionamento. Tais alterações nos sinais das correntes elétricas se justificam, pois estas são responsáveis pelo fluxo magnético gerado nas bobinas do estator, as quais provocam a indução das tensões no enrolamento do rotor, como é apresentado nas literaturas mais tradicionais como Ong (1998) ou mesmo em trabalhos recentes como Bensaoucha et al. (2018).

Um diagnóstico antecipado permite a intervenção antes mesmo da evolução da falta. Portanto, uma boa metodologia de investigação e detecção de falhas deve englobar várias características e capacidade diagnóstica (DÍAZ et al., 2018). De acordo com Leme (2017), com a

utilização correta das ferramentas e informações, é possível prever até mesmo o tempo de operação do motor antes que um determinado tipo de pane completa ocorra.

Das falhas anteriormente citadas, algumas referências como Kowalski e Orłowska-Kowalska (2003) e Han, Yang e Yin (2007) estimam que os rolamentos são responsáveis por 40% ou mais das paradas indesejadas dos MIT; e as falhas de estator correspondem a mais de 30%, restando cerca de 10% das falhas atribuídas a rotor e 20% para uma classificação mais genérica. A Figura 4 apresenta um gráfico comparativo entre os diversos tipos de falhas, conforme os estudos encomendados pelas agências *Institute of Electric and Electronic Engineers* (IEEE) e *Electric Power Research Institute* (EPRI) e apresentados nos trabalhos relacionados.

Figura 3: Comparativo de estudos em ocorrência de falhas em MITs

Fonte: (KOWALSKI; ORŁOWSKA-KOWALSKA, 2003)

Uma abordagem multiclassificadora, focada no apontamento antecipado da presença de falhas de rotor (barras quebradas) e falhas de estator, capaz ainda de classificar a falta em suas características distintas permitiria o diagnóstico preciso da manutenção preditiva abordando até 47% das anomalias de funcionamento dos MITs.

1.2 JUSTIFICATIVA

Observando o cenário de distribuição de energia no Brasil, têm-se como maior percentual de consumo de energia elétrica a parcela de consumidores industriais, superando os 35% de todas as categorias de consumidores nacionais. Dentre estes, em trabalhos correlatos recentes apresentados por Godoy (2016) e Palácios (2016), afirma-se que ao chão de fábrica são aplicados na alimentação de MIT mais de 60% da energia elétrica. Esses, por sua vez, são interligados às redes de alimentação basicamente por duas formas distintas:

I) Diretamente na rede elétrica: O que significa a alimentação por sinais senoidais de frequência conhecida e padronizadas no sistema elétrico brasileiro em 60 Hertz.

II) Por meio de cicloconversor ou inversor de frequência: Utilizando chaveamento eletrônico e técnicas de modulação de sinais de alimentação que, por consequência, alimentam as máquinas com sinais não senoidais e são aplicados para variação de velocidade e controle de processos.

As técnicas de assessoramento na tomada de decisões para a manutenção em máquinas rotativas classificam a presença das falhas por análises de corrente elétrica e/ou a análise de vibrações como é descrito por Almeida (2018) e Oliveira (2007). Nos trabalhos de Sobrinho (2015) e Soares (2014) são apresentados os estudos comparativos das técnicas e proposições de observações de resultados.

Entretanto, existe um grande número de dificuldades associadas com estas técnicas e, consequentemente, com a sua aplicação prática. Isso devido a abrangência de detecção pela vasta gama de problemas associados às máquinas e também à grande variedade de características construtivas dos motores, como descrito por Godoy (2016) e Palácios (2016) e revalidado nas publicações de Godoy et al. (2014), Godoy et al. (2015) e Palácios et al. (2016). Cada elemento componente da máquina pode ocasionar uma característica de falhas diferente a cada tipo de ocorrência anormal. Desta forma, as falhas ocasionam, em máquinas com características construtivas diferentes, respostas semelhantes mas em amplitudes ou faixas de operação diferentes (BENSAOUCHA et al., 2018). Assim, os Sistemas Inteligentes (SI) têm sido muito utilizados no contexto da dinâmica dos sinais e diversidade de características que em muitos casos são desconhecidas (DÍAZ et al., 2018).

Na detecção e classificação de falhas pode-se citar desde os estudos de Baccarini (2005) até os mais recentes trabalhos como Bensaoucha et al. (2018) que apresentam as principais falhas de MIT e equacionamento que tornam possível a simulação de falhas por modelagem matemática. Também Suetake (2012) e) que apresenta a metodologia para emular falhas de rotor e estator nos MIT em ambiente controlado de laboratório; ambos abordando a capacidade de sistemas inteligentes na classificação destas falhas. Corroborando com a variação de metodologia, Santos, Silva e Suetake (2012a) apresenta a utilização destas metodologias inteligentes utilizando-se de parâmetros estatísticos como fator de análise.

Em trabalhos correlatos como os apresentados em Godoy et al. (2014), Godoy et al. (2015), Godoy et al. (2016), Palácios et al. (2015), Palácios et al. (2016) e Palácios (2016) é visto que não necessita-se de equipamentos específicos para análise dos MIT, mas sim a leitura dos dados de funcionamento diretamente dos sensores de tensão e corrente, sendo os dados tratados tanto para máquinas ligadas diretamente a rede de alimentação como acionadas por inversores de frequência. Assim, nos referidos trabalhos são aprofundadas as análises das abordagens inteligentes com comparação de desempenho entre elas e proposta ainda uma abordagem multiagente com a proposição de um sistema capaz de classificar a existência ou não das falhas bem como determinar a origem das mesmas.

Ainda, segundo Santos, Silva e Suetake (2012b), os métodos mais tradicionais para análise de sinais de MIT não apresentam tanta eficiência na identificação de falhas em motores acionados por inversores de frequência. Isto pode ocorrer pelo controle da realimentação de corrente que vem mascarar a assinatura da frequência de falha (MARTIN-DIAZ et al., 2017). Outros fatores impeditivos de um diagnóstico preciso são a mudança constante da carga, ou produção de componentes de frequências próximos à componente fundamental; que podem sobrepor-se às assinaturas de barra quebra do rotor (KIM et al., 2011).

Os inversores de frequência podem apresentar inúmeros tipos de controle distintos que interferem e modulam diretamente o sinal de alimentação e, por consequência, podem refletir em frequências características de falhas que a máquina venha a apresentar. Outro aspecto é que as máquinas que utilizam o controle de velocidade podem operar em características diferentes aos dados nominais do motor, como velocidade de rotação e torque (MARTIN-DIAZ et al., 2017).

Esses fatores contribuem diretamente nas frequências características de falhas, uma vez que os modelos matemáticos têm por base os valores de velocidades de funcionamento das máquinas. Outro aspecto que pode-se avaliar é que muitas vezes são desconsiderados nas ferramentas tradicionais e nas metodologias de identificação de falhas a aplicação ou conexão a que estes motores fazem parte. Em alguns casos estes motores podem ser implementados em máquinas maiores que são acoplados a eixos, mancais, rolamentos, caixas de redução/engrenagens e cargas distintas que também têm suas contribuições na injeção de sinais de falhas no MIT (DÍAZ et al., 2018).

Essa variedade de situações propicia as investigações de falhas e corroboram para o surgimento continuado de metodologias e tecnologias diversas, tanto de softwares, como exemplo o descrito por Soares (2014), como também hardwares demonstrado por Gongora et al. (2013), todas empregadas para o desenvolvimento e aperfeiçoamento das técnicas de detecção de falhas em MIT (D'ANGELO et al., 2011). Estas técnicas objetivam o assessoramento nas tomadas das decisões referentes à manutenção e ao melhor desempenho na detecção precoce da falta, buscando também a aplicação de algoritmos simplificados de análise diversificadas e sensoria-mento de baixo custo (ISHIZAKA; NEMERY, 2014).

Neste contexto, ainda são referenciados os trabalhos de Cusido et al. (2006a) e Cusido et al. (2006b), que propõe a inserção de um sinal de referência em uma determinada frequência por meio de um inversor conectado em paralelo à alimentação da máquina. Entretanto, este sinal é único e provido por um meio externo a ligação da mesma ao acionamento. Distinguindo deste trabalho, a proposta aqui apresentada utiliza-se do mesmo módulo inversor responsável pelo acionamento para a inserção de vários sinais harmônicos de referência de busca que são utilizados para direcionar e enfatizar as características de falhas a serem observadas pelo classificador de padrões inteligente.

Assim, este trabalho busca apresentar uma forma alternativa para a investigação e diagnóstico de falhas com a injeção de sinais de referência em frequências distintas e conhecidas para construção de uma matriz de entrada que possa ser utilizada em sistemas inteligentes atuando

como classificadores de padrões. A diferença principal dessa proposta consiste na utilização dessa matriz de dados com os sinais elétricos adicionados de sinais harmônicos de referências injetados juntamente com a alimentação da máquina. Assim, propõe-se um único sistema inteligente capaz de indicar e classificar a presença de múltiplas falhas no MIT a partir da análise da resposta em frequência da matriz proposta.

1.3 OBJETIVO

A proposta deste trabalho consiste em fornecer uma ferramenta de apoio a decisão dos operadores, bem como dos processos complexos de diagnóstico e multiclassificação de falhas, por meio de uma metodologia de inserção e monitoramento de parâmetros das máquinas utilizando o próprio módulo inversor de frequência da alimentação do motor. Assim, objetiva-se determinar o estado do seu funcionamento e suas falhas de maneira preditiva utilizando um sistema classificador de padrões inteligente.

A aplicação de sistemas inteligentes tem por base suas arquiteturas de processamento e a capacidade de generalização do conhecimento. Isso significa que ao imputar um conhecimento com uma quantidade significativa de exemplos, os quais descrevem a dinâmica do sistema no seu domínio de operação, este sistema é capaz de responder a estímulos para os quais não foi treinado.

Desta forma, a proposta deste trabalho fica vinculada também ao desenvolvimento de uma metodologia alternativa as tradicionais para análise de dados e extração de informações, utilizando esta ferramenta auxiliar na tomada de decisão por operadores lógicos e sistemas inteligentes. Esta proposição manipula e monitorar as grandezas elétricas de tensão e corrente de alimentação de um motor de indução trifásico juntamente com componentes harmônicas em frequências características específicas, injetados para o diagnóstico da máquina.

A análise dos dados é fundamentada na resposta em frequência destes sinais aplicados à alimentação do motor de indução trifásico. Técnicas similares são propostas para sinais de tensão e corrente da máquina com a busca por frequências características de falha (SUETAKE, 2012; GONGORA et al., 2013). Assim, cada falha numa determinada máquina é responsável por uma frequência distinta (GRITLI et al., 2017) (BENSAOUCHE et al., 2019). Esta técnica pretende então inserir componentes harmônicas com amplitude e frequência conhecida e observar a resposta da máquina pela interação com este sinal.

1.3.1 Objetivo geral

O trabalho tem como objetivo principal a proposição de uma metodologia alternativa às convencionais para identificação de falhas em motores elétricos de indução trifásicos, baseado na análise no domínio da frequência das respostas à injeção de sinais harmônicos de referência em frequências pré determinadas, utilizando-se para isso a modulação dos sinais de alimentação por meio de inversor de frequência.

1.3.2 Objetivos específicos

Dentre outras funcionalidades esta proposta apresenta etapas intermediárias, as quais contam com as aplicações e os desenvolvimentos paralelos, como:

- ❑ Criar um banco de dados com sinais de tensão e corrente, modulados com sinais harmônicos de referências aplicados à máquinas saudáveis e com falhas de estator e rotor;
- ❑ Incrementar o banco de dados já existente com as medidas das grandezas elétricas providas dos motores em funcionamento nas mais diversas condições de falhas, gerando informações para ajuste e validação do modelo proposto e aprofundamento em abordagens similares;
- ❑ Estabelecer uma metodologia válida e um fluxo de processo para utilização como ferramenta de classificação de falhas;
- ❑ Sintonizar e testar cinco classificadores inteligentes de padrões, a saber: *i) Perceptron Multicamadas (PMC)*, *ii) Suport Vector Machine (SVM)*, *iii) k- nearest neighbor (k-nn)*, *iv) Decision Tree (C4.5)* e *v) Naive Bayes (NB)*; para classificação de falhas com dados de falhas elétricas obtidos nos testes e componentes do banco de dados;
- ❑ Elaborar um sistema especialista para implementação em hardware e prototipação da proposta.

Os dados necessários para o desenvolvimento e validação dos sistemas inteligentes serão diretamente obtidos de dados experimentais em laboratório. Assim sendo, o resultado final esperado pelo desenvolvimento deste trabalho é o aprimoramento de métodos, técnicas e ferramentas que permitem representar, analisar, projetar e implementar soluções inteligentes para diagnosticar falhas em motores elétricos de indução trifásicos.

1.4 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado da seguinte forma: o Capítulo 2 descreve as principais falhas elétricas em motores de indução que serão abordadas por essa tese, as quais representam mais de 47% das falhas a que estão sujeitos os MIT. Relata-se ainda, de forma sucinta, suas características e alterações no funcionamento da máquina. São apresentados também alguns procedimentos e metodologias de reprodução em laboratório destas falhas a fim de dispor de dados para treinamento do multiclassificador inteligente multiagente.

No Capítulo 3 são apresentadas as metodologias convencionais para identificação de falhas em questão. Também são descritas as funções matemáticas dos métodos e equacionamento das características de falhas para a análise de assinatura de corrente de motor, que é a base deste trabalho. Ainda no Capítulo 3 são abordadas as principais características dos sistemas inteligentes aplicados neste trabalho, exemplificando e equacionando os processamentos que

possibilitam sua implementação computacional em que são também apontados os pontos fortes de cada algoritmo.

O Capítulo 4 apresenta toda a metodologia empregada para inserção dos Sinal Harmônico de Referência de Busca (SHRB), onde são descritos os elementos essenciais e parametrização dos métodos e equipamentos utilizados para validação dos resultados, relatando ainda a aquisição dos sinais de dados e apresentando a concepção geral do fluxo de informação da proposta de estudo. Por fim, apresenta-se a concepção dos algoritmos multiclassificadores de padrões com menção às metodologias de sistemas inteligentes no papel de classificador de falhas.

A conclusão, presente no Capítulo 5, apresenta as considerações observadas da utilização da metodologia de inserção do SHRB como classificador inteligente no diagnóstico de falhas do MIT. Neste capítulo também são discutidas as questões referentes ao processamento da informação e o incremento do banco de dados de sinais de máquinas defeituosas.

ASPECTOS RELACIONADOS AS FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

Os motores elétricos, como quaisquer equipamentos, estão sujeitos a diversos tipos de falhas. Algumas falhas podem ser atribuídas a sua peças ou partes componentes, os quais são citados como principais os enrolamentos de estator, as barras de rotor ou mesmo seus elementos de rolamentos de eixo ou mancais. Neste capítulo são apresentados os conceitos de falhas em motores de indução trifásicos, dando ênfase nas falhas de origem elétrica, as quais são observadas nas assinaturas espectrais da corrente de fase do motor de indução trifásico.

As falhas elétricas, tanto no rotor como no estator estão relacionadas aos enrolamentos abertos ou em curto, barras quebradas ou anéis de curto circuito danificados (YAHIA et al., 2012). Já para as falhas de origem mecânica, citam-se a excentricidade do rotor deslocado do seu centro magnético, rolamento defeituoso, ou ainda, eixo do rotor torto ou desalinhamento dos acoplamentos mecânicos (ATTOUI et al., 2017).

2.1 ASPECTOS GERAIS DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

A presença de algum tipo de falha nas máquinas de indução acarretam em mudanças de interação de fluxo entre o estator e o rotor, o que resulta em mudanças na corrente do estator, nas tensões, no campo magnético, na vibração da máquina, na temperatura de operação, nos ruídos audíveis, dentre outros distúrbios (GODOY, 2016) (GODOY et al., 2016). Mesmo as falhas internas ocasionam fenômenos perceptíveis externamente à máquina tais como vibrações, aumento da temperatura na carcaça e mudanças nos sinais de corrente de linha de alimentação do motor (PALÁCIOS et al., 2016). Mais especificamente, tanto as falhas de origem elétrica como as falhas de origem mecânica podem ser observadas por alterações na resposta elétrica da máquina.

Dividindo-se a origem das falhas nestes dois grupos distintos, falhas elétricas e falhas mecânicas, é possível vincular uma sub-classificação mais detalhada dos principais tipos de falhas em

MIT correlacionado aos seus elementos de procedência (SINGH; KUMAR, 2016), como apresentado na Tabela 1. Neste contexto identificar o elemento responsável por tais anomalias facilita a manutenção e recuperação do equipamento (BELLINI et al., 2008).

Tabela 1: Classificação das falhas por origem

Falhas Elétricas	Falhas Mecânicas
Enrolamento de Estator	Acoplamentos e Mancais
Quebra de Barras do Rotor	Desalinhamento
Quebra de Anéis de Curto Circuito	Excentricidade
	Rolamento

Fonte: (BELLINI et al., 2008)

No recente trabalho de Irfan et al. (2017) são apresentados os resultados de um estudo do EPRI onde estima-se que os rolamentos são responsáveis por 40% ou mais das paradas indesejadas dos motores. Complementarmente, como pode ser visto na Figura 4, as falhas de estator correspondem a mais de 37%, restando-se cerca de 10% das falhas atribuídas a rotor e 12% para outras falhas. Assim, classificar a presença de falhas de curto circuito no enrolamento do estator e nas barras quebradas do rotor pode corresponder em diagnosticar com precisão até 47% dos problemas em motores de indução. Ainda, pela referida pesquisa, pode-se observar pouca divergência em relação ao trabalho de Kowalski e Orłowska-Kowalska (2003) citado no Capítulo 1 desta tese.

Figura 4: Percentual de falhas em MITs segundo EPRI

Fonte: (IRFAN et al., 2017)

Com a utilização correta das ferramentas e informações é possível prever o tempo de operação do motor antes que um determinado tipo de pane completa ocorra (AYDIN; KARAKOSE; AKIN, 2014). Uma boa metodologia de investigação e detecção de falhas deve considerar a dinâmica dos processos, funcionamento do equipamento, tipo de acionamento ou controle e critérios adicionais diretamente relacionados às respostas dos métodos (MABROUK; ZOUZOU, 2015).

Um diagnóstico preciso e antecipado permite então a intervenção efetiva antes da evolução da falta para uma parada total do equipamento. Assim, a busca pelo monitoramento preditivo associada ao diagnóstico de falhas torna-se parte integrante de um processo maior da manutenção baseada em condições (LAKEHAL; RAMDANE, 2017).

2.2 FALHAS ELÉTRICAS

As falhas ditas de origem elétricas podem ser tanto relacionadas ao estator como ao rotor. Como mencionado por Irfan et al. (2017), falhas no enrolamento de estator correspondem a aproximadamente 37% das causas associadas às paradas indesejadas de motores elétricos. Outros trabalhos como Godoy et al. (2015) ou Palácios et al. (2016) apontam índices de cerca de 28%, com relevante destaque a esta falha e à necessidade de identificá-la.

Dentre as falhas oriundas de rotor, a quebra, trincas ou as rachaduras das barras ou dos anéis finais são responsáveis por aproximadamente 10% das falhas em MIT (IRFAN et al., 2017), com algumas ponderações deste valor citando cerca de 8% conforme Baccarini, Menezes e Caminhas (2010) e Godoy et al. (2016). Tal falha não necessariamente leva à parada imediata do motor, mas não exime a análise do estado e a gravidade da mesma, visto que pedaços das barras pode comprometer o estator rompendo o seu isolamento, causando assim um curto circuito entre espiras ou até mesmo entre as fases (YAHIA et al., 2012).

Nas subseções a seguir são tratadas mais especificamente cada uma das duas falhas elétricas abordadas neste trabalho, bem como a metodologia utilizada para recriar seus efeitos em ambiente de simulação controlada.

2.2.1 Falhas de estator

A alimentação trifásica nos enrolamentos do estator de um MIT resulta na circulação de correntes pelas bobinas. Estas, por sua vez, originam um campo magnético para cada uma das correntes circulantes, cuja amplitude varia conforme a tensão aplicada ao enrolamento. Fazendo-se a composição vetorial dos três campos magnéticos obtém-se então um campo resultante e girante que se desloca a uma velocidade angular proporcional à frequência do sinal de alimentação (FITZGERALD; KINGSLEY; UMANS, 2006).

As bobinas do estator que ficam sujeitas às diversas anomalias ocasionam variadas respostas e comportamentos inadequados do equipamento. As alterações no estator podem se manifestar

como no aquecimento excessivo do motor, vibração mecânica, perda de potência mecânica, sobrecarga elétrica e a falha no isolamento da bobina (GODOY, 2016).

Essas alterações podem ser diagnosticadas por testes de isolamento do estator com a carga da máquina, ou testes de isolamento entre as fases (KOWALSKI; ORLOWSKA-KOWALSKA, 2003; SEERA et al., 2014). Numa avaliação não invasiva e por medição em operação, podem ser feitas as análises da corrente elétrica; ou seja, uma abordagem de manutenção executada sem a necessidade da desmontagem da máquina utilizando apenas o monitoramento dos parâmetros de alimentação (D'ANGELO et al., 2011; PALÁCIOS et al., 2016).

As falhas mais comuns associadas aos enrolamentos de estator são as seguintes: curto-circuito entre fase-terra, fase-fase, curto-circuito entre as bobinas do mesmo enrolamento ou de diferentes fases (TRAN et al., 2013b; MARTÍNEZ-MORALES; PALACIOS-HERNÁNDEZ; CAMPOS-DELGADO, 2016). É importante observar que um pequeno curto-circuito entre as espiras da mesma bobina no enrolamento do estator com severidade reduzida permite que a máquina continue trabalhando, mas com o torque reduzido. Já um curto-circuito com maior grau de severidade pode ser detectado pela elevação da corrente de linha na alimentação da máquina. Este estágio do curto-circuito poderá afetar todos os enrolamentos da máquina e exige a intervenção imediata no motor (BELLINI et al., 2008). Estas falhas são observadas com frequência nos casos de motores de indução acionados por inversores de frequência (DAS et al., 2014; GODOY et al., 2016).

2.2.2 Emulação de falha de curto circuito no estator

O curto-circuito entre as fases ou entre a fase e o terra são falhas graves que podem inutilizar o estator do motor ou proporcionar danos à rede de alimentação. Tais situações não foram testadas em laboratório para este estudo.

As falhas de estator que foram simuladas em ambiente controlado tratam das faltas de isolamento dos enrolamentos das bobinas e são atribuídas a diferentes razões como, por exemplo surtos de tensão, envelhecimento, vibrações, manuseio mecânico inadequado durante os procedimentos de manutenções, excesso de graxa durante a substituição de rolamentos danificados, além da inevitável degradação natural da isolação

Outro agravante para perda de isolamento das bobinas de estator está nas elevações térmicas excessivas (PALÁCIOS et al., 2016), pois a temperatura no enrolamento das máquinas elétricas exerce importante influência para a vida útil do isolamento, sendo relatado que um aumento de 10 °C acima do limite especificado reduz a vida útil prevista do motor para cerca da metade. Mais especificamente, quando o sinal de alimentação é modulado para controlar a velocidade da máquina, o acionamento em baixas faixas de frequência associados À elevados conjugados de carga favorecem a elevação da temperatura nos enrolamentos do motor e, conseqüentemente, a redução da sua vida útil (ROMERO-TRONCOSO, 2017).

A simulação de condição de falha no estator é proposta por Suetake (2012), e utilizada em outros trabalhos como Godoy et al. (2016), Palácios et al. (2014) e Lopes et al. (2016), em que

é relatado todo o procedimento para recriação deste defeito em laboratório. Basicamente, a inserção ocorre pela emulação da perda do isolamento do fio que compõe a bobina do estator. Uma vez desprotegida, esta bobina pode ocasionar o curto entre as fases, a fase e a carcaça ou entre as espiras de uma mesma bobina.

Nessas condições, é apresentado na Figura 5 um motor de 1 cv, 4 pólos, da marca WEG que foi rebobinado com *taps* de derivação dos enrolamentos das bobinas de cada fase, as quais são usadas para simular os curto-circuitos. Chaves de ligação (*on/off*) são acopladas aos bornes de ligação dos *taps* de derivação para o acionamento e desacionamento da condição faltosa. Quando as referidas chaves são acionadas ocorre curto-circuito entre 1%, 3%, 5% ou 7% das espiras de uma mesma bobina.

Figura 5: Motor de estator rebobinado com *taps*

Outras razões para a falha de isolamento incluem surtos de tensão, envelhecimento, vibrações, manuseio mecânico inadequado durante os procedimentos de manutenções, excesso de graxa durante a substituição de rolamentos danificados, além da inevitável degradação natural da isolação (YANG et al., 2007). O monitoramento deste tipo de falha em seu estágio inicial de evolução permitirá a reparação da máquina e reutilização após recondicionamento do bobinamento do estator (SUETAKE, 2012).

2.2.3 Falhas de rotor

O diagnóstico de barras quebradas de rotor em motores de indução trifásicos é apresentado em pesquisas como Suetake (2012) e Palácios et al. (2016). A quebra de barras do rotor pode ser provocada por vibração, desalinhamento e excentricidade. A carga excessiva no eixo também é capaz de provocar a ruptura ou trinca, além de fatores como alterações de temperaturas, que podem ser consequências dos outros problemas, ou mesmo desgaste dos mancais do motor (GODOY et al., 2016).

No momento em que o circuito apresenta uma barra quebrada ocorrem alterações na distribuição do fluxo de entreferro, pois o rotor não responde à excitação de maneira uniforme. Esta variação eletromagnética, que é criada por pontos de sobra ou sem indução no rotor, pode causar níveis significativos de ruídos principalmente na partida do motor, além de vibrações da máquina e do eixo. De acordo com o apresentado por Godoy (2016), este tipo de falha não leva o motor à uma pane imediata podendo a máquina continuar em funcionamento.

A barra quebrada tem impacto no conjugado, gerando oscilações de duas vezes a frequência de escorregamento (BACCARINI; MENEZES; CAMINHAS, 2010). De maneira geral, as falhas elétricas nos MIT podem ser originadas por problemas internos da máquina ou problemas relacionados a distúrbios de qualidade de energia na rede externa que alimenta o motor.

2.2.4 Reprodução do defeito de barras quebradas

A reprodução do defeito de barras quebradas de rotor em laboratório consiste no cisalhamento forçado das barras do rotor ou interrupção do circuito que compõem a gaiola de indução. Este procedimento é apresentado por Suetake (2012) e utilizado nos trabalhos de Godoy et al. (2016) e Palácios et al. (2016). A ruptura da barra é obtida com a perfuração por meio de furadeira de bancada com broca de diâmetro maior que a largura da barra. O resultado é um conjunto de rotores, cada qual com uma composição de barras quebradas conforme o exemplo apresentado na Figura 6. As quebras propostas foram feitas de 1 até 4 barras distribuídas em sequências e também diferenciadas na circunferência do rotor.

Figura 6: Rotor com quebra forçada das barras

Um fato questionável nesta técnica fica evidente no trabalho de Sobrinho et al. (2015), o qual afirma que pequenas quantidades de massa retiradas do rotor, de forma irregular ou desproporcional, causam o desbalanceamento mecânico por distribuição irregular de peso e oscilações no fluxo magnético, o que acarreta em frequências harmônicas presentes nos sinais da corrente.

Entretanto, a referida metodologia é encontrada em recentes trabalhos como Yahia et al. (2012), Palácios et al. (2015), Palácios et al. (2016), Godoy et al. (2016) e Godoy et al. (2015). Nestes trabalhos o efeito do desbalanço de massa do rotor são negligenciados, pois acredita-se que a alteração da distribuição do fluxo magnético de entreferro é predominante no sinal da corrente de linha da alimentação.

2.3 CONSIDERAÇÕES PARA MOTORES ACIONADOS POR INVERSORES DE FREQUÊNCIA

Os acionamentos elétricos modernos são comumente formados pela combinação de motores elétricos acionados por meio de inversores de frequência, os quais são responsáveis pela variação da velocidade nos MIT. Em Martin-Diaz et al. (2017), Fernandez-Cavero et al. (2015) e Santos, Silva e Suetake (2012b) é relatada a necessidade nos sistemas de detecção e diagnóstico de problemas nos MIT alimentados por inversores de frequência.

Uma atenção especial em falhas elétricas de estator é dada na maioria das pesquisas relacionadas à classificação e diagnóstico de falhas em MIT acionados por inversores de frequência. Há o entendimento de que os inversores são um componente adicional no processo de geração deste tipo de falhas uma vez que as máquinas são submetidas à distorções da tensão senoidal devido ao chaveamento dos dispositivos semicondutores (GODOY et al., 2016). Consequentemente, há o aumento excessivo da temperatura dos enrolamentos, desenvolvendo os problemas de isolamento e favorecendo a ocorrência de falhas já relatados anteriormente.

Os módulos inversores de frequência, em sua grande maioria, empregam técnicas de *Pulse Width Modulation* (PWM) a fim de controlar os níveis de tensão e a frequência de sinais de alimentação dos motores a eles acoplados. Consequentemente, quando há diferença de impedância entre a fonte e a carga, sinais harmônicos aleatórios são amplificados ou produzidos procedentes de reflexão junto dos sinais principais. Esta problemática de casamento de impedância pode ser oriunda de uma instalação incorreta, seleção de componentes indevidos ou degradação do equipamentos ao longo do tempo, levando-se a tensão de pico a níveis que ocasionam a quebra do isolamento do motor (FERNANDEZ-CAVERO et al., 2015).

Outro aspecto proveniente do uso da modulação de sinais consiste no surgimento de correntes parasitas que circulam pelo sistema. Assim, estas correntes podem ocasionar o excesso de calor nos enrolamentos ou provocar descargas por meio do contato direto com partes aterradas (SANTOS; SILVA; SUETAKE, 2012b).

Ao mesmo tempo, defende-se a importância dos inversores de frequência nos sistemas de diagnóstico de falhas em motores elétricos pelo monitoramento continuado da corrente elétrica, velocidade de rotação e níveis de tensão (GODOY, 2016). A disponibilidade de sensoriamento empregada por estes equipamentos, juntamente com processadores digitais, criam novas perspectivas na identificação e classificação de falhas em motores. Essas tendências tecnológicas

apontam estudos para o uso de inversores inclusive na notificação de falhas de origem interna e externa aos MIT (KUMAR; KODAD; SARVESH, 2018).

De acordo com Godoy (2016) os inversores de frequência, além de melhorar desempenho e gerar economia em vários aspectos, possibilitam a automação de processos com aprimoramento de técnicas de sistemas inteligentes operando em uma hierarquia superior.

Um apontamento encontrado no trabalho de Godoy (2016), também demonstrado por Santos, Silva e Suetake (2012a), diz que sinais usados na identificação de falhas em MIT acionados por inversores de frequência apresentam limitações devido ao mascaramento da assinatura da falha, uma vez que a dinâmica de controle modula os sinais para compensar as alterações de carga e garantir a velocidade de rotação. Para minimizar esta limitação, trabalhos mais recentes aplicam técnicas avançadas de processamento de sinais (VINAYAK; UDDIN; JAGADANAAND, 2017) ou direcionam a análise por meio da potência instantânea (IRFAN et al., 2015; IRFAN et al., 2017).

2.4 CONCLUSÃO DO CAPÍTULO

Este capítulo descreve sucintamente os aspectos relacionadas as características principais das falhas elétricas no MIT e das técnicas de reprodução de falhas em ambiente de simulação controlada. Considerando os apontamentos descritos a partir da caracterização das falhas de rotor e estator, que representam cerca de 47% dos defeitos em discussão, estas metodologias são empregadas no desenvolvimento desta abordagem alternativa de processamento de sinais para a criação de um banco de dados.

Esta proposta busca uma alternativa viável e confiável à aplicação em máquinas que são acionadas por inversores de frequência, visando superar as limitações apontadas no que tange o mascaramento de assinatura de falhas. Desta forma, são criados subsídios para a aplicação de estratégias de detecção de falhas baseadas em metodologias tradicionais e também sistemas inteligentes com conhecimento amplo e abrangência sobre as anomalias que estão sujeitas as máquinas.

As metodologias tradicionais de estruturação de um classificador inteligente para identificação de falhas são apresentadas no Capítulo 3 subsequente, com foco na capacidade de indicar a presença ou não da falta e estimar a degradação da anomalia.

METODOLOGIA PARA IDENTIFICAÇÃO DE FALHAS EM MIT

A presença de algum tipo de falha nas máquinas de indução acarretam em mudanças de interação de fluxo entre o estator e o rotor. Este fato resulta em mudanças na corrente do estator, nas tensões, no campo magnético, na vibração da máquina, na temperatura de operação, nos ruídos audíveis, dentre outros distúrbios (ROMERO-TRONCOSO, 2017).

Os sistemas de diagnóstico de falhas geralmente optam por métodos não-invasivos e técnicas diferentes são apresentadas e desenvolvidas tanto para aquisição como ao pré processamento de dados. No entanto, essas ferramentas aumentam a quantidade de informações necessárias para a análise e o uso dos sinais medidos originais como atributos devido à sua grande dimensionalidade.

Neste contexto as técnicas mais atuais de diagnóstico passam geralmente por duas etapas que são as seguintes: i) o cálculo e a seleção de recursos ou a redução de dimensionalidade, e ii) o estágio de classificação por Sistemas Inteligentes (SI) (ATTOUI et al., 2017). Neste capítulo são tratados os aspectos relacionados à análise espectral dos sinais de corrente do motor que embasam os dados de diagnóstico da metodologia proposta e as metodologias de classificação de padrões utilizados neste trabalho.

3.1 ASPECTOS RELACIONADOS À ANÁLISE ESPECTRAL E TRANSFORMADA DE FOURIER

A avaliação das metodologias convencionais para detecção e diagnóstico de falhas em máquinas elétricas é baseada na representação de um sinal durante seu processamento, podendo ser abordados no domínio do tempo ou no domínio da frequência (SOBRINHO, 2015). O foco deste estudo está fundamentado na análise no domínio da frequência da qual toma-se por base a *Fourier Transform* (FT).

A FT trabalha com a representação de um sinal periódico em composição de infinitos termos

em senos e cossenos. Em síntese, uma ferramenta matemática que permite representar e estudar o comportamento dos sinais com respeito às propriedades de periodicidade (KÖRNER, 1989) e (BEERENDS et al., 2003).

Entretanto, a fim de viabilizar a prática e a implementação do cálculo do espectro via transformada, são propostos alternativas com a discretização dos sinais conhecida como Discrete Fourier Transform (DFT) ou Transformada Discreta de *Fourier* em tradução literal. A DFT é uma técnica que possibilita avaliar o sinal de forma mais rápida e viável, proporcionando um menor esforço computacional, a qual é derivada do algoritmo conhecido como *Fast Fourier Transform* (FFT) (OPPENHEIM; SCHAFER, 2010) e (OLIVEIRA, 2007).

3.1.1 Transformada contínua de Fourier

A abordagem da transformada de Fourier tem por base a série trigonométrica apresentada pelo matemático francês *Jean Baptiste Joseph Fourier*, que foi publicada pela primeira vez em 1822 no *Theorie analytique de la Chaleur* (SOBRINHO, 2015). Em que, por meio de uma série infinita de funções trigonométricas apresentadas na Equação (1), foi possível estabelecer o equacionamento diferencial parcial na administração da difusão de calor (ROBERTS, 2012).

$$f(t) \approx \frac{a_0}{2} + \sum_{k=1}^{\infty} [a_k \cos(k\omega_0 t) + b_k \sin(k\omega_0 t)] \quad (1)$$

Sendo k uma sequência infinita de números reais inteiros ($k = 1, 2, 3, \dots$) e $\omega_0 t$ a frequência angular em radianos por segundo, chamados de harmônicos da função. Estes termos obedecem a relação $\omega_0 = 2\pi/T$, pertencente à janela de tempo $t_0 < t < t_0 + T$ para o período T . É importante ressaltar que para sinais periódicos a janela de observação frequentemente coincide com o período T do sinal. Ainda, os coeficientes a_0 , a_k e b_k obedecem a série de funções apresentadas na Equação (2) (CHU, 2008).

$$\begin{aligned} a_0 &= \frac{2}{T} \int_{t_0}^{t_0+T} f(t) dt \\ a_k &= \frac{2}{T} \int_{t_0}^{t_0+T} f(t) \cos(k\omega_0 t) dt \\ b_k &= \frac{2}{T} \int_{t_0}^{t_0+T} f(t) \sin(k\omega_0 t) dt \end{aligned} \quad (2)$$

A transformada de Fourier é uma função de valor complexo da frequência apresentada na Equação (3), cujo valor absoluto representa a soma das frequências presente na função original e cujo argumento complexo é a fase de deslocamento da base senoidal naquela frequência (SMITH, 2007).

$$f(t) \approx \sum_{k=-\infty}^{\infty} c_k e^{(-j\omega_0 kt)} \quad (3)$$

Os valores de c_k são chamados de coeficientes da série exponencial de Fourier ou coeficientes espectrais apresentados na Equação (4).

$$c_k = \frac{1}{T} \int_T f(t) e^{(-j\omega_0 kt)} dt, k = \pm 1, \pm 2, \pm 3, \dots \quad (4)$$

Assim sendo, a FT é uma transformada integral que detecta frequências e representa qualquer função integrável $f(t)$ como a soma exponencial complexa com frequência angular ω e amplitude complexa $F(j\omega)$, quanto $T \rightarrow \infty$ e $c_k \rightarrow 0$. A representação matemática simplificada da FT é dada pela Equação (5) (HAYKIN; VEEN, 1999).

$$F(j\omega) = \int_{-\infty}^{\infty} f(t)e^{(-j\omega_0 t)} dt \quad (5)$$

A representatividade gráfica dos coeficientes de um sinal em função da frequência resulta em um quadro designado espectro em frequência, e a análise do mesmo recebe a denominação de análise espectral (KÖRNER, 1989).

3.1.2 Transformada rápida de Fourier

Em algumas abordagens em que não é possível obter o cálculo exato da FT de forma analítica, faz-se necessário buscar, a partir de um conjunto de valores medidos, a possibilidade de calcular uma aproximação para a resposta da TF do sinal (SOBRINHO, 2015).

Assim, tendo por base o conjunto de pontos componentes de um período inteiro de um sinal periódico que represente os valores das amostras, torna-se possível calcular a FT desse sinal. O cálculo dessa transformada é obtido por meio de um número finito de operações aritméticas de números complexos, denominada DFT e representada pela Equação (6) (OPPENHEIM; SCHAFER, 2010).

$$F(n) = \frac{1}{N} \sum_{k=0}^{N-1} f(k)W_N^{kn} \quad (6)$$

A Equação (6) é aplicável considerando um sinal no domínio do tempo ($f(k)$) manifestado com N amostras de k variando de $k = 0, 1, 2, 3, \dots, N-1$, obtendo como resposta as mesmas N amostras do sinal agora no domínio da frequência denotadas por $F(n)$ para $n = 0, 1, 2, 3, \dots, N-1$.

Com a evolução da matemática computacional, por meio do Processamento Digital de Sinais (PDS) e o aumento da capacidade de processamento em conjunto com o aparecimento de novas técnicas eficientes para a avaliação de transformadas discretas ou Transformadas Rápidas, a DFT tornou-se uma solução prática cada vez mais atrativa (SOBRINHO, 2015).

A DFT ganhou reconhecimento e popularidade como a FFT, onde um algoritmo rápido reordena os cálculos dos coeficientes de uma DFT com o objetivo de diminuir a complexidade temporal e minimizar o tempo de execução, consequentemente reduzindo o número de operações elementares realizadas, o que diminui a energia consumida no processo visando aplicações em tempo real (OLIVEIRA, 2007).

3.2 DETECÇÃO DA FALHA UTILIZANDO A CORRENTE DO ESTATOR

O método de análise espectral em que se realiza o estudo da assinatura elétrica pode ser relacionado a várias técnicas e procedimentos que visam identificar um padrão (assinatura) presente nos sinais elétricos da máquina que caracterizem as particularidades de uma determinada falha (REIS, 2010). Mesmo que este sinal venha de uma falha mecânica ele pode ser percebido nas características elétricas, pois assim é o comportamento dinâmico do MIT. Conforme Singh, Kumar e Kumar (2014), a grandeza elétrica a ser monitorada para análise determina a nomenclatura do método sendo as principais:

- I) *Current Signature Analysis* (CSA);
- II) *Voltage Signature Analysis* (VSA);
- III) *Motor Current Signature Analysis* (MCSA); e
- IV) Outras componentes de múltiplas análises.

A metodologia CSA é útil para analisar não somente motores elétricos de indução, mas também geradores, transformadores, etc; envolvendo análise de resistência, impedância, indutância, ângulo de fase, resposta de corrente/frequência e isolamento para terra danificados (SINGH; KAZAZ, 2003; SINGH; KUMAR; KUMAR, 2014; REIS, 2010). A abordagem VSA apresenta estas mesmas características com a observação dos sinais de tensão do equipamento. Já a abordagem MCSA é um dos métodos mais empregados nas práticas de diagnóstico de falhas em MIT, tratando-se de uma especificidade da abordagem de CSA.

As falhas alteram o fluxo de entreferro do motor e induzem tensões com frequências harmônicas características das falhas nas indutâncias da máquina. O fluxo magnético oscilante, que reflete na tensão induzida, e como consequência na corrente que circula pelo enrolamento, interage com a frequência de alimentação. Essas alterações harmônicas resultam em bandas laterais da frequência fundamental de alimentação (ROMERO-TRONCOSO, 2017; ATTOUI et al., 2017).

Ao observar a Figura 7(a) e 7(b), a partir de seus sinais no domínio do tempo não é possível diferenciar em qual deles está presente a falha de barras quebradas no rotor. É comum que o método da análise espectral seja empregado como parte dessas avaliações, analisando o sinal da corrente elétrica com a observância de sua composição harmônica (SANTOS; SILVA; SUETAKE, 2012b; IMMOVILLI et al., 2013).

No sinal tratado no domínio da frequência, apresentado em detalhe na Figura 7(c) e 7(d), é observável a existência de componentes harmônicos com frequência característica de uma falha de rotor. A observação destas componentes harmônicas podem determinar a falha incipiente da máquina (TRAJIN; REGNIER; FAUCHER, 2008; IMMOVILLI et al., 2010; SEERA et al., 2014).

Assim, a classificação ocorre pela presença de frequências harmônicas ou pela diferença das amplitudes das frequências em decibéis (*dB*). Essa diferença também caracteriza o grau de deterioração da mesma, pois a amplitude do espectro em frequência é diretamente proporcional à amplitude da vibração ocasionada pela falha. Assim, quanto menor a diferença de amplitude

Figura 7: Comparação de sinais de corrente de fase

do sinal na frequência característica de falha e na frequência fundamental, maior o estado de degradação (BLODT et al., 2008).

Desta forma, conforme consta na literatura, a MCSA é muito utilizada para diagnóstico de falhas em máquinas elétricas. Entretanto, o referido método tem algumas limitações. No trabalho de Siegel et al. (2012) é citada a necessidade de um sensor de velocidade para determinar a frequência específica de análise. Ainda, conforme descrito em Bellini et al. (2008), a análise do sinal de corrente pode ser usado para detectar falhas quando os rolamentos estão muito deteriorados.

3.2.1 Análise de assinatura da corrente do motor

O método de Análise pela Assinatura da Corrente do Motor, da sigla em inglês MCSA, é uma técnica não-invasiva de diagnóstico, que consiste em avaliar o espectro do sinal de corrente de linha do estator, sendo um procedimento padrão para análise de harmônicas específicas. Quando uma falha está se desenvolvendo, o espectro de frequência da corrente se torna diferente para quando a máquina opera em condições sem falha.

O método conhecido como MCSA foi desenvolvido pelo *Oak Ridge National Laboratory* em 1989 para monitorar uma variedade de motores elétricos. Essa técnica é um aperfeiçoamento da classe mais ampla de métodos ESA e tradicionalmente é aplicada a motores de indução trifásicos, pois permitem a identificação de falhas tanto elétricas como mecânicas (REIS, 2010).

A metodologia da MCSA utiliza a análise do espectro de frequência da corrente do motor para detectar componentes específicas ligadas a falhas distintas. A variação da técnica pode ser aplicada até mesmo em regime transitório (REIS, 2010).

A assinatura da corrente do estator relata problemas incipientes como as falhas no estator, curto-circuitos do enrolamento, anomalias na carga, danos nos rolamentos, barras quebradas do rotor, anéis quebrados do rotor e excentricidades; com sinais característicos em frequências específicas no espectro. Estas componentes de frequência podem ser indicadores de falha para sistemas automatizados como afirmam Nandi et al. (1999). Em outras palavras, os componentes da corrente podem representar mais de uma falha, além de algumas características escondidas ou mascaradas em ruídos devido às baixas frequências. Logo, torna-se necessária a aplicação de técnicas de processamento de sinais para extração dessas características.

O sinal de tensão do estator também é usado para detectar problemas no rotor, principalmente quebras nas suas barras. O sinal padrão do suprimento de tensão é analisado e seu ciclo médio é determinado a fim de ser usado como comparação com outros sinais, pois as oscilações específicas no ciclo médio aumentam quando há falhas nas barras do rotor (NEMEC et al., 2010). A comparação da amplitude relativa à frequência desses componentes assegura a presença de falha do motor. Além disso, a diferença da amplitude da componente relacionada à falha pode indicar um tempo de sobrevida usado para monitorar a condição da máquina.

Métodos que utilizam os sinais de vibração também são usados para detectar a presença de falhas mecânicas nos rolamentos e nas barras do rotor (D'ANGELO et al., 2011). Entretanto, os sensores de emissão acústica exigidos podem ser caros e de difícil instalação, além de serem influenciados por ruídos inerentes ao próprio funcionamento normal da máquina (IMMOVILLI et al., 2010; FROSINI; BASSI, 2010). Os sinais elétricos são preferidos em muitas situações em virtude de serem facilmente acessados, confiáveis e, principalmente, por traduzir diferentes tipos de falhas (IMMOVILLI et al., 2013).

As técnicas de processamento de sinais tradicionais podem esconder problemas dos MIT acionados por inversores de frequência (SANTOS; SILVA; SUETAKE, 2012a)(GODOY et al., 2014; PALÁCIOS et al., 2015; PALÁCIOS et al., 2016). Assim, buscam-se métodos alternativos para analisar o estado de operação dos dispositivos elétricos. Dentre estes métodos destacam-se os sistemas inteligentes, os quais podem ser implementados em controladores ou em aplicações *offline* do sistema de diagnóstico. Em trabalhos correlatos, encontram-se as Redes Neurais Artificiais por meio da PMC, SVM, k-nn, *Fuzzy* ARTmap, Árvore de Decisão e *Naive Bayes*, aplicadas na identificação de falhas diversas com esta alimentação (PALÁCIOS, 2016) em barras quebradas do rotor (KAMINSKI; KOWALSKI; ORLOWSKA-KOWALSKA, 2010; GODOY et al., 2016) e em falhas no enrolamento do estator (CHO et al., 2010; GODOY et al., 2015) e no rolamento (ABU-RUB et al., 2010; GONGORA et al., 2013).

A metodologia proposta neste trabalho tem por objetivo fornecer o fluxo *online* de leitura e análise das grandezas elétricas, as quais são adicionadas frequências pré-selecionadas que possam revelar falhas e anomalias. A análise de dados utilizando-se de sinais processados no

domínio da frequência seguirá os princípios da metodologia de análise de assinatura da corrente elétrica, observadas por classificadores inteligentes, fazendo-se saber: PMC, SVM, k -nn, C4.5 Árvore de Decisão e *Naive Bayes*.

3.3 EQUACIONAMENTO DAS FREQUÊNCIAS DE FALHAS

O método de análise espectral em que se realiza a busca pela assinatura elétrica do motor pode ser relacionado a várias técnicas e procedimentos, as quais visam identificar padrões presentes nos sinais elétricos que caracterizam a particularidade de uma determinada falha. Muitas abordagens utilizam a combinação desta técnica a fim de garantir a confiabilidade da resposta (ROMERO-TRONCOSO, 2017).

A vibração resultante de cada tipo de falha resultará em uma assinatura harmônica diferente como pode ser observado na Figura 8, em que são apresentadas as *FFT* de falhas de rolamento (distribuída e localizada), barras quebradas de rotor e a máquina em estado de funcionamento sem falha.

Figura 8: Detecção da falha através da corrente do estator utilizando *FFT*

A fim de ilustrar a metodologia MCSA a Figura 8 apresenta 4 situações de análise espectral do sinal de corrente de um único MIT de 1 cv acionado por um inversor de frequência operando em 60 Hz sem adição de carga mecânica no eixo. Visualmente, em algumas frequências harmô-

nicas são percebidas as particularidades de cada falha. Na Figura 8 (a) é apresentado o espectro do sinal de corrente do motor sem falhas, o qual toma-se por base na comparação com as demais situações. Observando a Figura 8(b), amostrado o sinal com falha de barras quebradas do rotor, fica evidenciada a presença de frequências harmônicas em bandas laterais da frequência fundamental e no entorno de 300 Hz e 400 Hz. Já na Figura 8(c) e (d), as quais comparam as falhas de rolamento distribuídas e localizada respectivamente, são percebidas as acentuações das harmônicas de ordem ímpar (3^a , 5^a e 7^a) do referido sinal.

As falhas alteram, entre outros, o fluxo de entreferro do motor e induzem tensões com frequências harmônicas características. O fluxo magnético oscilante, que se reflete na tensão induzida e como consequência na corrente que circula pelo enrolamento, interage com a frequência de alimentação. Essas alterações harmônicas resultam em bandas laterais da frequência fundamental de alimentação. Mesmo que este sinal venha de uma falha mecânica, este pode ser percebido nas características elétricas, dado o comportamento dinâmico do MIT (THOMSON; CULBERT, 2017).

Uma forma de aprofundar a análise espectral descrita na Seção 3.3 é determinar numericamente a frequência característica da falha que pretende se observar e assim desenvolver a observação mais detalhada com verificação da presença ou alterações das amplitudes em *dB*.

De acordo com Thomson e Gilmore (2003) é possível determinar as séries de frequências de falhas oriundas de quebras de barras do rotor pela Equação (7), onde a resultante determina o valor proporcional de ordem (k) da frequência harmônica de barra quebrada (f_{brb}) baseada na frequência de funcionamento da máquina (f_{fun}) com o escorregamento (s) e o número de pólos do estator (p).

$$f_{brb} = f_{fun} \left[k \left(\frac{1-s}{p} \right) \pm s \right] \quad (7)$$

Em se tratando da frequência característica de curto-circuito dos enrolamentos do estator, a Equação (8) apresenta os resultados tendo a frequência harmônica de curto no estator (f_{st}), também baseada na frequência de funcionamento da máquina (f_{fun}) com o escorregamento (s) e o número de pólos do estator (p).

$$f_{st} = f_{fun} \left[\frac{n}{p} (1-s) \pm k \right] \quad (8)$$

Sendo (k) de ordem inteira, em ambos os casos são estabelecidas as frequências em bandas laterais igualmente dispostas que se propagam e atenuam em torno da frequência fundamental.

Ainda sobre a metodologia tradicional de MCSA, conforme consta na literatura e observado na Equação (7) e (8), sua precisão depende de uma série de informações dinâmicas do MIT tais como a frequência de alimentação, a velocidade de operação, o escorregamento e o número de pólos.

Neste contra ponto, as abordagens contendo métodos de classificação baseadas em Sistemas Inteligentes para observação das respostas providas do MCSA têm se mostrado eficazes para

auxiliar os operadores nas tomadas de decisões como observado em Romero-Troncoso (2017), Liu et al. (2018) ou Martin-Diaz et al. (2017).

3.4 CLASSIFICADORES INTELIGENTES DE PADRÕES

O reconhecimento inteligente de padrões consiste em observar as regularidades num conjunto de dados por meio de algoritmos computacionais visando a distribuição desses dados em categorias ou classes distintas baseados em conhecimento preliminar, dedutivo ou informações estatísticas extraídas dos padrões estabelecidos (HAYKIN, 2001).

Existem dois tipos de reconhecimento inteligente de padrões: o supervisionado e o não supervisionado. O reconhecimento supervisionado utiliza o conjunto de treinamento para classificar os dados obtidos de acordo com as categorias já existentes e nelas organizá-los. Por sua vez, o reconhecimento não supervisionado utiliza o conjunto de treinamento para criar novas categorias, ao invés de simplesmente separar os dados de acordo com as categorias já existentes. Esse emprego dos SI na área de máquinas elétricas e em especial aos aspectos relacionados à identificação e classificação de padrões de falhas em MIT são ferramentas altamente flexíveis que aplicáveis em vários segmentos e condições operacionais (SILVA; SPATTI; FLAUZINO, 2010).

Os classificadores de padrões inteligentes aqui estudados e testados são baseados em regras, árvores de decisão, vizinhança de elementos, vetores de suporte, redes neurais artificiais e redes *Bayesianas*. Estes métodos utilizam-se de padrões de informações conhecidas que são colocados para treinamento e validação do algoritmo a fim de criar modelos de classificadores que possam ser aplicados em novos conjuntos de dados como ferramenta inteligente de classificação. Posteriormente é realizada uma comparação entre as metodologias propostas e estruturada numa solução multiclassificadora para aplicação na detecção e classificação quanto à severidade das falhas a que são sujeitas os MIT.

3.4.1 Perceptron multicamadas

As redes neurais artificiais são metodologias de processamento paralelo e conhecimento distribuído baseadas no processamento do neurônio biológico e nas redes neurais humanas (HAYKIN, 2001). Esta ferramenta é aplicada em diversos tipos de problemas e apresentam boas práticas na classificação de padrões. Dentre elas destaca-se a rede PMC que tem sua topologia organizada em camadas conforme apresentada na Figura 9. Esta rede é composta de camada de entrada, saída e com a presença de uma ou mais camadas escondidas. Essa estrutura garante a extração e armazenamento de conhecimentos associados a alguma aplicação específica (SILVA; SPATTI; FLAUZINO, 2010).

Neste tipo de rede o fluxo de dados segue uma única direção, isto é, existem apenas ligações entre as saídas dos neurônios de um nível para as entradas dos neurônios de um nível subsequente, não existindo conexões entre os elementos de um mesmo nível como é apresentado na

Figura 9. Na referida figura, observa-se que um vetor de entrada fornece as informações aplicadas aos neurônios da camada de entrada. Os sinais de saída são então apresentados a cada camada posterior e assim sucessivamente até a saída de RNA. Os elementos da rede podem ser identificados como: x_n que representa a n -ésima entrada da RNA; ω_{mn} que representa os pesos sinápticos dos n neurônios das m camadas da rede e y_n que representa a n -ésima saída da RNA.

Figura 9: Exemplificação da rede perceptron multicamadas

De acordo com Silva, Spatti e Flauzino (2010) estas estruturas podem ser representadas matematicamente, permitindo então a sua implementação computacional. Considerando os elementos descritos na Figura 9 estabelece-se que o modelo matemático de uma rede do tipo PMC é apresentado pelas equações (9) e (10).

$$I_m = \sum_{i=1}^n \omega_{mi} x_i \quad (9)$$

$$y(I_m) = f(I_m) \quad (10)$$

O termo I_m representa os vetores intermediários de entrada da camada subsequente até a m -ésima camada da RNA, onde a resultante da saída da camada anterior é ponderada pelos pesos sinápticos ω . O elemento $y(I_m)$ é o vetor de saída das camadas intermediárias, determinado pela aplicação da função de ativação f do neurônio aos elementos de entrada da camada anterior.

As saídas da rede y_n é a resultante da aplicação da Equação (10) na última camada. Os sinais provenientes desta saída podem ser utilizados diretamente ou tratados de acordo com a necessidade da aplicação.

O treinamento de uma RNA pode ser subdividido em supervisionado ou não supervisionado (SILVA; SPATTI; FLAUZINO, 2010), onde o treinamento supervisionado *backpropagation* é aplicado aos modelos deste trabalho e consiste no ajuste dos seus pesos sinápticos até que um conjunto de dados de entrada produza uma saída desejada. Este procedimento chega aos critérios de parada de treinamento por meio da determinação do Erro Quadrático (E_q) e Erro Quadrático Médio (E_{qm}) entre o sinal de entrada e a resposta desejada e é baseado no apresentado por Haykin (2001), Silva, Spatti e Flauzino (2010).

3.4.2 k -nn

A regra de classificação dos k -Nearest Neighbor é um método baseado na aprendizagem por analogia ou similaridades entre as amostras de teste com as amostras de treinamento pré-rotuladas (HAN; KAMBER; PEI, 2011). O algoritmo k -nn procura estabelecer um espaço padrão entre as k amostras de treinamento próximas à amostra desconhecida. Estes k elementos de treinamento são os k -vizinhos mais próximos como é exemplificado na Figura 10

Figura 10: Exemplificação da classificação por k -nn

Considerando um conjunto de treinamento X , de m atributos, cada amostra deste fica alocado em um ponto no espaço m dimensional. O classificador calcula a proximidade entre os elementos pela distância euclidiana dada pela Equação (11), onde $P = (p_1, \dots, p_m)$ é uma amostra a ser classificada comparada ao padrão $Q = (q_1, \dots, q_m)$ elemento do conjunto de treinamento X , ambos m -dimensionais, onde cada dimensão determina uma característica;

$$D(P, Q) = \sqrt{\sum_{i=1}^m (p_i - q_i)^2} \quad (11)$$

Assim, o algoritmo é capaz de verificar e associar a qual classe de X pertencem a amostra P pela predominância dos k padrões mais próximos. Estes k conjuntos de treinamento são os k -vizinhos mais próximos deste conjunto desconhecido. O classificador cria as fronteiras de decisão complexas da seguinte maneira:

1. Calcula-se a distância métrica de cada elemento X para todos os outros elementos do padrão de treinamento conforme a distância métrica entre os termos. Essa distância pode ser dada por exemplo pela distância euclidiana apresentada na Equação (11);
2. Verifica quais classes pertencem os X_n padrões mais próximos;
3. Classifica-se associando o padrão de teste à classe que for predominante.

Como vantagem desse método cita-se a criação de uma superfície de decisão que se adapta à forma de distribuição dos dados de treinamento de forma detalhada. Tomando-se $k = 1$, obtém-se um classificador preciso e com boas taxas de acerto, mas sujeito a interferências por pequenas variações nas amostras. Entretanto, a vizinhança k pode ser acrescida, criando regiões maiores de hiperplanos com generalização de dados, uma vez que sejam aceitas diminuições de precisão.

3.4.3 Support Vector Machines - SVM

A técnica SVM é um método de aprendizagem supervisionada treinado com um algoritmo de otimização matemática que implementa um limite derivado da teoria de aprendizagem estatística (GODOY, 2016).

Utilizado para classificação ou para regressão, essa estratégia de aprendizagem desenvolvida por Vapnik (1995) pode ser formulada como um otimizador de programação quadrática para determinar o valor ótimo. Esta estratégia alcança alto desempenho em aplicações práticas na classificação de falhas em máquinas elétricas como pode ser visto no trabalho de Martínez-Morales, Palacios-Hernández e Campos-Delgado (2016).

Nas aplicações que requerem a aprendizagem de duas classes distintas, o objetivo do SVM é encontrar a melhor função que permita a distinção entre os membros de um conjunto de treinamento D composto por x_i, y_i , onde $x_i \in \mathfrak{R}$ é uma representação vetorial de uma amostra i em $y_i \in -1, 1$ sua correspondente classe linearmente separável. Tal proposição é exemplificada na Figura 11

Figura 11: Exemplificação de classificação por SVM

Uma função de classificação linear, que separa as duas classes, pode ser determinada pela Equação (12) que corresponde a um hiperplano separador e que possui margens denominadas de vetores suportes representadas pela Equação (13).

$$x_i \cdot w + b = 0, i = 1, 2, \dots, D \quad (12)$$

$$\begin{cases} y_i(x_i \cdot w + b) - 1 \geq 1 \\ y_i(x_i \cdot w + b) - 1 < -1 \end{cases} \quad (13)$$

Tem-se nesta equação que x_i representa um vetor com os padrões de entrada de treinamento, w é o vetor normal ao hiperplano de vetor de pesos ajustáveis e b é o limiar que corresponde à distância do hiperplano em relação à origem.

O algoritmo SVM tem-se mostrado uma ferramenta promissora na classificação de falhas em máquinas elétricas como pode ser visto nos trabalhos de Tran et al. (2013a), Godoy et al. (2016), Palácios et al. (2016) e Martínez-Morales, Palacios-Hernández e Campos-Delgado (2016).

3.4.4 Árvores de decisão

O sistema de árvore de decisão C4.5 foi proposto por Quinlan (1993) onde o algoritmo seleciona as características mais significativas para classificar o conjunto de dados. A técnica de processamento caracteriza-se por utilizar a estratégia de divisão e conquista. As árvores de decisão classificam instâncias ordenando-as de um ponto conhecido como raiz até um determinado nó-folha, o qual designa a classificação da instância em causa como pode ser visto na Figura 12 como exemplo.

Figura 12: Exemplificação da classificação por C4.5

Sendo assim, um problema considerado complexo é dividido em problemas mais simples e recursivamente aplicado na mesma estratégia de divisão. Cada nó na árvore especifica um determinado atributo, enquanto cada ramo descendente corresponde a um possível valor para o atributo, dividindo a problemática recursivamente, como pode ser visto em aplicação para classificação de falhas em MIT no trabalho de Aydin, Karakose e Akin (2014).

Por meio do cálculo do ganho de informação, em comparação à entropia, ordena-se as instâncias de um ponto conhecido como raiz até um determinado nó-folha. Exemplificando, um conjunto X de treinamento com m classes $(C_1, C_2, \dots, C_m)$ onde é estabelecida a entropia da in-

formação do nó $E(x)$ pela Equação (14) tem-se $|X|$ casos em X e $f(C_i, X)$ casos C_i pertencentes à X .

$$E(X) = - \sum_{i=1}^m \frac{f(C_i, X)}{|X|} \log_2 \left(\frac{f(C_i, X)}{|X|} \right) \quad (14)$$

Para selecionar as características Z , o conjunto de treinamento é classificado em n subconjuntos $(S_1, S_2, \dots, S_n)$, sendo a entropia de informação esperada $I_e(X, Z)$ calculada pela Equação (15), onde o S_j é o número de casos.

$$I_e(X, Z) = - \sum_{j=1}^n \frac{|S_j|}{|X|} I(S_j) \quad (15)$$

Essa estrutura de classificação de dados é capaz de evitar *overfitting* dos dados e determina o quanto deve crescer uma árvore de decisão. Ainda, são desafios desta metodologia reduzir o erro da poda da árvore, introduzir a regra de pós-poda, manusear atributos contínuos, escolher uma medida de seleção de atributos adequados, manipular dados de treinamento com valores de atributos que faltam e melhorar a eficiência computacional (PALÁCIOS, 2016).

Para selecionar as características Z , o conjunto de treinamento é classificado em n subconjuntos $(S_1, S_2, \dots, S_n)$, sendo a entropia de informação esperada calculada pela Equação (15), onde o S_j é o número de casos.

3.4.5 Naive Bayes - NB

Os métodos *Bayesianos* utilizam resoluções de problemas por probabilidade de acerto, que são utilizados na tomada de decisões. O algoritmo estabelece a probabilidade que uma amostra desconhecida tem em pertencer a cada uma das classes possíveis, predizendo a classe mais provável (JOHN, 1995). Uma exemplificação gráfica é mostrada na Figura 13

Figura 13: Exemplificação da classificação por NB

A maior probabilidade P de uma instância Y pertencer a uma classe Z é determinada pela Equação (16) onde o resultado vai indicar a classe a que essa instância pertence. Sendo $P(Z|Y)$ a probabilidade a *posteriori* de Z condicional a Y :

$$P(Z|Y) = \frac{P(Z|Y)P(Z)}{P(Y)} \quad (16)$$

Um classificador de *Bayes* pode ser composto por um grafo dirigido em que cada nó representa uma variável aleatória. Então, cada regra prevê a classe mais provável para um dado exemplo, baseado na distribuição (assumida como sendo conhecida) do conjunto de dados considerado.

Este tipo de predição é estatística, pois é completamente baseada em probabilidades. Assim, esse método associa uma probabilidade a cada previsão, o que representa o nível de confiança do classificador na resposta final (JOHN, 1995).

3.5 MÉTRICA DE AVALIAÇÃO DE CLASSIFICADORES

Para poder compreender dentre os cinco classificadores estudados quais suas características, pontos positivos e negativos, bem como a dinâmica das respostas, é necessário que sejam definidas métricas de avaliação. Mesmo não sendo foco desta pesquisa a avaliação recursiva dos classificadores, nem mesmo a determinação de novas metodologias ou métricas de análise de desempenho dos SI.

A seguir, estão apresentadas as métricas de avaliação e conceitos comumente usados para análises comparativas entre classificadores. Os parâmetros presentes em Kohavi e Provost (1998) fazem parte de uma série de indicadores estatísticos e são utilizados para compreender e subsidiar as discussões fundamentadas em desempenho individual de cada classificador. Também são descritas as equações e modelos que são aplicados pela plataforma WEKA para estabelecer cada índice de desempenho.

3.5.1 Acurácia

A acurácia é definida como a taxa de predições corretas feitas pelo modelo sobre um conjunto de dados e pode ser determinada pela Equação (17), sob a perspectiva que P representa todos os positivos (elementos pertencente a determinada classe) e N todos os negativos (elementos não pertencente a determinada classe) (CARVAJAL et al., 2015).

$$Sens = \left(\frac{VP + VN}{P + N} \right) \quad (17)$$

Definindo-se que VP indica o número de elementos verdadeiros positivos (classificados corretamente como positivos); VN indica o número de verdadeiros negativos (classificados corretamente como negativos). Esta relação de estimativa com seus parâmetros ou valores verdadeiros é realizada com um conjunto de testes que não foi empregado no processo de aprendizagem.

No caso da abordagem adotada por esta proposta aplica-se ainda, pela plataforma WEKA, a técnicas de estimativa de precisão mais complexas conhecida como a validação cruzada ou *k-fold*. Este método consiste em dividir o conjunto total de dados em k subconjuntos particulares e do mesmo tamanho. Empregando $k - 1$ subconjuntos para estimação dos parâmetros e 1 subconjunto destacado para cálculo da acurácia do modelo (FRANK; HALL; WITTEN, 2016).

Este processo é realizado k vezes alternando o subconjunto de teste até que todos sejam usados para cálculo da acurácia. Então, ao final das k iterações, calcula-se a acurácia sobre os erros encontrados e a média dos valores de cada interação é adotada como índice de modelo classificador.

3.5.2 Coeficiente *kappa*

O apontamento do coeficiente *kappa* ou *kappa statistic* estabelece a relação entre o resultado esperado e o resultado estimado para a saída de cada classificador (EUGENIO; GLASS, 2004). Apresentado na Equação (18) define a concordância entre o valor de resposta do classificador (VR) e o valor esperado ou referência (VE).

$$Sens = \left(\frac{VR - VE}{1 - VE} \right) \quad (18)$$

Quanto mais próximo está de um valor unitário, mais os valores estimados correspondem aos reais. Fornecendo assim uma expressão do quanto as observações se afastam das referências e indicando quão verdadeira é a interpretação dos dados (VIERA; GARRETT, 2005). O índice *kappa* estipula o sucesso do classificador desconsiderando os acertos ao acaso.

3.5.3 Sensibilidade e especificidade

Uma análise percentual de desempenho, que embasa os resultados preditores em classificadores, está na utilização da sensibilidade e especificidade.

A sensibilidade, determinada pela Equação (19), demonstra a capacidade do modelo classificar um indivíduo de forma correta segundo uma determinada classe, apresentando em si o percentual de verdadeiros positivos (VP) em face no número de VP acrescidos dos positivos classificados erroneamente, ou seja, os Falsos Negativos (FN).

$$Sens = \left(\frac{VP}{VP + FN} \right) \times 100 \quad (19)$$

Complementarmente, pode-se analisar a especificidade que é apresentada na Equação (20), onde avalia-se a capacidade do modelo predizer um indivíduo na classe concorrente, ou seja, os verdadeiros negativos (VN) pelo somatório de VN com o número de elementos classificados erroneamente para outra classe (Falsos Positivos (FP)).

$$Espc = \left(\frac{VN}{VN + FP} \right) \times 100 \quad (20)$$

3.5.4 Erro absoluto médio

O erro absoluto médio conhecido da sigla em inglês *Mean Absolute Error* (MAE) é a média dos módulos da diferença entre os valores fornecidos pelo classificador e o valor da resposta esperada. Pode ser calculada utilizando a Equação (21) na qual N representa o número total de amostras, $\hat{x}_i$ é o valor fornecido pelo classificador para a i -ésima amostra e x_i é o valor de referência da amostra ou valor real.

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{x}_i - x_i| \quad (21)$$

Ao fazer uma análise de desempenho observando apenas o erro absoluto, ou seja, a diferença direta entre a resposta obtida com a resposta desejada, pode-se incorrer numa avaliação tendenciosa ou inverídica. Erros individuais positivos e negativos de mesma magnitude se cancelam em um somatório. Assim, a média dos erros absolutos apresenta uma sistemática que evita este problema ao tratar essa diferença em módulo.

3.5.5 Raiz quadrada do erro quadrático médio

O erro quadrático médio ou em inglês *Mean Squared Error* (MSE) foi proposta por *Gauss* como uma medida estatística padrão de dispersão, que leva em consideração a tendência do classificador. Essa medida, em um grupo com o número de amostras grande, pode ser definida como a média da diferença entre um valor observado ($\hat{x}_i$) e sua respectiva referência (x_i).

Entretanto, ao aplicar a raiz quadrada ao somatório destas diferenças também ao quadrado, como é visto na Equação (22), é possível estabelecer uma medida análoga à variância. Esta abordagem do índice da raiz quadrada do erro quadrático médio, também chamado em inglês de *Root Mean Squared Error* (RMSE), é utilizada para estimar a qualidade de um classificador por meio de um desvio padrão amostral generalizado (CARVAJAL et al., 2015).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{x}_i - x_i)^2} \quad (22)$$

Como os erros são elevados ao quadrado antes da média, a análise atribui um peso relativamente alto a erros grandes. Mesmo onde as médias de erro permanecem baixas o índice do RMSE aumenta à medida que a variância associada à distribuição dos resultados pode aumentar.

3.6 CONCLUSÃO DO CAPÍTULO

Este capítulo apresentou a concepção geral das metodologias tradicionais empregadas para a detecção de falhas em motores elétricos explanando sucintamente os aspectos e as características da análise pela assinatura da corrente do motor. Esta estratégia com modelagem matemática e equacionamento das falhas em discussão consiste no pilar metodológico para criar a base dos dados a ser compilado e apresentado aos algoritmos classificadores inteligentes.

É apresentada ainda uma visão concisa sobre os classificadores inteligentes direcionando a uma concepção geral de cada uma das metodologias de processamento de sistemas inteligentes abordadas neste trabalho. Os aspectos de funcionamento e equacionamento básico, bem como modelos genéricos de tratamento de dados são demonstrados a fim de exemplificar sua aplicabilidade como classificadores de padrões de falhas em MIT a ser tratado no Capítulo 4.

Por fim, são descritas métricas de avaliação de modelos classificadores através da análise de erros que servirão de base para comparativo entre os classificadores inteligentes de padrões.

.

METODOLOGIA DE INJEÇÃO DE SINAL HARMÔNICO DE REFERÊNCIA DE BUSCA

É visto que os sistemas de diagnóstico de falhas podem optar por métodos não-invasivos durante a aquisição dos dados para análise de falhas, como apresentado no Capítulo 3. Com isso, técnicas diferentes são desenvolvidas tanto para coleta de informações como para o tratamento e interpretação das respostas. Dentre estas, destacam-se as abordagens que utilizam sistemas inteligentes, que são o foco desta proposta.

Segundo Santos, Silva e Suetake (2012a), uma das principais vantagens no uso de sistemas inteligentes consiste na implementação com baixa complexidade computacional, pois são capazes de determinar o tipo de uma falha num MIT sem necessitar de modelos matemáticos de equacionamento complexo. Nos trabalhos relacionados de Suetake (2012) e Araujo et al. (2010) são apresentadas propostas de RNA aplicadas à identificação dos vários tipos de falhas encontradas no MIT. Ainda, no trabalho de Samanta e Al-Balushi (2003) e Gongora et al. (2013) esta técnica é destinada à determinação da falha no rolamento.

Nos trabalhos de Godoy et al. (2016) e Palácios et al. (2016) são apresentados estudos relativos à multiclassificação de falhas elétricas e mecânicas em MITs com abordagens para extração de características no domínio do tempo. Estas estratégias consistem na apresentação direta da amplitude dos sinais senoidais para os sistemas classificadores de padrões. Tais proposições utilizam a subamostragem da senóide como entrada dos agentes que se mostra capaz de identificar as assinaturas de falhas presentes na corrente elétrica.

Esse trabalho busca o aperfeiçoamento de resultados de classificação de falhas em MIT alimentados por inversores de frequência com a utilização de sistemas multiclassificadores inteligentes. Neste caso, o pré-processamento dos sinais de corrente de alimentação da máquina para extração das características de falhas e sua severidade é realizado no domínio da frequência. Ainda, a metodologia é testada em várias frequências de operação e cargas mecânicas aplicadas ao eixo do motor.

4.1 METODOLOGIA PROPOSTA

A metodologia proposta pretende utilizar de infraestrutura já existente de controle de máquinas com inversores de frequência industriais em que possam ser adicionadas rotinas de monitoramento e classificação de falhas. Esta rotina baseia-se na inserção de sinais harmônicos conhecidos para observação por modelos de SI. Assim, tornar-se-á possível determinar o estado do funcionamento, as falhas presentes, bem como o estado de degradação da máquina sem grandes alterações na estrutura de acionamento já instalada.

Esta estratégia não necessita da retirada da máquina de operação ou interferência no processo do qual faz parte. Também, não é impeditivo a esquematização e implementação de novas instalações a fim de prover os recursos necessários para o funcionamento da proposição inicial.

O esquemático geral da proposta é apresentado na Figura 14 onde é possível observar que a tensão modulada com a frequência de funcionamento mais a frequência de componente harmônica do Sinal Harmônico de Referência de Busca (SHRB) alimentará a máquina. O sinal de corrente distorcido é medido pelos sensores de corrente e processado no fluxo *online* de análise dos dados por um computador ou processador embarcado. Este mesmo computador é quem executa o controle da inserção dos SHRB e quem realiza as rotinas de classificação pelos SI.

Figura 14: Esquemático proposto

A aplicabilidade desta abordagem foi realizada na bancada de ensaios do Laboratório de Sistemas Inteligentes da Universidade Tecnológica Federal do Paraná - Cornélio Procópio, que é apresentada na Figura 15. Esta bancada foi usada nos trabalhos de Palácios et al. (2015), Palácios (2016), Palácios et al. (2016), Godoy et al. (2014), Godoy et al. (2015), Godoy et al. (2016), Lopes et al. (2016) e Bazan et al. (2017).

Figura 15: Bancada de ensaios

Neste trabalho utiliza-se um hardware dedicado com um software embarcado, baseado num kit de DSP - Processamento Digital de Sinais da *Texas Instruments*® modelo *TMS320C2000*TM e processador *F28335 Delfino*TM. Este equipamento realiza a modulação e o sequenciamento de chaves que são aplicados pelo inversor de frequência trifásico do modelo *PS-3 Semikron SKS 80F* com potência nominal de 22 kW. A referida bancada de ensaios é apresentada na Figura 15.

Nesta composição tem-se a possibilidade de emular as condições de funcionamento dos motores, como a variação de carga e a inclusão de defeitos controlados. As variações das condições de operação de velocidade ocorrem por meio do inversor de frequência trifásico modulando o sinal de alimentação trifásica com frequência de chaveamento de 10kHz, tensão nominal de linha de 220 V na frequência de 20 Hz a 60 Hz para o motor de 1 cv.

O próprio módulo inversor de frequência utilizado na alimentação do motor é empregado para injetar as frequências harmônicas de referência de busca com amplitudes reduzidas em um intervalo curto de tempo, estabelecido heurísticamente em 160 milissegundos. Esse intervalo de tempo é condizente a um número completo de ciclos da senoide modulada que permite a realização da análise por FFT. Outrossim, este intervalo reduzido tem por objetivo apenas observar a resposta da dinâmica elétrica da máquina, uma vez que não deve afetar a dinâmica mecânica.

Objetiva-se também utilizar esta técnica como uma ferramenta genérica e dispensar o conhecimento prévio da máquina, dos seus componentes, bem como as condições de operação. Assim, faz-se necessário o incremento dos testes para diversas frequências de operação do motor (20 Hz à 60 Hz) e com variação do conjugado de carga (0 à 100% T_n).

4.2 FLUXO DE INFORMAÇÃO DO PROCESSAMENTO

A estruturação de um algoritmo de inteligência computacional descrito por Marwala (2012), de forma simplificada, estabelece alguns passos de processamento para a tomada de decisão ou indicação da falhas. O referido algoritmo é composto por 3 etapas sequenciais mas distintas e neste trabalho apresenta-se uma proposta classificadora de falhas como ferramenta alternativa às tradicionais no diagnóstico de máquinas elétricas como exemplificado na Figura 16.

Figura 16: Fluxo de informação para processamento dos dados

A primeira parte da metodologia opera na interface entre o meio físico e o meio digital, considerando para tal a etapa de preparação e monitoramento dos sinais na aquisição dos dados para análise computacional. Esta etapa é realizada pela modulação dos inversores utilizando-se o DSP e uma *Data Acquisition Board* (DAQ), como placa digital de aquisição de sinais.

Nesta primeira etapa do processamento a medição dos sinais de corrente e de tensão em motores para criação de um banco de dados é executada. Os motores em estudo operam em condições normais e anormais com falhas, e as medições podem ser gravadas para interação computacional utilizando-se de hardwares de interface como placas de aquisições digitais de sinais - *DAQs*, em que a taxa de amostragem de 30.000 pontos por segundo permitem o aprofundamento dos estudos. Em laboratório utiliza-se o modelo 6221 da *National Instruments*TM, o qual apresenta 16 entradas analógicas de 16 *bits* com taxa de aquisição de 250kS/s (*kilo-sample/second*).

Numa segunda etapa são tratados os procedimentos empregados para o pré-processamento e estruturação dos dados para extração das características, que são realizados em ambiente computacional de cálculo. Os atributos e a estruturação da base de dados são assistidos no software *MatLab*[®] pela manipulações matemáticas da FFT, onde os dados são compilados e aglomerados em vetores de informações componentes de uma matriz de dados.

Na sequência, deve-se analisar os dados de acordo com a abordagem inteligente desejada. Essa etapa também é realizada em ambiente computacional de cálculo utilizando o software *Waikato Environment for Knowledge Analysis* (WEKA), o qual trata de uma coleção de algoritmos de aprendizado de máquinas para processamento de dados (HALL et al., 2009). O software contém ferramentas para pré-processamento de dados, classificação, regressão, agrupamento, regras de associação e visualização. Também é adequado para o desenvolvimento de novos esquemas de aprendizado de máquinas. O *WEKA* procede à análise computacional e estatística dos dados fornecidos a partir dos padrões encontrados gerando hipóteses para soluções.

Assim, finalizando a terceira etapa, o algoritmo de classificação de falha e estado de degradação é capaz de diagnosticar a condição de operação da máquina e assessorar na tomada de decisão do processo pela abordagem de classificadores de padrões. O resultado do processamento é apresentado ao meio físico por meio de uma Interface Homem Máquina (IHM), a qual mostra a classificação obtida pelo SI ao operador.

Finalizando o fluxo do processamento de dados, o algoritmo serve de base ao operador na tomada da decisão dos processos de manutenção culminando com a determinação da condição diagnóstica da máquina. O multiclassificador estabelece um diagnóstico da real situação da máquina avaliada indicando o seu estado (com falha / sem falha), o tipo de falha (estator / rotor) e a severidade em caso de falha (classe final).

4.3 MODULAÇÃO DO SINAL HARMÔNICO DE REFERÊNCIA DE BUSCA

Na primeira etapa da modulação utiliza-se o próprio módulo inversor de frequência de controle de velocidade e torque do MIT para emular o sinal de tensão de alimentação senoidal multiplexado com um SHRB, como exemplificado na Figura 17. O SHRB opera em uma frequência múltipla ímpar de ordem inteira da fundamental com amplitude de 10% da tensão nominal de alimentação. Este valor percentual de amplitude, estabelecido de modo empírico, foi considerado dentro de uma oscilação plausível sem ocasionar danos ao MIT ou a outros equipamentos conectados à rede.

A essência do controle escalar é estabelecer a relação constante tensão/frequência (V/f), de modo a manter o fluxo magnético máximo no entreferro também constante. A técnica de modulação utilizada neste trabalho opera desta forma e controla o inversor, em modo de malha aberta, através de sinais de modulação por largura de pulso (PWM). Mais especificamente, o

Figura 17: Modulação do Sinal Harmônico de Referência de Busca - SHRB

algoritmo de modulação usado neste trabalho é baseado no proposto por Broeck, Skudelny e Stanke (1988), onde ocorre a modulação da largura de pulso do vetor espacial (SVPWM).

A modulação ocorre no eixo de coordenadas $\alpha\beta$, sendo assim aplicada por igual às três fases da alimentação. As harmônicas de ordem inteira são injetadas uma de cada vez para que não sejam tratadas ou geradas sub-harmônicas na rede com o aumento da complexidade de entendimento e manipulação por processamento digital. O inversor opera no módulo de controle V/f constante a laço aberto.

Cada sinal modulado é empregado na alimentação da bancada de ensaios, a qual é composta por um Motor de Indução Trifásico de 1 cv acoplado a um Gerador CC que estabelece uma relação de carga no eixo da máquina simulando sua aplicabilidade em condições variadas de trabalho que também são consideradas na pesquisa. Esta bancada é monitorada em diversos aspectos e os dados são aquisitados e armazenados por meio de uma placa de aquisição de dados DAQ modelo 6221 da *National Instruments*®. Os sensores de corrente utilizados neste trabalho são fabricados pela LEM, e são do modelo LAH-25NP com frequência de corte em 200 kHz. Mas as placas de condicionamento de sinais são montadas com um filtro passa baixa de 1ª ordem de 1 kHz.

O intervalo de variação das frequências das componentes harmônicas dos Sinal SHRB é compreendido da 3ª até a 21ª ordem harmônica do sinal fundamental. Variando seu valor de acordo com a velocidade de operação do motor (frequência fundamental), adicionada com mais 10 componentes harmônicas distintas de injeção individuais a cada aquisição.

Neste caso, considerando os motores de indução convencionais, a faixa de observação das frequências SHRB tem o limite inferior abaixo da faixa de frequência de duas vezes a frequência de escorregamento que é estabelecida para as falhas de barras quebradas, como propõe Thomson e Gilmore (2003), Baccarini, Menezes e Caminhas (2010) e Zhu et al. (2014) e conforme apresentado na seção 3.3 do Capítulo 3. Também, nas mesmas referências, o limite superior da observação se encontra dentro das faixas de frequências consideradas da região de baixa inferência de outras harmônicas, como o próprio chaveamento do inversor.

Uma vez que cada SHRB é individualmente injetado na tensão de alimentação da máquina, são então gerados os sinais de corrente elétrica que devem ser estruturados em um único conjunto de amostras a ser empregado para classificação pelo SI, dando início à etapa de pré-processamento dos dados. Para tal, é executado no ambiente computacional *MatLab*[®], que gerencia o funcionamento e aquisição da DAQ, um algoritmo de extração e manipulação dos vetores de dados com a criação de um vetor amostral para cada sequência de inserção de harmônico composto pelos 11 sinais modulados. Essa manipulação consiste na transformação dos sinais do domínio do tempo em sinais de resposta em frequência pela Transformada Rápida de Fourier (FFT).

Como característica de padronização, cada FFT de um sinal senoidal acrescido SHRB dá origem a um sub-vetor de 1300 pontos onde cada ponto é a amplitude em uma frequência no espectro determinado de 1 *Hz* a 1300 *Hz*. Os sub-vetores de uma mesma amostra (*n* referências harmônicas de busca) são organizados em sequência, criando assim um único vetor amostral de 14300 pontos, ou seja, com as 10 componentes harmônicas injetadas e o sinal da frequência fundamental de funcionamento.

4.4 CONDIÇÕES GERAIS DE EXECUÇÃO DA PROPOSTA

Buscando a proximidade com a realidade do ambiente industrial e abrangência do percentual considerável de falhas a que estão sujeitos os MIT segundo Irfan et al. (2017), foram estabelecidos em laboratório as quebra de barras de rotor e o curto circuito das bobinas do estator, o que corresponde a cerca de 47% das falhas pertinentes aos MIT.

Os procedimentos metodológicos de inserção de falhas em laboratório já apresentados e validados no Capítulo 2 foram considerados nesta etapa com duas condições distintas, além de uma classe para operação sem falha que são apresentados na Tabela 2.

Tabela 2: Amostra de dados

Classe	a	b	c	d	e
Localização	sem falha	rotor	rotor	estator	estator
Tipo Falha	sem falha	2 barras quebradas	4 barras quebradas (2 – 2)	curto-circuito (3%)	curto-circuito (5%)
Número Instâncias	240	120	120	120	120
Frequência Operação	20Hz a 60Hz	20Hz a 60Hz	20Hz a 60Hz	20Hz a 60Hz	20Hz a 60Hz
Torque Carga	0,5 a 4Nm	0,5 a 4Nm	0,5 a 4Nm	0,5 a 4Nm	0,5 a 4Nm

Nesse etapa, a metodologia de inserção do SHRB e processamento dos dados foi completa, como descrito na Seção 4.1, em que utiliza-se o hardware dedicado DSP na modulação e sequenciamento de chaves aplicados pelo inversor de frequência trifásico na referida bancada de ensaios.

O processamento dos sinais a que se refere este processo também é desenvolvido conforme o exposto anteriormente neste trabalho. A bancada é monitorada em tensão de linha, corrente

de fase, torque mecânico e velocidade. Já a aquisição dos sinais para armazenamento e processamento ocorre por meio de uma placa de aquisição de dados *DAQ* modelo 6221 da *National Instruments*®. A taxa de aquisição foi estabelecida em 30.000 pontos por segundo, com tempo de aquisição definido em 2 segundos com o motor operando em regime e não havendo transitórios de carga ou de velocidade. Dentro deste tempo de 2 segundos de aquisição há a inserção da componente harmônica do SHRB com duração de 160 ms.

4.4.1 Resultados de avaliação PMC

O software WEKA permitiu a parametrização de variadas topologias para buscar um modelo e verificar a acurácia do mesmo. Para esta proposta foi utilizada uma rede com 15 neurônios na camada de entrada, uma camada intermediária com 10 neurônios e uma camada de saída com 5 neurônios. Foi estabelecido ainda o passo de aprendizagem de 0,03 e o termo momentum 0,2 para o algoritmo de aprendizagem otimizado de *Levenberg Marquardt*.

Foram utilizadas as 720 matrizes completas dos sinais amostrados e montadas conforme o descrito anteriormente. Assim, cada amostra apresentada para a rede tem 14301 pontos em uma estrutura de $M = [14301 \times 720]$. São 1300 pontos amostrados da *FFT* em sinais distintos de cada corrente de fase, sendo 120 composições de espectros para cada falha e 240 composições de espectros sem falhas.

A classificação correta destas matrizes de validação atingiram índices de 98,19%, como pode ser visto na Tabela 3. A classificação ocorreu na presença de não falhas ou falha e com o tipo de falha e estado de degradação. Cada neurônio da camada de saída assume uma classe distinta.

Tabela 3: Resultado final da classificação pelo algoritmo PMC

Final Algoritmo PMC	
Estrutura de Camadas/Neurônios	15-10-5
Instâncias amostradas	720
Atributos das Instâncias	14301
Tipo de Validação	Cruzada
Índice de Validação	10
Percentual de Classificação	98,19%
Classificações Incorretas	13

Das topologias propostas a PMC é a que mais demanda tempo de máquina em processamento e treinamento dos modelos, mas alcança um percentual de acerto maior que 98%. A determinação da topologia ocorre de forma heurística e outras composições foram testadas não gerando modelos válidos pelo software por limitação de hardware e tempo de processamento como é descrito no Apêndice A. Porém, resultados válidos com estrutura de números de neurônios diferentes são apresentados e discutidos.

4.4.2 Resultados de avaliação k -nn

A regra de classificação dos *k-nearest neighbor* é um método baseado na aprendizagem por analogia ou similaridades entre as amostras de teste com as amostras de treinamento pré rotuladas.

A estruturação aplicada a este algoritmo, como apresentada na Tabela 4, foi determinada para uma vizinhança de $k = 1$ com 10 dobras de validação cruzada. Divide-se o conjunto amostral em 10 subconjuntos, sendo 9 usados para treinamento e 1 para teste e repetido por 10 vezes com a inversão dos conjuntos.

Tabela 4: Resultado final da classificação pelo algoritmo k -nn

Final Algoritmo k -nn	
Índice de Vizinhança	1
Instâncias amostradas	720
Atributos das Instâncias	14301
Tipo de Validação	Cruzada
Índice de Validação	10
Percentual de Classificação	100%
Classificações Incorretas	0

O algoritmo é capaz de verificar e associar a qual classe de dados pertencem uma determinada amostra pela predominância dos k padrões mais próximos. Usando a metodologia com a proximidade $k = 1$ vizinho mais próximo o algoritmo proporcionou resultado 100% correto em classificação.

4.4.3 Resultados de avaliação SVM

A técnica SVM é um método de aprendizagem supervisionada treinado com um algoritmo de otimização matemática que implementa um limite derivado da teoria de aprendizagem estatística.

Utilizado para classificação ou para regressão formulado como um otimizador de programação quadrática para determinar o valor ótimo, esta estratégia alcança alto desempenho em aplicações práticas na classificação de falhas em máquinas elétricas como pode ser visto neste trabalho onde atinge 100% de acerto. Outros aspectos da abordagem também são apresentados na Tabela 5.

4.4.4 Resultados de avaliação C4.5

A abordagem classificadora por árvore de decisão foi aplicada mantendo-se a proposta do universo amostral de dados de entrada anteriormente citado na utilização do software *WEKA*. A estruturação aplicada a este algoritmo é apresentada na Tabela 6.

Tabela 5: Resultado final da classificação pelo algoritmo SVM

Final Algoritmo SVM	
Instâncias amostradas	720
Atributos das Instâncias	14301
Tipo de Validação	Cruzada
Índice de Validação	10
Percentual de Classificação	100%
Classificações Incorretas	0

Tabela 6: Resultado final de classificação pelo algoritmo C4.5

Final Algoritmo C4.5	
Instâncias amostradas	720
Atributos das Instâncias	14301
Tipo de Validação	Cruzada
Índice de Validação	10
Percentual de Classificação	93,61%
Classificações Incorretas	46

Nesta abordagem foram estabelecidas duas metodologias distintas, em que a árvore pelo sistema de poda convencional do software obteve um tamanho de 29 ramificações em 15 folhas e 14 nós, tendo os valores correspondentes ao percentual de acerto apresentados anteriormente na Tabela 6.

Esta abordagem inteligente apresentou índices de acerto menores que os demais classificadores de padrões com mais de 93% de acerto das 720 instâncias amostradas. Dentre as 46 instâncias classificadas erroneamente, obteve-se 14 falsos positivos e 25 falsos negativos.

Uma proposição com alteração no parâmetro de poda ou redução do erro de poda pela entropia obteve um modelo de árvore de decisão menor que é tratado no Apêndice A como modelo alternativo ao presente SI.

4.4.5 Resultados de avaliação NB

Os métodos Bayesianas utilizam uma tabela de probabilidade na tomada de decisões. Esta estratégia tem como objetivo estabelecer a probabilidade que uma amostra desconhecida pertença a cada uma das classes possíveis, predizendo a classe mais provável. O algoritmo classificador inteligente Naive Bayes seguiu a aplicação das demais abordagens no que tange o universo amostral no software *WEKA* e a estruturação aplicada a este algoritmo é apresentada na Tabela 7.

Nesta proposta o algoritmo SI apresentou uma tabela de probabilidade das 5 classes distintas com 8 atributos, gerando o resultado de 96,11% de acerto com 28 instâncias classificadas incorretamente.

Para uma avaliação das variações nas condições de operação é proposto o aumento da reso-

Tabela 7: Resultado final de classificação pelo algoritmo NB

Final Algoritmo NB	
Instâncias amostradas	720
Atributos das Instâncias	14301
Tipo de Validação	Cruzada
Índice de Validação	10
Percentual de Classificação	96,11%
Classificações Incorretas	28

lução dos valores da tabela ou estimador de *kernel*, sendo esta variação descrita com resultados no Apêndice A.

4.5 DISCUSSÕES E RESULTADOS

Utilizando-se da base de dados montada para esta proposta, uma série de indicadores de desempenho dos classificadores é obtida. Com a análise dos resultados dos cálculos e a comparação dos índices das respostas que o software WEKA retorna para o operador é possível indicar qual classificador demonstra maior capacidade de classificação de falha em cada situação distinta. Ainda são ressaltadas algumas particularidades da observação.

A seguir são apresentados os resultados para classificação múltipla ou severidade baseada nos indicadores de erro. Também são vistos os índices de uma abordagem de classificação simples de presença ou não de falha. Além de uma análise que pode se traduzir como confiabilidade pela evolução do desempenho de cada classificador.

Por fim, são tratados os índices encontrados nesta tese e correlacionados a trabalhos da área em comparação direta de acurácia por tipo de classificador inteligente.

4.5.1 Classificador de severidade

A descrição sucinta dos resultados é consolidada e apresentada na Tabela 8, em que se comparam os melhores percentuais de classificação assertiva de cada classificador inteligente para o mesmo padrão de dados. Alternativas e variações dos modelos são descritos no Apêndice A, a fim de demonstrar a estruturação e parametrização dos SI e justificar a aceitação desses resultados abaixo apresentados.

As cinco propostas resultaram na classificação com acertos de 93% à 100% conforme é apresentado na Tabela 8, sendo que estes percentuais de acerto se baseiam na classificação das instâncias em 5 classes distintas que são separadas tanto em tipo de falha como em intensidade de degradação.

Ainda na Tabela 8, são denotados alguns coeficientes e índices de erros comumente utilizados para avaliação comparativas entre classificadores, sendo eles os seguintes: i) MAE,

conhecida por Erro Médio Absoluto; ii) RMSE, também chamado de Erro Quadrático Médio; e iii) *kappa statistic*.

Tabela 8: Resultados comparativos entre os SI

SI	PMC	<i>k - nn</i>	SVM	C 4.5	NB
Número Classes	5	5	5	5	5
Número Instâncias	720	720	720	720	720
Instâncias Incorreta	13	0	0	46	28
Instâncias Corretas	707	720	720	674	692
% Classificação	98,19	100	100	93,61	96,11
MAE	0,063	0,002	0,001	0,027	0,015
% RMSE	0,119	0,003	0,002	0,158	0,123
Kappa	0,976	1	1	0,917	0,950

As abordagens dos algoritmos *k-nn* e *SVM* obtiveram 100% de acerto, enquanto as demais abordagens obtiveram índices superiores à 93% para *C4.5*, 96% para *NB* e 98% para *PMC*.

O apontamento apresentado no coeficiente *kappa statistic* mostra a relação entre o valor verdadeiro e o valor estimado para a saída de cada classificador. Quanto mais próximo o índice *kappa* estiver de um valor unitário, mais os valores estimados correspondem aos reais. Assim, mesmo nas abordagens em que o índice difere de 1 (acerto menor que 100%), não existe grande divergência nos resultados, pois todos os valores são maiores que 0,9, mostrando-se que os valores de saída dos classificadores, mesmo quando imprecisos, estão próximos aos valores verdadeiros.

Quanto aos valores dos erros médios de previsão de modelo em unidades da variável de interesse, todas as métricas são tratadas indiferentes em relação à direção dos erros, ou seja, são pontuadas e orientadas negativamente, o que significa que valores mais baixos são melhores. Sobre esta perspectiva, o índice MAE das abordagens supracitadas, principalmente no que tange às propostas que não classificam com precisão de 100%, mostra que o algoritmo *NB* se destaca entre os pares. Pode-se dizer então que o valor 0,015 de média dos erros absolutos, apresentados pelo classificador *NB*, é menor que os demais, ficando superior apenas a *k-nn*. Isso representa que para este algoritmo há uma distribuição mais coesa entre os valores classificados referenciados nos padrões apresentados.

Ao observar os resultados pela métrica RMSE, em que os erros são elevados ao quadrado antes da média, tem-se que o cálculo potencializa os erros absolutos de cada amostra. Isso significa que mesmo onde o MAE é mais baixo e o RMSE percentual pode ter valores consideráveis à medida que a variância associada à distribuição de frequência das magnitudes de erro também aumenta. Um exemplo pode ser citado nos modelos alternativos no Apêndice A. Assim, ao observar as abordagens em questão, salienta-se que o índice baixo de 0,119 para o RMSE do algoritmo *PMC* está próximo ao valor 0,123 do algoritmo *NB*, consolidando uma diferença de apenas 0,004 pontos percentuais, mesmo com as divergências em seus valores de

MAE em mais de 4 vezes, demonstrando-se que em ambas as propostas não são encontrados erros de valores acentuados.

Quando observados estes índices para os classificadores *k-nn* e *SVM* nota-se uma concordância interessante, pois tem-se 0,002 atribuído ao *k-nn* e 0,001 ao *SVM* como valor do MAE. Este índice define uma média de erros absolutos quase nula. Também para os valores atribuídos a RMSE igual a 0,003 e 0,002 para *k-nn* e *SVM* respectivamente, demonstrando uma variância quase nula em suas respostas.

Estas métricas aqui descritas também podem ser indicadores de qual é a melhor abordagem classificadora, mesmo se comparando algoritmos que atingem 100% de acerto. Colocadas lado a lado, elas representam a precisão em respostas mais justas e concisas e pode demonstrar a tendência do SI a generalizar e interpretar valores. Por exemplo, ao se comparar estes valores nas abordagens de *SVM* e *k-nn*, fica evidenciado que *SVM* tem uma ligeira vantagem em relação ao *k-nn*. Mas esta situação justifica-se pela modalidade do classificador *SVM* quando utilizando-se de função de kernel definida como função polinomial e calibrador como *LibSVM*. Estes parâmetros são melhores definidos no Apêndice A, em que resultados correlatos do *SVM* encontram-se dentro da faixa estabelecida pelos vetores e garantem a classificação em 100%, mas a saída do classificador está distante do esperado.

Isto posto, mostra uma ligeira vantagem do classificador *PMC* em relação aos classificadores *C4.5* e *NB*. Mesmo com a maior média dos erros absolutos ($MAE = 0,063$), tem a maior taxa de acerto e menor índice RMSE das propostas que não atingiram classificação de 100%. Enfatizando ainda que o $RMSE = 0,119$ é menor em 0,04 pontos percentuais ao $RMSE = 0,159$ do algoritmo *C4.5*, garantindo que suas respostas não apresentem erros com diferenças grandes dos valores objetivos.

4.5.2 Classificador simples

Aprofundando mais a análise de desempenho das propostas tem-se as matrizes de confusão apresentadas na Tabela 9, a qual quantifica os exemplos da base de dados utilizada nas abordagens *PMC*, *C4.5* e *NB*. A matriz de confusão nada mais é do que uma tabela que permite visualizar o desempenho do classificador com o cruzamento de informações, tendo a cada linha da matriz a classe das amostras e o quantitativo que o classificador retornou de cada categoria que é representa nas coluna. Cabe lembrar que “a” representa a classe sem falhas; “b” corresponde à classe de 2 barras quebradas do rotor; “c” representa as falhas de 4 barras quebradas (2 à 2); “d” corresponde à falha de curto-circuito de 3% do enrolamento do estator; e por fim “e” representa a falha de curto-circuito de 5%.

Pelos resultados apresentados na Tabela 8 o percentual de maior acerto entre as abordagens *PMC*, *C4.5* e *NB* está com o algoritmo *PMC*, pois classifica melhor dentre as 5 classes de falhas propostas. Se considerar ainda uma abordagem de classificação simples, presença ou não de falha, a abordagem *PMC* se destaca novamente, uma vez que não apresentou falso positivo nem mesmo falsos negativos. Isto corresponde a um percentual de acerto de 100% para a *PMC*

Tabela 9: Matrizes de confusão dos algoritmos PMC, C4.5 e NB

PMC								
a	b	c	d	e		Falso	Positivo	0
240	0	0	0	0	a	Falso	Negativo	0
0	120	0	0	0	b	Classe	Maior Erro	c
0	9	111	0	0	c	Classe	Menor Erro	d
0	0	4	116	0	d			
0	0	0	0	120	e	Sem	Erro	a,b,e

C4.5								
a	b	c	d	e		Falso	Positivo	14
226	7	6	1	0	a	Falso	Negativo	25
17	101	2	0	0	b	Classe	Maior Erro	b
6	2	110	1	1	c	Classe	Menor Erro	d
2	0	0	117	1	d			
0	0	0	0	120	e	Sem	Erro	e

NB								
a	b	c	d	e		Falso	Positivo	18
222	18	0	0	0	a	Falso	Negativo	10
0	120	0	0	0	b	Classe	Maior Erro	d
0	0	120	0	0	c	Classe	Menor Erro	a
10	0	0	110	0	d			
0	0	0	0	120	e	Sem	Erro	b,c,e

classificando de forma direta a presença de falha, enquanto o *NB* permanece com a taxa de 96,11%.

Em se tratando do sistema inteligente classificador de padrões *NB* é perceptível o padrão de erro distinto, pois classificou 18 instâncias como falso positivo, mas todas de uma única categoria sem falhas e as 10 amostras classificadas de falso negativo também são de uma mesma classe com falha de rotor com 2 barras quebradas. Em ambos os casos as classes trocadas foram as de menor grau de degradação de falha, tanto a considerada no falso positivo como as que foram desconsideradas no falso negativo.

Outra particularidade da abordagem *NB* é visível quando apresenta a classe “a” (sem falhas) como a classe de menor erro aparente e a classe “d” (2 barras quebradas) sendo apontada como a de maior classificação errada. Demonstra-se assim que a classe “d” apresenta características não muito marcantes para estas extrações de atributos ocasionando os falsos positivos. Acredita-se que tais condições podem ser contornadas com intensificações no treinamento ou mesmo na base de dados amostral. Esta é uma característica latente da abordagem *NB*, apesar de suas 28 instâncias classificadas erradas tem 18 falsos positivos e 10 falsos negativos. Não havendo erros na caracterização de falhas de estator como falhas de rotor ou vice-versa. Fato que é presente nas abordagens *PMC* e *C4.5*.

Ao observar, com estas propriedades, a matriz de confusão da abordagem *C4.5*, percebe-se ainda que em quase todas as classes (com exceção da classe “e”) houveram classificações de falsos positivos, transmitindo a necessidade de selecionar melhor os atributos de classificação e a extração de características. Outra alternativa consiste em abordar outras condições de execução como variações nos métodos de poda. Entretanto, a resposta deste SI em um contexto geral de classificação assemelha-se aos demais métodos classificadores.

Ao aplicar as análises de cunho probabilístico, que embasam os resultados preditores para

a classificação simples de falhas, pode-se utilizar dos termos de sensibilidade e especificidade. A sensibilidade para esta aplicação demonstra a capacidade do modelo classificar um indivíduo com falhas de forma correta e apresentar o percentual de verdadeiros positivos. Esta estratégia é complementada pela especificidade que avalia a capacidade do modelo predizer um indivíduo como sem falha, ou seja, verdadeiros negativos.

Valendo-se dos valores VP (Verdadeiros Positivos) os dados classificados corretamente com falhas, VN (Verdadeiros Negativos) os classificados corretamente sem falhas, FN (Falsos Negativos) os classificados incorretamente sem falhas e FP (Falsos Positivos) sendo os classificados incorretamente com falhas, cujos dados identificados na matriz de confusão apresentada na Tabela 9, tem-se os índices de sensibilidade e especificidades dos modelos classificadores *PMC*, *C4.5* e *NB* para classificação simples entre presença ou não de falhas, os quais são apresentados na Tabela 10.

Tabela 10: Índices de Sensibilidade e Especificidade para *PMC*, *C4.5* e *NB*

Algoritmo	<i>PMC</i>	<i>C4.5</i>	<i>NB</i>
Verdadeiros Positivos (VP)	480	455	470
Falsos Positivos (FP)	0	14	18
Verdadeiros Negativos (VN)	240	226	222
Falsos Negativos (FN)	0	25	10
Sensibilidade	100%	94,79%	97,91%
Especificidade	100%	94,16%	92,50%

Novamente destaca-se o algoritmo *NB* com percentual de 97,91% de realizar a classificação correta dos elementos com falhas. Porém, esta abordagem inteligente em questão apresenta o menor percentual de classificação correta para a classe de motor sem falhas visto seu índice de 92,50% de especificidade.

Neste contexto, desconsiderando o algoritmo *PMC* que como já descrito anteriormente atinge 100% na classificação simples de presença de falhas ou não, tem-se a avaliação do algoritmo *C4.5* como uma abordagem mais regular. Ambos os índices percentuais de sensibilidade e especificidade ficaram em 94% e demonstram sua predição tanto de uma classe como da outra.

4.5.3 Comparativo de desempenho por ZeroR

Uma terceira alternativa na análise de desempenho dos SI classificadores de padrões baseia-se na contraposição com o método de classificação *ZeroR*. Esse método de classificação simplista prevê a classe majoritária do problema e desconsidera os preditores. Embora não tenha a capacidade de previsibilidade, o algoritmo *ZeroR* é útil para determinar o desempenho de referência servindo de índice comparativo para os outros métodos de classificação (FRANK; HALL; WITTEN, 2016).

Em uma observação mais detalhada, o gráfico apresentado na Figura 18, demonstra o ganho percentual de cada abordagem de SI em relação ao valor de *ZeroR*, tanto para classificação

simples como para classificação em severidade.

Figura 18: Comparativo percentual de desempenho por SI

O *ZeroR* é o referencial percentual da maior classe encontrada pelo SI em relação ao número total de amostras apresentadas. Assim sendo, em uma visão simplificada, gera-se a taxa de acerto se todas as amostras fossem classificadas em uma só classe. Esta análise pode se traduzir como a confiabilidade ou grau de acerto de cada SI, determinando ainda o desempenho dos algoritmos.

O índice percentual de acerto para cada SI é incrementado se a classificação for apenas simples e não de severidade. Assim, tem-se por base o valor de *ZeroR* e um maior ganho de desempenho para a classificação de severidade pelo mesmo referencial apresentados.

4.5.4 Comparação com trabalhos correlatos

Ao proceder as análises aqui propostas e fazendo uma comparação direta com resultados apresentados por trabalhos correlatos tem-se um ganho significativo no percentual de acerto em algumas abordagens de SI com a execução da técnica de pré-processamento proposta como se observa na Tabela 11.

Tabela 11: Comparativo entre trabalhos correlatos

Referência	Falha	Classificação	Técnica	Método	Acurácia (%)
Yahia et al. (2012)	rotor	simples	FFT	MCSA	NE
Bazan et al. (2017)	estator	simples	FFT / DWT	RBF / PMC	95,82 / 99,64
Aydin, Karakose e Akin (2012)	estator e roto	simples	FFT	k-nn / SVM	86,50 / 98,85
Godoy et al. (2015)	estator	severidade	D T	SVM / PMC	76,32/85,79
Este Trabalho	estator e rotor	severidade	FFT	k-nn / SVM / PMC	100 / 100 / 98,19

Dentre os artigos apresentados na Tabela 11 a proposta deste trabalho é a única que avalia as falhas em questão da severidades para duas classificações de falhas simultaneamente, pois

tem uma classe distinta para cada categoria de falha e o grau de deterioração. Esta proposta em relação ao trabalho de Yahia et al. (2012) quantifica os resultados em acertos percentuais para a técnica similar de identificação de falhas utilizando a *FFT* em uma abordagem de *MCSA*.

No trabalho de Godoy et al. (2015) também se apresenta a classificação de severidade, porém, para sinais no domínio do tempo e com a análise de falhas restrita a presença de curto-circuito nos enrolamentos de estator. Tendo por base dois algoritmos SI classificadores semelhantes, os resultados apresentados nesta proposta superam os valores descritos em tal trabalho. A taxa de acerto de 100% em relação a 76,32% para a proposta de *SVM* e 98,19% em relação a 85,79% para a *PMC*.

Outro aspecto relevante nas comparações é a classificação de falhas de rotor e estator que também é abordado por Aydin, Karakose e Akin (2012), com taxa de acerto de 98,85% comparada a 100% para a proposta de SI de *SVM* aqui descrita. Nesse trabalho em questão, a classificação simples pelo SI *k-nn* apresenta acerto percentual de 86,50%, ficando aquém dos também 100% obtidos nesta tese.

Na comparação direta de resultados desta proposta com o trabalho de Bazan et al. (2017) o valor de 98,19% na abordagem da *PMC* fica aquém dos 99,64%. Novamente, cabe-se a ressalva da classificação em graus de severidade, pois, como tratado anteriormente, se considerar a proposta da *PMC* como um classificador simples o valor percentual de acerto para este trabalho é de 100%.

Ressaltando também o trabalho recente apresentado por Godoy (2016), tem-se a correlação na área de classificadores inteligentes de falhas em MIT com menção às máquinas acionadas por inversores de frequências. Entretanto, mesmo com a similaridade de multiclassificação de falhas, a abordagem apresentada pelo referido autor trata da observação dos sinais no domínio do tempo, enquanto que este trabalho se utiliza da análise no domínio da frequência. Esta consideração por si só já difere a empregabilidade das abordagens, uma vez que não são necessários os pré-processamentos de normalização dos sinais de alimentação de máquinas de potências distintas que são utilizados como entrada para os SI.

Salvo as particularidades na referida abordagem, observa-se a distinção e ascendência de resultados para a utilização do SHRB a fim de aumentar a confiabilidade nos classificadores inteligentes em questão, como é apresentado na Tabela 12.

Tabela 12: Resultados comparativos entre os SI

Referência SI	Este Trabalho			Godoy (2016)		
	<i>PMC</i>	<i>k - nn</i>	<i>SVM</i>	<i>PMC</i>	<i>k - nn</i>	<i>SVM</i>
Número Instâncias	720	720	720	8901	8901	8901
% Classificação	98,19	100	100	89,37	87,56	76,22
MAE	0,063	0,002	0,001	0,06	0,06	0,27
% RMSE	0,119	0,003	0,002	0,2	0,24	0,35
Kappa	0,976	1	1	0,85	0,83	0,67

Analisando de forma geral a Tabela 12 observa-se que o algoritmo *k-nn* apresenta um bom

desempenho em ambos os trabalhos. No trabalho de Godoy (2016) o percentual de acerto é de 87,56% e índice *kappa* de 0,83, sendo superado com 100% de acerto nesta abordagem e consequentemente o índice *kappa* igual a 1. Ambos os trabalhos tratam a vizinhança estabelecida em $[1 \leq k \leq 5]$.

Outro destaque que se apresenta neste comparativo está para a rede *PMC*. No trabalho de Godoy (2016), este algoritmo obtém a maior acurácia com a taxa assertiva de cerca de 90% e o índice *kappa* de 0,85. Novamente é visto a hegemonia da utilização do SHRB com o valor de desempenho que supera os 98% de acerto e *kappa* 0,976, mantendo-se os mesmos valores comparativos de erro absoluto médio e erro quadrático médio.

Um aspecto relevante das abordagens de *PMC* é encontrado na estruturação das redes neurais, uma vez que a topologia empregada por Godoy (2016) tem maior número de neurônios do que a proposta neste trabalho. O trabalho em comparação estabelece a melhor proposta de RNA com a composição de 150 entradas, uma única camada intermediária de 76 neurônios e a camada de saída com 5. Enquanto que neste trabalho a RNA tem seus valores de entrada apresentados a apenas 15 neurônios, 10 neurônios na camada oculta e os mesmos 5 neurônios na camada de saída.

Uma disparidade é vista na classificação pela abordagem *SVM* quando o trabalho de Godoy (2016) apresenta o menor percentual de acerto com 76,22%, enquanto que a atual proposta atinge os 100%.

Vale ressaltar que a abordagem apresentada por Godoy (2016), quando na multiclassificação de falhas, trabalha com as falhas de rolamento que não são abordadas neste estudo e com a utilização de máquinas acionadas por inversores distintos. Porém, a superioridade conquistada com a metodologia de inserção do SHRB subsidia a possibilidade de um bom desempenho dos classificadores inteligentes para com tal falha.

4.6 CONCLUSÃO DO CAPÍTULO

Neste capítulo foi descrito o fluxo de informação e processamento de dados, bem como a metodologia aplicada na inserção das frequências harmônicas componentes da proposta. São descritos ainda os ensaios realizados e as condições que são abordadas para o emprego do MIT nos quesitos de torque de carga e variação de frequência de alimentação. O método tradicional de identificação de falhas utilizando-se a FFT foi acrescida de uma composição de sinais harmônicos as amostras e então estruturado em uma base de dados que é apresentada aos algoritmos classificadores inteligentes de padrões.

Sequencialmente foram descritos os resultados de testes de validação, utilizando a matriz de dados com sinais injetados, para cada proposta de classificador inteligente. Ainda, foram apontados os resultados individuais e seus percentuais de acerto.

A proposta também apresentou a discussão sobre as abordagens de SI com um comparativo de desempenho entre elas em 3 perspectivas diferentes. A análise dos classificadores com

identificação de múltiplas classes são demonstrados com valores individuais de desempenho e os resultados sendo abordados para utilização como classificadores simples para a identificação da presença ou não de falha. E, finalmente, uma abordagem de desempenho entre os classificadores propostos tendo a referência o valor da classe majoritária ZeroR.

Concluindo estas análises, foram também apresentados resultados de trabalhos correlatos e comparados diretamente aos índices alcançados para os mesmo classificadores inteligentes de padrões.

CONCLUSÃO

Este trabalho apresentou um método alternativo aos convencionais para detecção de dois tipos de falhas elétricas em motores de indução trifásicos alimentados por meio de moduladores de tensão como inversores de frequência, observando e manipulando para tal as grandezas de tensão e corrente elétrica. Estes sinais foram tratados no domínio da frequência sob a ótica da análise da FFT como resposta das interações da máquina a sinais harmônicos de referências injetados juntamente com a alimentação.

Toda a abordagem foi implementada e utilizada em um modelo de classificação *off-line*, pois os dados coletados foram tratados, estruturados e classificados externamente aos módulos inversores de frequência e controle da máquina. Mas, em simples adequação, o algoritmo de controle pode conter as rotinas de averiguação e varredura para processamento e classificação das falhas em uma abordagem *on-line* ao sistema.

A avaliação das correntes estatóricas, com as frequências harmônicas de referências injetadas na alimentação dos motores, mostra-se capaz de evidenciar a existência de falhas elétricas. Em uma visão mais específica do problema busca-se a melhoria dos métodos de aquisição e especificação da falha com a evolução do algoritmo, embasado na maior capacidade de informações apresentada para processamento.

As matrizes de entradas são compostas de sinais com injeção de frequências harmônicas de referências escolhidas de forma heurística e em sequência harmônica ímpar de ordem inteira, sendo o intervalo selecionado para este trabalho compreendido por 11 sinais harmônicos entre a frequência fundamental de funcionamento, iniciando na 3ª até a 21ª frequência harmônica. Com isso, os sub-vetores amostrais no espectro da frequência, determinado de 1 Hz a 1300 Hz nas FFTs, contemplam a faixa de frequência conhecida para a identificação das falhas e permanecem dentro da faixa de frequência considerada de baixa interferência de outras harmônicas, como as do próprio chaveamento do inversor.

Os resultados práticos para os testes, com simulação controlada das falhas elétricas de quebra de barras de rotor e curto-circuito em bobina do estator, mostraram a capacidade que a técnica de inserção de sinais harmônicos de referência de busca tem ao ser empregada como ferramenta auxiliar no diagnóstico dos motores de indução trifásicos. Isto porque todas as abor-

dagens de classificadores inteligentes encontram sintonia satisfatória junto ao software WEKA e resultados de classificação condizentes.

As cinco propostas resultaram na classificação com acertos de 93% à 100%, sendo que estes percentuais de acerto se baseiam na classificação das instâncias em 5 classes distintas que são separadas tanto em tipo de falha como em intensidade de degradação. Destaca-se ainda que destas cinco abordagens, duas retornaram valor de classificação em 100% com um erro quadrático médio praticamente nulo.

Ainda, foi proposto uma análise correlata utilizando-se das mesmas respostas obtidas dos classificadores mas objetivando a classificação simples da presença ou não de falha. Nesta condição pôde-se atribuir o acerto de 100% também ao SI tipo PMC e acréscimo de 1% na taxa de acerto do classificador C4.5.

É possível observar que mediante a modulação e inserção de sinais harmônicos de referência de busca, bem como o pré-processamento de dados antes da submissão ao sistema inteligente, é alcançada uma abordagem mais simplificada de multiclassificação de falhas sem a necessidade de utilização de multi-agentes ou subclassificações sequenciais com redes em cascata.

Desta forma, a análise de falhas pelo método de inserção de SHRB e o processamento dos sinais empregados para as análises mostraram a versatilidade do método, uma vez que são obtidas respostas condizentes e satisfatórias para a classificação de falhas, salvo especificidades de cada abordagem de SI. Isso implica uma metodologia generalista que pode ser empregada adjacente a outras técnicas de classificação inteligente de falhas que não foram abordadas neste trabalho.

Os resultados individuais de cada classificador inteligente de padrões demonstraram a particularidade de cada proposta. Tais características são apontadas quando indicadores de desempenho como MAE ou RMSE apontam o classificador *PMC* em melhor relação que os classificadores *C4.5* e *NB*. Esta análise macro das propostas das abordagens de SI que não atingiram classificação de 100% é enfatizando com os índices da *PMC* melhores que os do algoritmo *C4.5*. Assim, tem-se menor variância e dispersão dos resultados mesmo com a média dos erros absolutos ligeiramente maior.

Ao se comparar estes valores de MAE ou RMSE nas abordagens de *SVM* e *k-nn*, fica evidenciado que *SVM* apresenta ligeira vantagem em relação ao *k-nn*. Entretanto, é demonstrado uma variância quase nula em suas respostas e um erro mínimo de discrepância em seus valores estimados em relação ao esperado.

Outra perspectiva dos resultados entre as abordagens *PMC*, *C4.5* e *NB* está com o algoritmo *PMC* apresentando melhor resultado dentre as propostas se considerar uma abordagem de classificação simples com a presença ou não de falha. A abordagem *PMC*, que não apresenta falso positivo nem mesmo falsos negativos, passa a operar com um percentual de acerto de 100%, enquanto o *NB* permanece com a taxa de 96,11% e mesmo com aumento para 94,58% não há superação pela proposta *C4.5*.

No viés de regularidade na classificação simples tem-se que o SI *C4.5* descreve os índices

percentuais de sensibilidade e especificidade mais coesos em 94%, demonstrando sua predição tanto de uma classe como da outra. Neste caso superam-se os 92,50% de especificidade do algoritmo *NB* que tende uma menor taxa de acerto para os sinais sem falha.

Ao proceder as análises comparativas com resultados apresentados por trabalhos correlatos, demonstra-se um ganho significativo no percentual de acerto de SI com a execução da técnica de pré-processamento proposta, onde esta metodologia tem superioridade tanto para classificação simples como de severidade em 3 classificadores distintos, sendo a única proposta a classificar severidade em duas categorias de falhas distintas pelo mesmo classificador.

Das qualidades a serem destacadas, indica-se a difusão da metodologia pela abstração que pode exercer em relação à parametrização, uma vez que não há necessidade da determinação das características do motor para indicação das faltas.

A confiabilidade da proposta como ferramenta auxiliar na classificação de falha e estimativa de grau de deterioração, independente do classificador de padrões adotado, é fundamentada pelos valores percentuais de acertos apresentados como resultados e pelo coeficiente de concordância (*kappa*) que está acima de 0,90 em todos os classificadores propostos. Também, se comparados ao referencial *ZeroR* para o universo de amostras utilizados como banco de dados, fica evidente o ganho de desempenho em mais de 27% para multiclassificação de falhas e mais 61% para classificação simples. Este fato demonstra que os classificadores de padrões abordados não são tendenciosos e não apresentam sobreajuste comumente chamado de *overfitting* nos modelos de classificadores inteligentes.

Conjuntamente, a generalização da abordagem é evidenciada nas variações de velocidade de funcionamento dos motores de 20 *Hz* à 60 *Hz*, e nas amostragens com variações de torque de carga no eixo da máquina compreendidas desde a máquina trabalhando com torque mínimo de 0,5 *Nm* até torque nominal de 4 *Nm*. Esta combinação resulta em 934 ensaios com aquisição de sinais de tensão, corrente e torque, os quais compõem o banco de dados a que cada sistema inteligente foi submetido. Ressaltando que para todas as abordagens foram utilizados os mesmos padrões de dados mesclados entre motores saudáveis e com falhas dentro das modulações citadas.

A abrangência da técnica também fica definida considerando a quantificação do grau de degradação de cada tipo de falha com 5 classes distintas em 2 categorias de falhas e 2 graus de degradação por falha proposta, considerando também que as falhas abordadas no estudo abrangem cerca de 47% das falhas a que estão submetidos os MIT em operação.

Desta forma, o trabalho também contribui com a ampliação da base amostral de sinais elétricos de motores de indução trifásicos em condições adversas de funcionamento e sobre o efeito de falhas tanto elétricas como mecânicas. Ainda, nos 934 ensaios para máquinas alimentadas por inversores de frequência, foram aquiridos mais de 6500 sinais de tensão, corrente e torque. Esta base de dados já está estruturada e compartilhada entre os Laboratórios de Automação Inteligente de Processos e Sistemas da USP (São Carlos) e o Laboratório de Sistemas Inteligentes da UTFPR (Cornélio Procópio).

Finalizando esta análise de aplicabilidade do modelo identificador de falhas, a possibilidade de trabalhar com a matriz de sinais no domínio da frequência garante ao processamento sua abordagem mais simplista pelos classificadores inteligentes e, portanto, uma facilidade de implementação e operação. A exploração de suas habilidades de generalização e confiabilidade de respostas, bem como a abrangência e abstração de parametrização, pode garantir não só a aplicabilidade como método auxiliar mas vindo também a assumir as principais funções de análise no papel da manutenção preventiva e no monitoramento *online*.

5.1 TRABALHOS FUTUROS

Cabe a exploração dos resultados para a classe de falhas de rolamento em todas as suas subclasses, o que culminaria a uma ferramenta empregada a classificar mais de 80% das falhas das máquinas elétricas rotativas de indução. Com uma abordagem dinâmica e de estruturação moderada, uma vez que são empregados os próprios equipamentos de modulação de alimentação para injeção dos Sinais Harmônicos de Referência de Busca (SHRB).

Em trabalhos correlatos como apresentado Gongora et al. (2013) vê-se que é factível a inclusão de uma Rede Neural Artificial (RNA) na classificação de falhas de rolamento em MIT, embarcada em um DSP. Portanto, em simples adequação, o algoritmo de controle dos módulos inversores pode conter rotinas de averiguação e varredura para processamento e classificação das falhas em uma abordagem *on-line* embarcada ao sistema.

Foram propostas minimizações de resolução de sinais para estruturação de matrizes de referências de entradas, mas a interferência nos resultados é imperceptível ou nula. Cabe uma investigação mais detalhada e a determinação de um método de extração de características e otimização de resultados baseado em uma análise recursiva de padrões de entrada de sinais.

Testes de robustez, como a inserção de ruídos e demais degradações de sinal não foram executados, pois não teriam finalidade no tratamento no domínio da frequência. Entretanto, podem ser considerados inserções de ruídos brancos ou distorções de amostras mediante os padrões já estabelecidos em trabalhos futuros.

5.2 PUBLICAÇÕES ASSOCIADAS

Artigo aceito em congresso

Titulo: Embedded System to Detect Bearing Faults in Line-Connected Induction Motors;
Conference: *XXIIIrd* International Conference on Electrical Machines (*ICEM'*2018).

Artigo aceito em periódico

Titulo: Reference Signal Injection in Induction Motors Drives to Electrical Failures Detection
Periódico: Journal of Control, Automation and Electrical Systems

Referências

- ABU-RUB, H.; AHMED, S. M.; IQBAL, A.; RAHIMIAN, M.; TOLİYAT, H. A. Incipient bearing fault diagnostics for inverter fed induction motor drive using anfis. In: **The XIX International Conference on Electrical Machines - ICEM 2010**. [S.l.: s.n.], 2010. p. 1–5.
- ALMEIDA, P. D. **Manutenção Mecânica Industrial – Conceitos Básicos e Tecnologia Aplicada**. [S.l.]: Editora Saraiva, 2018. ISBN 9788536515724.
- ARAUJO, R.; RODRIGUES, R.; PAULA, H. de; BACCARINI, L. Desgaste prematuro e falhas recorrentes dos rolamentos de um MIT: Estudo de caso. **9th IEEE/IAS International Conference on Industry Applications (INDUSCON)**, 2010. v. 1, p. 1–6, nov. 2010.
- ATTOUI, I.; FERGANI, N.; BOUTASSETA, N.; OUDJANI, B.; DELIOU, A. A new time frequency method for identification and classification of ball bearing faults. **Journal of Sound and Vibration**, 2017. v. 397, p. 241 – 265, 2017. ISSN 0022-460X.
- AYDIN, I.; KARAKOSE, M.; AKIN, E. An adaptive artificial immune system for fault classification. **Journal of Intelligent Manufacturing**, 2012. v. 23, n. 5, p. 1489–1499, Oct 2012. ISSN 1572-8145.
- _____. An approach for automated fault diagnosis based on a fuzzy decision tree and boundary analysis of a reconstructed phase space. **ISA Transactions**, 2014. v. 53, n. 2, p. 220 – 229, 2014. ISSN 0019-0578.
- BACCARINI, L. M. R. **Deteção e Diagnóstico de Falhas em Motores de Indução**. 207 p. Tese (Doutorado) — Universidade Federal de Minas Gerais, Belo Horizonte - MG, 2005.
- BACCARINI, L. M. R.; MENEZES, B. R. de; CAMINHAS, W. M. Fault induction dynamic model, suitable for computer simulation: Simulation results and experimental validation. **Mechanical Systems and Signal Processing**, 2010. v. 24, n. 1, p. 300 – 311, 2010. ISSN 0888-3270.
- BAZAN, G. H.; SCALASSARA, P. R.; ENDO, W.; GOEDTEL, A.; GODOY, W. F.; PALÁCIOS, R. H. C. Stator fault analysis of three-phase induction motors using information measures and artificial neural networks. **Electric Power Systems Research**, 2017. v. 143, p. 347 – 356, 2017. ISSN 0378-7796.
- BEERENDS, R.; MORSCHE, H.; BERG, J. van den; VRIE, E. van de. **Fourier and Laplace Transforms**. [S.l.]: Cambridge University Press, 2003. (Fourier and Laplace Transforms). ISBN 9780521534413.

- BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G.-A. Advances in diagnostic techniques for induction machines. **IEEE Transactions on Industrial Electronics**, 2008. v. 55, n. 12, p. 4109–4126, dez. 2008.
- BENSAOUCHE, S.; TETA, A.; AHMED, B. S.; AMEUR, A. Squirrel cage induction motor under stator and rotor bars faults modeling and diagnosis. In: . [S.l.: s.n.], 2018.
- _____. Comparative investigation of broken bar fault detectability in induction motor through fft and music techniques. In: . [S.l.: s.n.], 2019.
- BLODT, M.; GRANJON, P.; RAISON, B.; ROSTAING, G. Models for bearing damage detection in induction motors using stator current monitoring. **IEEE Transactions on Industrial Electronics**, 2008. v. 55, n. 4, p. 1813–1822, April 2008. ISSN 0278-0046.
- BROECK, H. van der; SKUDELNY, H.-C.; STANKE, G. Analysis and realization of a pulsewidth modulator based on voltage space vectors. **IEEE Transactions on Industry Applications**, 1988. v. 24, n. 1, p. 142–150, Jan 1988. ISSN 0093-9994.
- CARNERO, M. C. Multicriteria model for maintenance benchmarking. **Journal of Manufacturing Systems**, 2014. v. 33, n. 2, p. 303 – 321, 2014. ISSN 0278-6125.
- CARVAJAL, S.; CUNHA, S.; GOMES, G.; PINHEIRO, J. **Estatística Básica: A arte de trabalhar com dados**. [S.l.]: Elsevier Editora Ltda, 2015. ISBN 9788535231922.
- CHO, H. C.; KNOWLES, J.; FADALI, M. S.; LEE, K. S. Fault detection and isolation of induction motors using recurrent neural networks and dynamic bayesian modeling. **IEEE Transactions on Control Systems Technology**, 2010. v. 18, n. 2, p. 430–437, March 2010. ISSN 1063-6536.
- CHU, E. **Discrete and Continuous Fourier Transforms: Analysis, Applications and Fast Algorithms**. [S.l.]: CRC Press, 2008. ISBN 9781420063646.
- CUSIDO, J.; ROSERO, J.; ROMERAL, L.; ORTEGA, J. A.; GARCIA, A. New fault detection techniques for induction motors. **Electrical Power Quality and Utilization**, 2006. v. 2, n. 1, p. 39–46, April 2006.
- _____. New techniques for fault detection analysis by injecting additional frequency test. In: **2006 IEEE Instrumentation and Measurement Technology Conference Proceedings**. [S.l.: s.n.], 2006. p. 2087–2090. ISSN 1091-5281.
- D'ANGELO, M. F. S. V.; PALHARES, R. M.; TAKAHASHI, R. H. C.; LOSCHI, R. H.; BACCARINI, L. M. R.; CAMINHAS, W. M. Incipient fault detection in induction machine stator-winding using a fuzzy-bayesian change point detection approach. **Applied Soft Computing Journal**, 2011. v. 11, n. 1, p. 179–192, 2011.
- DAS, S.; PURKAIT, P.; KOLEY, C.; CHAKRAVORTI, S. Performance of a load-immune classifier for robust identification of minor faults in induction motor stator winding. **IEEE Transactions on Dielectrics and Electrical Insulation**, 2014. v. 21, n. 1, p. 33–44, February 2014.
- DÍAZ, I. M.; SOTELO, D. M.; DUQUE, O.; ROMERO-TRONCOSO, R. de J. An experimental comparative evaluation of machine learning techniques for motor fault diagnosis under various operating conditions. **IEEE Transactions on Industry Applications**, 2018. PP, p. 1–1, 02 2018.

EUGENIO, B. D.; GLASS, M. The kappa statistic: A second look. **Comput. Linguist.**, 2004. MIT Press, Cambridge, MA, USA, v. 30, n. 1, p. 95–101, 2004. ISSN 0891-2017.

FERNANDEZ-CAVERO, V.; SOTELO, D. M. n.; DUQUE, O.; PONS-LLINARES, J. Fault detection in inverter-fed induction motors in transient regime: State of the art. **2015 IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)**, 2015. v. 1, n. 1, 2015.

FITZGERALD, A.; KINGSLEY, C.; UMANS, S. **Máquinas Elétricas**. Porto Alegre, RS: ARTMED-BOOKMAN, 2006.

FRANK, E.; HALL, M. A.; WITTEN, I. H. **The WEKA Workbench: Data Mining Practical Machine Learning Tools and Techniques**. Fourth edition. San Francisco, CA, USA: Morgan Kaufmann, 2016. 621 p.

FROSINI, L.; BASSI, E. Stator current and motor efficiency as indicators for different types of bearing faults in induction motors. **IEEE Transactions on Industrial Electronics**, 2010. v. 57, n. 1, p. 244–251, Jan 2010. ISSN 0278-0046.

GODOY, W. F. **Multiclassificador Inteligente de Falhas no Domínio do Tempo em Motores de Indução Trifásicos Alimentados por Inversores de Frequência**. 164 p. Tese (Doutorado) — Universidade de São Paulo (USP) - Escola de Engenharia de São Carlos (EESC), São Carlos - SP, 2016.

GODOY, W. F.; SILVA, I. N. d.; GOEDEL, A.; PALÁCIOS, R. H. C.; GONGORA, W. S. Neural approach for bearing fault classification in induction motors by using motor current and voltage. In: **2014 International Joint Conference on Neural Networks (IJCNN)**. [S.l.: s.n.], 2014. p. 2087–2092. ISSN 2161-4393.

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

GODOY, W. F.; SILVA, I. N. d.; GOEDEL, A.; PALÁCIOS, R. H. C.; LOPES, T. D. Application of intelligent tools to detect and classify broken rotor bars in three-phase induction motors fed by an inverter. **IET Electric Power Applications**, 2016. v. 10, n. 5, p. 430–439, 2016. ISSN 1751-8660.

GONGORA, W. S.; SILVA, H. V. D.; GOEDEL, A.; GODOY, W. F.; SILVA, S. A. O. da. Neural approach for bearing fault detection in three phase induction motors. In: **Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED), 2013 9th IEEE International Symposium on**. [S.l.: s.n.], 2013. p. 566–572.

GRITLI, Y.; BELLINI, A.; ROSSI, C.; CASADEI, D.; FILIPPETTI, F.; CAPOLINO, G. A. Condition monitoring of mechanical faults in induction machines from electrical signatures: Review of different techniques. In: **2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)**. [S.l.: s.n.], 2017. p. 77–84.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: An update. **SIGKDD Explor. Newsl.**, 2009. ACM, New York, NY, USA, v. 11, n. 1, p. 10–18, nov 2009. ISSN 1931-0145.

- HAN, J.; KAMBER, M.; PEI, J. **Data Mining: Concepts and Techniques**. [S.l.]: Elsevier, 2011.
- HAN, T.; YANG, B.-S.; YIN, Z.-J. Feature-based fault diagnosis system of induction motors using vibration signal. **Journal of Quality in Maintenance Engineering**, 2007. v. 13, n. 2, p. 163–175, may 2007. ISSN 1355-2511.
- HAYKIN, S. **Redes Neurais Princípios e Prática**. Porto Alegre, RS: Bookman, 2001.
- HAYKIN, S.; VEEN, B. V. **Signals and Systems**. New York, NY: John Wile and Sons, Inc, 1999.
- IMMOVILLI, F.; BELLINI, A.; RUBINI, R.; TASSONI, C. Diagnosis of bearing faults in induction machines by vibration or current signals: A critical comparison. **IEEE Transactions on Industry Applications**, 2010. v. 46, n. 4, p. 1350–1359, July 2010. ISSN 0093-9994.
- IMMOVILLI, F.; BIANCHINI, C.; COCCONCELLI, M.; BELLINI, A.; RUBINI, R. Bearing fault model for induction motor with externally induced vibration. **IEEE Transactions on Industrial Electronics**, 2013. v. 60, n. 8, p. 3408–3418, Aug 2013. ISSN 0278-0046.
- IRFAN, M.; SAAD, N.; IBRAHIM, R.; ASIRVADAM, V. S. An on-line condition monitoring system for induction motors via instantaneous power analysis. **Journal of Mechanical Science and Technology**, 2015. v. 29, n. 4, p. 1483–1492, Apr 2015. ISSN 1976-3824.
- _____. Condition monitoring of induction motors via instantaneous power analysis. **Journal of Intelligent Manufacturing**, 2017. v. 28, n. 6, p. 1259–1267, Aug 2017. ISSN 1572-8145.
- ISHIZAKA, A.; NEMERY, P. Assigning machines to incomparable maintenance strategies with electre-sort. **Omega**, 2014. v. 47, p. 45 – 59, 2014. ISSN 0305-0483.
- JOHN, P. L. G. H. Estimating continuous distributions in bayesian classifiers. In: **Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence**. [S.l.: s.n.], 1995. p. 338–345.
- KAMINSKI, M.; KOWALSKI, C. T.; ORLOWSKA-KOWALSKA, T. General regression neural networks as rotor fault detectors of the induction motor. In: **2010 IEEE International Conference on Industrial Technology**. [S.l.: s.n.], 2010. p. 1239–1244.
- KIM, B.; LEE, K.; YANG, J.; LEE, S. B.; WIEDENBRUG, E. J.; SHAH, M. R. Automated detection of rotor faults for inverter-fed induction machines under standstill conditions. **IEEE Transactions on Industry Applications**, 2011. v. 47, n. 1, p. 55–64, Jan 2011. ISSN 0093-9994.
- KOHAVI, R.; PROVOST, F. Glossary of terms. **Editorial For the Special Issue on Applications of Machine Learning and the Knowledge Discovery Process**, 1998. v. 30, n. 2, p. 271–274, Feb 1998.
- KÖRNER, T. **Fourier Analysis**. [S.l.]: Cambridge University Press, 1989. ISBN 9780521389914.
- KOWALSKI, C. T.; ORLOWSKA-KOWALSKA, T. Neural networks application for induction motor faults diagnosis. **Mathematics and Computers in Simulation**, 2003. v. 63, n. 3-5, p. 435–448, 2003.

KUMAR, M. D.; KODAD, S.; SARVESH, B. Simplified fault detection algorithm for voltage source fed induction motor. **Materials Today: Proceedings**, 2018. v. 5, n. 1, Part 1, p. 1401 – 1410, 2018.

LAKEHAL, A.; RAMDANE, A. Fault prediction of induction motor using bayesian network model. In: **2017 International Conference on Electrical and Information Technologies (ICEIT)**. [S.l.: s.n.], 2017. p. 1–5.

LEME, M. O. **Metodologia de manutenção preditiva para motores elétricos baseada em monitoramento de variáveis físicas e análise multicritério**. 164 p. Tese (Doutorado) — Programa de PósGraduação em Engenharia de Produção - Universidade Tecnológica Federal do Paraná (UTFPR), Ponta Grossa - PR, 2017.

LIU, R.; YANG, B.; ZIO, E.; CHEN, X. Artificial intelligence for fault diagnosis of rotating machinery: A review. **Mechanical Systems and Signal Processing**, 2018. v. 108, p. 33 – 47, 2018. ISSN 0888-3270.

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

MABROUK, A. E.; ZOUZOU, S. E. Diagnosis of rotor faults in three-phase induction motors under time-varying loads. In: **2015 IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)**. [S.l.: s.n.], 2015. p. 373–379.

MARTIN-DIAZ, I.; MORINIGO-SOTELO, D.; DUQUE-PEREZ, O.; ARREDONDO-DELGADO, P.; CAMARENA-MARTINEZ, D.; ROMERO-TRONCOSO, R. Analysis of various inverters feeding induction motors with incipient rotor fault using high-resolution spectral analysis. **Electric Power Systems Research**, 2017. v. 152, p. 18 – 26, 2017. ISSN 0378-7796.

MARTÍNEZ-MORALES, J. D.; PALACIOS-HERNÁNDEZ, E. R.; CAMPOS-DELGADO, D. U. Multiple-fault diagnosis in induction motors through support vector machine classification at variable operating conditions. **Electrical Engineering**, 2016. p. 1–15, 2016.

MARWALA, T. **Condition Monitoring Using Computational Intelligence Methods: Applications in Mechanical and Electrical Systems**. [S.l.]: Springer London, 2012. (SpringerLink : Bücher). ISBN 9781447123804.

NANDI, S.; BHARADWAJ, R.; TOLIYAT, H. A.; PARLOS, A. G. Study of three phase induction motors with incipient rotor cage faults under different supply conditions. In: **Conference Record of the 1999 IEEE Industry Applications Conference. Thirty-Forth IAS Annual Meeting (Cat. No.99CH36370)**. [S.l.: s.n.], 1999. v. 3, p. 1922–1928 vol.3. ISSN 0197-2618.

NEMEC, M.; DROBNIC, K.; NEDELJKOVIC, D.; FISER, R.; AMBROZIC, V. Detection of broken bars in induction motor through the analysis of supply voltage modulation. **IEEE Transactions on Industrial Electronics**, 2010. v. 57, n. 8, p. 2879–2888, Aug 2010. ISSN 0278-0046.

OLIVEIRA, S. M. de. **Análise de sinais para Engenheiros: Uma abordagem via Wavelets**. [S.l.]: Brasport Livros e Multimidia Ltda, 2007. (Soc. Bras. de Telecomunicações SBrT). ISBN 978-85-7452-283-8.

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

OPPENHEIM, A.; SCHAFER, R. **Discrete-time signal processing**. [S.l.]: Prentice Hall, 2010. (Prentice-Hall signal processing serie). ISBN 9780131988422.

PALÁCIOS, R. H. C. **Aplicação de Técnicas Inteligentes com Análise no Domínio do Tempo para Reconhecimento de Defeitos em Motores de Indução Trifásicos**. 189 p. Tese (Doutorado) — Escola de Engenharia de São Carlos (EESC), São Carlos - SP, 2016.

PALÁCIOS, R. H. C.; GOEDEL, A.; GODOY, W. F.; FABRI, J. A. Fault identification in the stator winding of induction motors using pca with artificial neural networks. **Journal of Control, Automation and Electrical Systems**, 2016. v. 27, n. 4, p. 406–418, 2016. ISSN 2195-3899.

PALÁCIOS, R. H. C.; SILVA, I. N. da; GOEDEL, A.; GODOY, W. F.; OLESKOVICZ, M. A robust neural method to estimate torque in three-phase induction motor. **Journal of Control, Automation and Electrical Systems**, 2014. v. 25, n. 4, p. 493–502, 2014. ISSN 2195-3899. Disponível em: <<http://dx.doi.org/10.1007/s40313-014-0118-6>>.

PALÁCIOS, R. H. C.; SILVA, I. N. da; GOEDEL, A.; GODOY, W. F. A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. **Electric Power Systems Research**, 2015. v. 127, p. 249 – 258, 2015.

_____. A novel multi-agent approach to identify faults in line connected three-phase induction motors. **Applied Soft Computing**, 2016. v. 45, p. 1 – 10, 2016.

QUINLAN, J. R. **C4.5: Programs for Machine Learning**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1993. ISBN 1-55860-238-0.

REIS, A. J. S. **Reconhecimento de padrões de falha em motores de indução trifásico utilizando redes neurais**. 88 f p. Dissertação (Mestrado) — Programa de Pós Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Norte - Natal, agosto 2010.

ROBERTS, M. J. **Signals and Sysytems: Analysis Using Transform Methods and MATLAB**. 2. ed. New York, NY: McGraw-Hill, 2012.

ROMERO-TRONCOSO, R. de J. Multirate signal processing to improve fft-based analysis for detecting faults in induction motors. **IEEE Transactions on Industrial Informatics**, 2017. v. 13, n. 3, p. 1291–1300, June 2017. ISSN 1551-3203.

SAMANTA, B.; AL-BALUSHI, K. Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. **Mechanical Systems and Signal Processing**, 2003. v. 17, n. 2, p. 317–328, 2003.

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

_____. Sobre a aplicações de sistemas inteligentes para diagnóstico de falhas em máquinas de indução - uma visão geral. **SBA - Sociedade Brasileira de Automatica - Controle & Automação**, 2012. Scielo, v. 23, p. 553–569, 10 2012.

SEERA, M.; LIM, C. P.; NAHAVANDI, S.; LOO, C. K. Condition monitoring of induction motors: A review and an application of an ensemble of hybrid intelligent models. **Expert Systems with Applications**, 2014. v. 41, n. 10, p. 4891 – 4903, 2014.

SIEGEL, D.; AL-ATAT, H.; SHAUCHE, V.; LIAO, L.; SNYDER, J.; LEE, J. Novel method for rolling element bearing health assessment: A tachometer-less synchronously averaged envelope feature extraction technique. **Mechanical Systems and Signal Processing**, 2012. v. 29, p. 362 – 376, 2012. ISSN 0888-3270.

SILVA, F. G.; ANDRADE, J. J. d. O. Análise de falhas de equipamentos da indústria metal-mecânica como subsídio para estabelecimento de atividades de manutenção. **Revista espacios**, 2016. v. 38, p. 17, marc 2016.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Artificial Neural Networks: engineering and applied sciences(in Potuguese)**. 1. ed. São Paulo, SP: Artliber, 2010.

SINGH, A.; GRANT, B.; DEFOUR, R.; SHARMA, C.; BAHADOORSINGH, S. A review of induction motor fault modeling. **Electric Power Systems Research**, 2016. v. 133, p. 191 – 197, 2016.

SINGH, G.; KAZZAZ, S. A. S. A. Induction machine drive condition monitoring and diagnostic researcha survey. **Electric Power Systems Research**, 2003. v. 64, n. 2, p. 145–158, 2003.

SINGH, S.; KUMAR, A.; KUMAR, N. Motor current signature analysis for bearing fault detection in mechanical systems. **Procedia Materials Science**, 2014. v. 6, p. 171 – 177, 2014. ISSN 2211-8128.

SINGH, S.; KUMAR, N. Detection of bearing faults in mechanical systems using stator current monitoring. **IEEE Transactions on Industrial Informatics**, 2016. PP, n. 99, p. 1–1, Dec 2016. ISSN 1551-3203.

SMITH, J. **Mathematics of the Discrete Fourier Transform (DFT): With Audio Applications**. [S.l.]: BookSurge Publishing, 2007. (W3K Publishing). ISBN 9780974560748.

SOARES, P. da S. **Sistema de avaliação preditiva de falhas em máquinas elétricas usando lógica fuzzy com análise dos parâmetros de vibração, corrente e temperatura**. Tese (Doutorado) — Universidade Estadual de Campinas, 2014.

SOBRINHO, C. A. N. **Estudo Coparativo de Técnicas para diagnóstico de Falhas em Motores de Indução Trifásicos**. Tese (Doutorado) — Universidade Federal da Paraíba, 2015.

SOBRINHO, C. A. N.; FILHO, A. L. C.; LIMA, T. L. V.; MAFALDO, . M.; G, R. D.; ADISSI, M. de O.; SILVA, J. F. da; SENA, A. P. C. de. Desenvolvimento de sistema embarcado para detecção de falhas em motores de indução. In: **XII Simpósio Brasileiro de Automação Inteligente**. [S.l.: s.n.], 2015.

SUETAKE, M. **Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos**. Tese (Doutorado) — Escola de Engenharia de São Carlos - Universidade de São Paulo, São Carlos-SP, 2012.

THOMSON, W.; CULBERT, I. **Current Signature Analysis for Condition Monitoring of Cage Induction Motors: Industrial Application and Case Histories**. [S.l.]: Wiley, 2017. (IEEE Press Series on Power Engineering). ISBN 9781119029595.

THOMSON, W. T.; GILMORE, R. J. Motor current signature analysis to detect faults in induction motor drives - fundamentals, data interpretation, and industrial case histories. In: **Proceedings of the Thirty-Second Turbomachinery Symposium**. [S.l.: s.n.], 2003. p. 145–156.

TRAJIN, B.; REGNIER, J.; FAUCHER, J. Indicator for bearing fault detection in asynchronous motors using stator current spectral analysis. **IEEE International Symposium on Industrial Electronics - ISIE**, 2008. v. 1, p. 570 –575, 30 2008-july 2 2008.

TRAN, V. T.; CATTLEY, R.; BALL, A.; LIANG, B.; IWNICKI, S. Fault diagnosis of induction motor based on a novel intelligent framework and transient current signals. **Chemical Engineering Transactions**, 2013. v. 33, n. 3, p. 691 – 696, may-june 2013. ISSN 1974-9791.

TRAN, V. T.; YANG, B.-S.; GU, F.; BALL, A. Thermal image enhancement using bi-dimensional empirical mode decomposition in combination with relevance vector machine for rotating machinery fault diagnosis. **Mechanical Systems and Signal Processing**, 2013. v. 38, n. 2, p. 601 – 614, 2013. ISSN 0888-3270.

VAPNIK, V. N. **The Nature of Statistical Learning Theory**. New York, NY, USA: Springer-Verlag New York, Inc., 1995. ISBN 0-387-94559-8.

VIERA, A. J.; GARRETT, J. M. Understanding interobserver agreement: the kappa statistic. **Family medicine**, 2005. U.S. National Library of Medicine, Bethesda, MD, USA, v. 37, n. 5, p. 360–363, 2005. ISSN 0742-3225.

VINAYAK, B. A.; UDDIN, R.; JAGADANAAND, G. Inter phase fault detection in inverter fed induction motor using wavelet transform. In: **2017 3rd International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)**. [S.l.: s.n.], 2017. p. 104–107.

YAHIA, K.; CARDOSO, A. J. M.; ZOUZOU, S. E.; GUEDDIDI, S. Broken rotor bars diagnosis in an induction motor fed from a frequency converter: experimental research. **International Journal of System Assurance Engineering and Management**, 2012. v. 3, n. 1, p. 40–46, Mar 2012. ISSN 0976-4348.

YANG, J.; LIGUO; XU, D.; XUE, B. Sensorless speed estimation for line-connected induction motor based on recurrent multilayer neural network. **IEEE International Conference on Automation and Logistics**, 2007. p. 2013–2018, 2007.

ZHU, H.; HU, J.; GAO, L.; HUANG, H. Fault diagnosis of broken rotor bars of inverter-fed squirrel-cage induction motor at no-load using supply-side current based on hilbert demodulation technique. **Chinese Journal of Scientific Instrument**, 2014. v. 35, n. 1, p. 139 – 147, 2014.

Apêndices

OUTRAS ANÁLISES DOS SISTEMAS INTELIGENTES

Como mencionado no texto do trabalho, não existe uma metodologia estabelecida e consolidada para determinar a estruturação ideal dos SI abordados nesta tese. O que ocorre são considerações acerca de ajustes finos para sintonia e determinação de parâmetros dentro de um escopo de tentativa e erro. O software WEKA traz a proposição da resposta a cerca da topologia de melhor desempenho de acordo com suas regras e algoritmos de otimização já estabelecidos, mas também permite a adequação a do operador na indicação dos valores e índices, de acordo com cada SI, que melhor se adaptem ou justifiquem a abordagem.

Assim sendo, outros testes foram realizados com os mesmos padrões de dados apresentados nas cinco abordagens de classificadores de padrões inteligentes. Nesta seção são compilados os resultados com menor desempenho mas que justificam a estruturação e apresentação das propostas descritas no Capítulo 4, consideradas de melhores resultados segundo a análise de emprego nas condições estabelecidas para a finalidade deste trabalho.

A seguir são apresentadas as discussões dos resultados acerca de variação dos modelos de SI para a análise e embasamento das vertentes adotadas como modelos classificadores desta tese. Inclusive são apontadas considerações para os modelos com percentual de acerto de 100%. No caso os algoritmos *SVM* e *k-nn*.

A.1 APONTAMENTOS SOBRE SVM E k-nn

A.1.1 Resultados de avaliação SVM

A técnica SVM é um método de aprendizagem com um algoritmo otimizador de programação quadrática para determinar o valor ótimo dos limites derivados da teoria de aprendizagem estatística.

Há diferentes tipos de SVM e para este trabalho foi escolhido o *Sequential Minimal Optimization* (SMO). O SMO é um algoritmo simples que resolve rapidamente o problema do SVM

sem nenhum armazenamento de matriz extra e sem invocar uma rotina numérica iterativa para cada subproblema. O SMO decompõe o problema geral em subproblemas e resolve o menor problema possível de otimização em cada etapa (VAPNIK, 1995).

O SMO é amplamente utilizado para o treinamento de máquinas de vetores de suporte e é implementado pela ferramenta *Library for Support Vector Machines* (LibSVM). O LibSVM é uma biblioteca utilizada em problemas de classificação onde as principais características são o suporte a problemas multiclasse. O treinamento com os tipos de *kernel* mais comuns e a validação cruzada é aplicada na escolha do melhor modelo.

Na Tabela 13 são apresentados dois resultados gerados pela plataforma WEKA onde SVM refere-se as configurações padrões do SVM com calibrador tipo Logística e kernel polinomial em comparação a SVM-LibSVM com calibrador tipo LibSVM e kernel polinomial.

Tabela 13: Resultados para o algoritmo SVM com variação do calibrador

Algoritmo SI	SVM	SVM-LibSVM
Número Classes	5	5
Número Instâncias	720	720
Instâncias Incorreta	0	0
Instâncias Corretas	720	720
% Classificação	100	100
MAE	0,240	0,001
% RMSE	0,316	0,002
RRSE	80,138	0,588
Kappa	1	1

Na abordagem otimizada a função de kernel escolhida foi a polinomial e os parâmetros C (custo) e ϵ (epsilon), apesar de geralmente serem escolhidos segundo o problema a ser resolvido, para esta proposta não foram alterados.

Como pode ser visto na Tabela 13, os resultados correlatos do SVM e SVM-LibSVM se encontram dentro da faixa estabelecida pelos vetores e garantem a classificação em 100%, mas a saída do classificador SVM está distante do esperado pois os índices de erro (MAE e RMSE) estão bem acima entre uma proposta e outra, reiterando a maior variância e desvio padrão.

A.1.2 Resultados de avaliação *k-nn*

Uma vez que a estruturação aplicada a este algoritmo determinada para uma vizinhança de $k = 1$ com 10 dobras de validação cruzada obteve 100% de acerto, novas abordagens e variações de padrões não se fazem tão necessárias para melhorar desempenho. Entretanto, foram realizadas análise da metodologia com a proximidade $k = 5$ vizinhos mais próximos, buscando observar desempenho computacional e tempo de máquina.

Como esperado o algoritmo manteve resultado 100% inclusive com o mesmo tempo de estruturação dos dados. Outrossim, esta variação no tempo de execução não interfere no processamento uma vez que o SI já esteja treinado.

Os resultados desta análise são transcritos na Tabela 14 onde são comparados com o padrão do SI com $k = 1$ vizinho e $k = 5$ vizinho.

Tabela 14: Resultado para algoritmo k -nn com variação de $k = 5$ vizinho

Algoritmo k -nn	$k = 1$	$k = 5$
Instâncias amostradas	720	720
Percentual de Classificação	100%	100%
Classificações Incorretas	0	0
MAE	0.0025	0.0027
% RMSE	0.0031	0.024
RRSE	0.776	6.194
Kappa	1	1

A.2 ALTERNATIVAS PARA PMC, C4.5 E NB

A.2.1 Resultados de avaliação PMC

As variações na abordagem da redes neurais tipo PMC partiram da alternância da topologia principal em número de neurônios, mas não em número de camadas neurais. Sendo então proposto, a abordagem com incremento de neurônios na camada de entrada e na camada oculta, preservado o padrão da camada de saída. Esta elevação no número de elementos neurais busca aumentar o desempenho do classificador no que tange a acurácia do algoritmo.

Assim, para esta análise, foi utilizada uma rede com 20 neurônios na camada de entrada, uma camada intermediária com 15 neurônios e uma camada de saída com 5 neurônios. Os 5 neurônios da camada de saída são mantidos para atender a recomendação proposta por Silva, Spatti e Flauzino (2010) de um neurônio para cada classe distinta do classificador.

Em uma observação inicial compreende-se que esse número maior de neurônios aumenta a complexidade computacional e mais tarde pode limitar a proposição da estruturação do algoritmo embarcado em hardware dedicado. Mesmo assim, foi mantida a topologia para verificar a evolução do desempenho do classificador.

Também foram mantidos o passo de aprendizagem em 0,03 e o termo momentum em 0,2, com a proposta de aprendizagem otimizado de *Levenberg Marquardt*. Estes parâmetros não interferem no desempenho computacional uma vez que a RNA já esteja treinada.

Ao contrário do esperado, a classificação correta desta matriz de validação atingiu índice de 94,86%, como pode ser visto na Tabela 15. A classificação ocorreu na presença de não falhas ou falha com tipo de falha e estado de degradação. Cada neurônio da camada de saída assumiu uma classe distinta.

Das duas topologias válidas propostas para PMC, a que mais demanda tempo de máquina em processamento e treinamento dos modelos é a que alcança um percentual de acerto menor com 94%. Essa redução da acurácia é provida pela perda de generalização do algoritmo com

Tabela 15: Resultado para algoritmo PMC com variação do número de neurônios

Variação Algoritmo PMC	
Estrutura de Camadas/Neurônios	20-15-5
Instâncias amostradas	720
Atributos das Instâncias	14301
Tipo de Validação	Cruzada
Índice de Validação	10
Percentual de Classificação	94,86%
Classificações Incorretas	37

um número exagerado de neurônios, onde o *overfitting* fica evidenciado e a RNA não consegue distinguir os parâmetros diferenciados das amostras usadas no treinamento.

Observando detalhadamente a matriz de confusão da Tabela 16 e considerando a abordagem de classificação simples (presença ou não de falha), a abordagem PMC apresentou apenas 1 falso positivo e 4 falsos negativos corresponde a um percentual de acerto de 99,3%.

Tabela 16: Matriz de confusão da abordagem PMC com variação do número de neurônios

PMC								
a	b	c	d	e		Falso	Positivo	1
239	1	0	0	0	a	Falso	Negativo	4
0	118	2	0	0	b	Classe	Maior Erro	d
4	3	113	0	0	c	Classe	Menor Erro	a
0	21	6	93	0	d			
0	0	0	0	120	e	Sem	Erro	e

A determinação da topologia ocorre de forma heurística e outras composições foram testadas não gerando modelos válidos pelo software por limitação de hardware e tempo de processamento.

A.2.2 Resultados de avaliação C4.5

Para esta abordagem duas metodologias distintas foram estabelecidas. A árvore pelo sistema de poda convencional do software obteve o tamanho de 29 ramificações em 15 folhas e 14 nós. Esta estratégia atinge a acurácia de 93,61% como apresentados anteriormente no Capítulo 4.

Na abordagem alternativa para o algoritmo de árvore de decisão optou-se pela redução do erro de poda baseada na entropia, onde se obteve um modelo de decisão menor, totalizando 21 ramificações em 11 folhas e 10 nós. Entretanto, o decréscimo no percentual de acerto foi gerado atingindo o valor percentual de 91,11% com 64 instâncias classificadas erradamente. Esta nova abordagem é descrita Tabela 17.

Um fato a ser observado e explorado em trabalhos futuros é que nas duas abordagens existem nós correspondentes ao mesmo valor de referência de entrada, como apresentado em destaque na Figura 19. O que pode ser atribuído a característica mais determinante presentes nos sinais em análise e portanto na classificação da falha.

Tabela 17: Resultado para algoritmo C4.5 com vriação na poda

Algoritmo C4.5 Alternativo	
Instâncias amostradas	720
Atributos das Instâncias	14301
Tipo de Validação	Cruzada
Índice de Validação	10
Percentual de Classificação	91,11%
Classificações Incorretas	64

Modelo Principal	Modelo Reduzido
<pre> ==== Run information ==== Scheme: weka.classifiers.trees.J48 -C 0.25 -M 2 Relation: motor-aprendizado Instances: 720 Attributes: 14301 [list of attributes omitted] Test mode: 10-fold cross-validation ==== Classifier model (full training set) ==== J48 pruned tree ----- Freq11712 <= 0.064988 Freq7712 <= 0.011277 Freq6828 <= 0.017243 Freq6005 <= 0.010271 Freq5780 <= 0.010914 Freq11575 <= 0.005619 Freq3228 <= 0.005655 Freq2520 <= 0.005574 Freq3701 <= 0.009321: 2 (113.0) Freq3701 > 0.009321: 1 (3.0) Freq2520 > 0.005574: 1 (24.0/1.0) Freq3228 > 0.005655: 1 (44.0) Freq11575 > 0.005619: 1 (161.0/1.0) Freq5780 > 0.010914 Freq22 <= 0.17911: 1 (3.0) Freq22 > 0.17911 Freq614 <= 0.010736: 2 (3.0) Freq614 > 0.010736: 3 (9.0) Freq6005 > 0.010271 Freq1321 <= 0.48043 Freq1220 <= 0: 2 (3.0) Freq1220 > 0: 1 (5.0) Freq1321 > 0.48043: 3 (36.0) Freq6828 > 0.017243: 3 (76.0/1.0) Freq7712 > 0.011277: 4 (60.0/1.0) Freq11712 > 0.064988 Freq2887 <= 0.024847: 5 (120.0) Freq2887 > 0.024847: 4 (60.0) Number of Leaves : 15 Size of the tree : 29 </pre>	<pre> ==== Run information ==== Scheme: weka.classifiers.trees.J48 -R -N 5 -Q 1 -M 5 Relation: motor-aprendizado Instances: 720 Attributes: 14301 [list of attributes omitted] Test mode: 10-fold cross-validation ==== Classifier model (full training set) ==== J48 pruned tree ----- Freq11712 <= 0.064988 Freq7712 <= 0.011277 Freq6828 <= 0.017243 Freq6005 <= 0.010271 Freq7164 <= 0.014581 Freq11575 <= 0.005619 Freq3228 <= 0.005655 Freq2520 <= 0.005574: 2 (96.0/3.0) Freq2520 > 0.005574: 1 (17.0) Freq3228 > 0.005655: 1 (35.0) Freq11575 > 0.005619: 1 (133.0/1.0) Freq7164 > 0.014581: 3 (6.0/1.0) Freq6005 > 0.010271 Freq1321 <= 0.48043: 1 (6.0/2.0) Freq1321 > 0.48043: 3 (31.0) Freq6828 > 0.017243: 3 (59.0) Freq7712 > 0.011277: 4 (49.0/1.0) Freq11712 > 0.064988 Freq2887 <= 0.024847: 5 (96.0) Freq2887 > 0.024847: 4 (48.0) Number of Leaves : 11 Size of the tree : 21 </pre>

Figura 19: Comparação de estruturas de árvores de decisão

A direita da Figura 19 são mostradas as regras de classificação da árvores de decisão sem limitações de poda e que obteve maior acurácia. A esquerda a árvore proposta com limitação da poda que apresentou menor percentual de classificação de erros mas ainda superior a 90% de acerto. As duas abordagens apresentam 9 dos seus nós alocados nos mesmos valores de referência.

A.2.3 Resultados de avaliação NB

A estratégia alternativa da tabela de probabilidade NB das classificações desta tese segue a aplicação das demais abordagens no que tange o universo amostral no software *WEKA*. Entre-

tanto, o diferencial nas condições de operação é o aumento da resolução dos valores da tabela ou estimador de *kernel*.

Essa proposição decreta a confiabilidade do sistema para abaixo de 90% de acerto como se referencia na Tabela 18 de resultados.

Tabela 18: Resultado para algoritmo NB com variação do *kernel*

Validação Algoritmo NB	
Instâncias amostradas	720
Atributos das Instâncias	14301
Tipo de Validação	Cruzada
Índice de Validação	10
Percentual de Classificação	90%
Classificações Incorretas	28

A.3 RESULTADOS ALTERNATIVOS

As cinco propostas resultaram na classificação com acertos de 90% à 100%, sendo que estes percentuais de acerto são aplicados na classificação das instâncias em 5 classes distintas, separadas tanto em tipo de falha como em intensidade de degradação. Entretanto, são tratados índices de desempenho e comparação individual entre cada classificador para evidenciar a evolução de seus resultados e estabelecidos a melhor proposta a ser considerada padrão e mais adequada para esta abordagem.