

ERICK ARAUJO NUNES

Diagnóstico de falhas de estator em motores de indução trifásicos via informação mútua e transformação de Clarke

São Paulo
2023

ERICK ARAUJO NUNES

Diagnóstico de falhas de estator em motores de indução trifásicos via informação mútua e transformação de Clarke

Versão Corrigida

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do Título de Mestre em Ciências.

Área de Concentração:

Engenharia de Sistemas

Orientador:

Prof. Dr. Bruno Augusto Angélico

Co-orientador:

Prof. Dr. Alessandro Goedtel

São Paulo
2023

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 17 de Dezembro de 2023

Assinatura do autor:



Assinatura do orientador:



Catálogo-na-publicação

Nunes, Erick Araujo

Diagnóstico de falhas de estator em motores de indução trifásicos via informação mútua e transformação de Clarke / E. A. Nunes -- versão corr. -- São Paulo, 2023.

101 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Telecomunicações e Controle.

1.APRENDIZADO COMPUTACIONAL 2.MOTORES ELÉTRICOS
3.RECONHECIMENTO DE PADRÕES 4.TEORIA DA INFORMAÇÃO
I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Telecomunicações e Controle II.t.

Dedico este trabalho à minha família,
pela dedicação e apoio.

AGRADECIMENTOS

Agradeço a Deus, por colocar pessoas incríveis em meu caminho e realizar grandes obras na minha vida.

Agradeço à minha mãe, por sua fé em mim. Privou-se de muitas coisas para que minha formação se tornasse realidade, e sempre esteve comigo, fosse em tristeza ou felicidade.

À minha querida Cremilda, que cobriu desde a minha infância as lacunas deixadas pela perda de meu pai, trazendo a essência mais verdadeira do significado de família que hoje tenho como base.

Agradeço com especial carinho à minha companheira Emy, por todo o suporte prestado durante todo o tempo, cuja compreensão e o companheirismo ajudaram a superar os momentos mais difíceis.

Ao meu irmão e minhas tias, que acreditam no meu sonho e em meu potencial. Eles foram capazes de preencher minhas lacunas e me tornaram mais forte.

Agradeço ao meu orientador Prof. Dr. Bruno Augusto Angélico, pela oportunidade, ensinamentos e orientação.

Ao meu coorientador Prof. Dr. Alessandro Goedel, por todos os ensinamentos, com ênfase àqueles que não são passados em sala de aula, como as virtudes da retidão.

A todos os meus amigos, em especial aqueles que compõem o Laboratório de Controle Aplicado (LCA) da Universidade de São Paulo (USP) e do Laboratório de Sistemas Inteligentes (LSI) da Universidade Tecnológica Federal do Paraná campus Cornélio Procópio (UTFPR-CP), em especial ao meu grande amigo Enrique, que não somente prestou suporte quando necessário, como também me mostrou o valor das melhores amizades.

Agradeço à Escola Politécnica da Universidade de São Paulo por contribuir de maneira imensurável com a minha formação acadêmica e profissional.

Como entusiasta de desenvolvimento em tempo livre, agradeço às minhas companheiras Valentina e Zoe, que me animam dias e noites em meu laboratório particular.

“Porque aos seus anjos dará ordem a teu respeito, para te guardarem em todos os teus caminhos.”

Bíblia Sagrada, Salmos 91, 11

RESUMO

NUNES, Erick Araujo. **Diagnóstico de falhas de estator em motores de indução trifásicos via informação mútua e transformação de Clarke**. 2023. 101 f. Dissertação (Mestrado em Engenharia Elétrica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2023.

Este estudo apresenta um sistema para diagnóstico do nível de severidade de falhas de curto-circuito entre espiras do enrolamento do estator de motores de indução trifásicos conectados diretamente à rede. A metodologia adotada baseia-se na informação mútua deslocada para extração de características relevantes entre sinais de corrente elétrica no sistema de referência ortogonal $\alpha - \beta$, gerados a partir de medições da corrente de linha de motores de indução trifásicos. Estes dados são submetidos a algoritmos de aprendizado de máquina baseados em redes neurais artificiais do tipo *Perceptron* multicamadas, SVM e kNN para reconhecimento de padrões associados à ocorrência da falha de curto-circuito e seu respectivo nível de severidade. Para validação do desempenho da metodologia proposta, dados experimentais de dois motores de indução trifásicos são utilizados em testes conduzidos sob diversas condições de operação.

Palavras-chave – Aprendizado Computacional, Motores Elétricos, Reconhecimento de Padrões, Teoria da Informação.

ABSTRACT

NUNES, Erick Araujo. **Three-phase induction motors stator fault diagnosis based on mutual information and Clarke's transform**. 2023. 101 f. Dissertação (Mestrado em Engenharia Elétrica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2023.

This study presents a system for severity level diagnosis of stator inter-turn short-circuit fault in three-phase induction motors directly connected to the grid. The methodology is based on delayed mutual information to extract relevant characteristics between electrical current signals in $\alpha - \beta$ orthogonal reference generated from line currents of three-phase induction motors. Those data are subjected to machine learning algorithms based on multilayer *Perceptron* artificial neural network, SVM and kNN for short-circuit fault identification and severity level diagnosis. Experimental data acquired from two induction three phase motors operating on several conditions are used in tests to validate the system's performance.

Keywords – Computational Learning, Electric Motors, Pattern Recognition, Information Theory.

LISTA DE FIGURAS

1	Consumo de energia elétrica por setor.	16
2	Categorização dos motores elétricos.	24
3	Motor de indução trifásico com rotor gaiola de esquilo.	27
4	Falhas comuns em motores de indução trifásicos.	28
5	Diagrama planejado com ilustração de falhas de curto-circuito no estator.	29
6	Fusão no núcleo do estator decorrente de curto-circuito.	30
7	Sinais de corrente elétrica em um MIT sujeito a condições de curto-circuito.	32
8	Dinâmica da variação de conjugado de carga e desbalanceamento de tensão em MIT.	33
9	Representação dos eixos α e β	35
10	Comparação sinais transformados.	37
11	Relação entre informação mútua e Entropia.	41
12	Partições sinal I_α	44
13	Partições sinais I_α e I_β	44
14	Representação por histograma.	45
15	Agrupamento da função de probabilidade conjunta.	45
16	Perfil de informação mútua deslocada.	46
17	Modelo de um neurônio artificial.	48
18	Funções de ativação.	49
19	Ilustração arquitetura MLP.	51
20	Separação de classes HMSVM.	53
21	Estrutura do sistema proposto.	57
22	Estrutura de testes e aquisição de dados.	60

23	Sinais em referencial estacionário sujeitos à diferentes condições de severidade de falha, desequilíbrio de tensão e conjugado de carga.	66
24	Histogramas de i_α , i_β e perfil de DMI para $\tau = 3$ em MIT saudável.	67
25	Histogramas de i_α , i_β e perfil de DMI para $\tau = 75$ em MIT saudável.	67
26	Histogramas de i_α , i_β e perfil de DMI para $\tau = 150$ em MIT saudável.	68
27	Histogramas de i_α , i_β e perfil de DMI para $\tau = 3$ em MIT sujeito a curto-circuito de estator.	69
28	Histogramas de i_α , i_β e perfil de DMI para $\tau = 75$ em MIT sujeito a curto-circuito de estator.	69
29	Histogramas de i_α , i_β e perfil de DMI para $\tau = 150$ em MIT sujeito a curto-circuito de estator.	70
30	Perfis de DMI sujeito às condições de MIT saudável, 3% de CC, 5% de CC e 10% de CC.	70
31	Influência de efeitos dinâmicos na característica de DMI.	71
32	Estrutura de treinamento e validação dos algoritmos de aprendizado de máquina.	75

LISTA DE TABELAS

1	Tabela de frequência.	41
2	Função de probabilidade conjunta.	42
3	Características dos MIT utilizados.	60
4	Condições de desbalanceamento de tensão.	61
5	Condições de variação do conjugado de carga.	61
6	Organização dos dados amostrais.	62
7	Combinações de dados amostrais de M1 por condição.	63
8	Combinações de dados amostrais de M2 por condição.	64
9	Topologias candidatas para RNA do tipo MLP.	73
10	Desempenho RNA Topologia 1.	77
11	Desempenho RNA Topologia 2.	77
12	Desempenho RNA Topologia 3.	77
13	Desempenho RNA Topologia 4.	77
14	Desempenho RNA Topologia 5.	77
15	Desempenho RNA Topologia 6.	77
16	Desempenho RNA Topologia 7.	78
17	Desempenho RNA Topologia 8.	78
18	Desempenho RNA Topologia 9.	78
19	Desempenho RNA Topologia 10.	78
20	Desempenho SVM $C = 1, \gamma = 0, 1$	79
21	Desempenho SVM $C = 1, \gamma = 1$	79
22	Desempenho SVM $C = 2, \gamma = 0, 1$	79
23	Desempenho SVM $C = 2, \gamma = 1$	79

24	Desempenho SVM $C = 2, \gamma = 10$.	79
25	Desempenho SVM $C = 3, \gamma = 0, 1$.	79
26	Desempenho SVM $C = 3, \gamma = 1$.	80
27	Desempenho SVM $C = 3, \gamma = 10$.	80
28	Desempenho kNN $k = 1$.	80
29	Desempenho kNN $k = 3$.	80
30	Desempenho kNN $k = 5$.	80
31	Desempenho kNN $k = 7$.	80
32	Desempenho kNN $k = 9$.	81
33	Severidade 3% RNA.	82
34	Severidade 3% SVM.	82
35	Severidade 3% kNN.	82
36	Severidade 5% RNA.	83
37	Severidade 5% SVM.	83
38	Severidade 5% kNN.	83
39	Severidade 10% RNA.	83
40	Severidade 10% SVM.	83
41	Severidade 10% kNN.	84
42	Avaliação geral de desempenho por modelo.	85
43	Informações MIT M2.	86
44	Desempenho RNA MIT 2.	87
45	Desempenho SVM MIT 2.	87
46	Desempenho kNN MIT 2.	87
47	Desempenho aplicado ao reconhecimento do nível de severidade no MIT 2.	88
48	Comparação taxa de acerto por atributo alvo e motor.	89

LISTA DE SIGLAS E ABREVIACÕES

CA	Corrente Alternada
CBM	<i>Condition-Based Maintenance</i>
CC	Corrente Contínua
CMMS	<i>Computerized Maintenance Management System</i>
CWT	<i>Continuous Wavelet Transform</i>
DEC	<i>Dynamic Eccentricity</i>
DMI	<i>Delayed Mutual Information</i>
DSP	<i>Digital Signal Processor</i>
DT	<i>Decision Trees</i>
DWT	<i>Discrete Wavelet Transform</i>
ELU	<i>Exponential Linear Unit</i>
EPE	Empresa de Pesquisas Energéticas
FFT	<i>Fast Fourier Transform</i>
GCC	Gerador de Corrente Contínua
GWh	GigaWatt hora
HMSVM	<i>Hard-Margin Support Vector Machines</i>
IA	Inteligência Artificial
IACO	<i>Improved Ant Colony Optimization</i>
IEA	<i>International Energy Agency</i>
kNN	<i>k-Nearest Neighbors</i>
LSI	Laboratório de Sistemas Inteligentes
MCC	<i>Matthews Correlation Coefficient</i>
MEC	<i>Mixed Eccentricity</i>
MI	<i>Mutual Information</i>
MIT	Motor de Indução Trifásico
ML	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
PMSM	<i>Permanent Magnet Synchronous Motors</i>
RBF	<i>Radial Basis Function</i>
RCM	<i>Reliability-Centered Maintenance</i>
ReLU	<i>Rectified Linear Unit</i>
RNA	Redes Neurais Artificiais
SEC	<i>Static Eccentricity</i>
SFO	<i>Self Organized Maps</i>
SMO	<i>Sequential Minimal Optimization</i>
SMSVM	<i>Soft-Margin Support Vector Machines</i>
SVM	<i>Support Vector Machine</i>
TBM	<i>Time-Based Maintenance</i>
WEKA	<i>Waikato Environment for Knowledge Analysis</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	DELIMITAÇÃO DO TEMA	21
1.2	JUSTIFICATIVA	21
1.3	OBJETIVOS	22
1.3.1	Objetivo Geral	22
1.3.2	Objetivos Específicos	22
1.4	ORGANIZAÇÃO DO TEXTO	23
2	MOTORES DE INDUÇÃO TRIFÁSICOS	24
2.1	CONSTRUÇÃO DE MOTORES DE INDUÇÃO TRIFÁSICOS	25
2.2	FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS	28
2.3	ESTRATÉGIAS PARA IDENTIFICAÇÃO DE FALHAS	30
2.4	SÍNTESE DO CAPÍTULO	33
3	EXTRAÇÃO DE CARACTERÍSTICAS E CLASSIFICAÇÃO DE PADRÕES	34
3.1	A TRANSFORMAÇÃO DE CLARKE	34
3.2	SIMILARIDADE ENTRE VARIÁVEIS E INFORMAÇÃO MÚTUA DESLOCADA	39
3.3	SISTEMAS INTELIGENTE APLICADOS À CLASSIFICAÇÃO DE PADRÕES	46
3.3.1	Redes Neurais Artificiais do Tipo <i>Perceptron</i> Multicamadas - MLP . . .	47
3.3.2	Máquina de Vetores de Suporte - SVM	52
3.3.3	k-Vizinhos Mais Próximos - kNN	55
3.4	SÍNTESE DO CAPÍTULO	56
4	METODOLOGIA	57

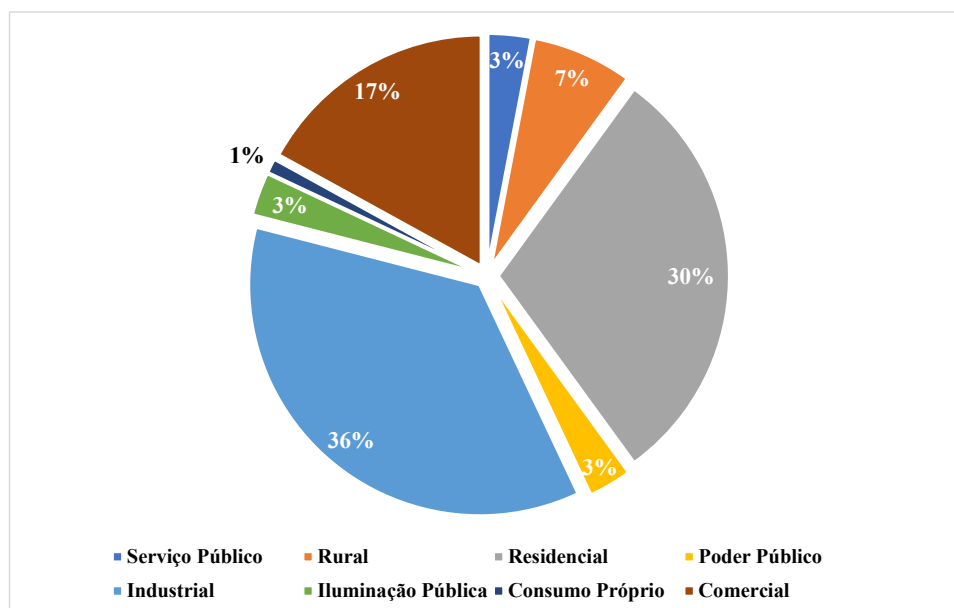
4.1	AQUISIÇÃO E ORGANIZAÇÃO DE DADOS	59
4.2	PRÉ-PROCESSAMENTO	64
4.3	EXTRAÇÃO DE CARACTERÍSTICAS	66
4.4	RECONHECIMENTO DE PADRÕES	72
4.5	SÍNTESE DO CAPÍTULO	75
5	RESULTADOS	76
5.1	DIAGNÓSTICO DA FALHA DE CURTO-CIRCUITO EM ESTATOR	76
5.2	DIAGNÓSTICO DE SEVERIDADE DA FALHA DE CURTO-CIRCUITO EM ESTATOR	82
5.3	DIAGNÓSTICO APLICADO A UMA MÁQUINA DE 2 CV	86
5.4	SÍNTESE DO CAPÍTULO	88
6	CONCLUSÃO	90
	REFERÊNCIAS	93
	Apêndice A – PRODUÇÕES CIENTÍFICAS	100
A.1	Artigos Publicados em Periódicos em Autoria ou Coautoria	100
A.2	Certificado de Registro de Programa de Computador em Autoria ou Coautoria com Associação Direta ao Trabalho	100
A.3	Certificado de Registro de Programa de Computador em Autoria ou Coautoria com Colaboração Direta em Outras Pesquisas	101

1 INTRODUÇÃO

De acordo com o relatório *Key World Energy Statistics* publicado em 2021 pela Agência Internacional de Energia (em inglês *International Energy Agency - IEA*) atribui-se ao setor industrial o maior consumo de energia elétrica, sendo este responsável por cerca de 41,9% do consumo mundial de eletricidade (IEA, 2021).

No Brasil, estudos da Empresa de Pesquisas Energéticas (EPE), indicam que o setor industrial corresponde a 36,25% do consumo nacional de energia elétrica, com a liderança no estudo de consumo por setor, o que representa mais de 180 GWh em 2021, conforme ilustrado na Figura 1 (EPE, 2021). Desta parcela, estima-se que 68% esteja relacionado ao acionamento de cargas por motores de indução trifásicos (MIT) (GUEDES *et al.*, 2019).

Figura 1: Consumo de energia elétrica por setor.



Fonte: Anuário Estatístico de Energia Elétrica (EPE, 2021).

Devido ao progressivo consumo de bens na sociedade, as indústrias modernas buscam elevar os níveis de produtividade e continuidade de seus processos. Porém, a ocorrência de quebras ou falhas em equipamentos fundamentais para a produção resultam em perdas de oportunidade de negócios e competitividade. Este fato culmina a mudança no âmbito da manutenção industrial que, anteriormente reativa e com foco em abordagens corretivas, passa a adotar métodos preventivos (CACHADA *et al.*, 2018).

Neste contexto, são adotadas estratégias de análise com o intuito de avaliar os aspectos financeiros, econômicos e técnicos orientados pela relação de custo x benefício associado com a operação de um ativo durante seu ciclo de vida (KESTELYN *et al.*, 2022).

A análise estatística de dados e o acompanhamento da degradação de equipamentos são alternativas comuns para o desempenho e disponibilidade no campo da gestão de ativos, desta maneira torna-se possível adotar estratégias para associar a probabilidade de ocorrência de um defeito com o percentual de vida útil atingido (MEHAIRJAN, 2011).

Entretanto, na ótica da gestão de ativos é importante visualizar o desenvolvimento de um defeito e antecipar a sua ocorrência e manter modelos de falha atualizados (MEHAIRJAN, 2011). No contexto industrial, o monitoramento de ativos é capaz de contribuir com o planejamento de manutenção para redução de custos relacionados com o reparo de equipamentos (YACOUT, 2010).

As abordagens típicas de manutenção aplicadas na indústria são centradas em tempo (em inglês *Time-Based Maintenance - TBM*), condições operacionais do equipamento (em inglês *Condition-Based Maintenance - CBM*) ou rentabilidade (em inglês *Reliability-Centered Maintenance - RCM*). Neste último cenário, a gestão tem como prioridade a redução de custos diretos e indiretos associados à manutenção, sendo amparado pelo monitoramento do equipamento por meio de sensores (HUO *et al.*, 2005; MOAT; COLEMAN, 2021). Atualmente destacam-se os sistemas computadorizados de gestão da manutenção (em inglês *Computerized Maintenance Management System - CMMS*), em que as informações podem ser gerenciadas com o auxílio de algoritmos específicos (ZEMMOUCHI-GHOMARI; CHERGUI; OUADAH, 2020).

Os MIT são frequentemente empregados em equipamentos industriais cujo funcionamento necessita de movimento rotativo. A popularidade deste tipo de máquina deve-se, principalmente, a características como custo reduzido, robustez construtiva e menor volume frente às máquinas síncronas e de corrente contínua, mantendo-se o valor de torque (BIM, 2018). Ressalta-se que, em geral, a diversidade de aplicação de MIT foi beneficiada pelos métodos de acionamento modernos baseados na tecnologia de estado sólido e no controle vetorial, tornando este tipo de máquina mais adequada para aplicações de velocidade variável (CHAPMAN, 2013).

Apesar dos benefícios associados às características supracitadas, os MIT sofrem com desgastes em seus componentes como todo equipamento eletromecânico (GUEDES *et al.*, 2018). Estes desgastes apresentam características evolutivas, de forma a originar falhas de natureza elétrica ou mecânica, capazes de afetar o desempenho da máquina de indução mesmo quando apresentam-se em estágio incipiente (SUETAKE, 2012).

Portanto, a relevância dos MIT para a indústria torna necessária a busca por procedimentos de manutenção adequados para estes equipamentos, a fim de reduzir os prejuízos financeiros e temporais associados à ocorrência de paradas indesejadas (GONGORA, 2013). Neste contexto, diversos pesquisadores dedicam-se ao desenvolvimento e aplicação de métodos para o diagnóstico assertivo da condição operativa de MIT a partir da leitura das variáveis elétricas e mecânicas da máquina (BAZAN *et al.*, 2019).

Dentre os métodos empregados, observa-se a predominância de estratégias não invasivas associadas à medição de temperatura, vibração mecânica, campo magnético, tensão elétrica, velocidade de rotação e corrente de linha (GUEDES *et al.*, 2019). Ademais, são apresentados resultados promissores em estudos recentes que integram o uso de modelos baseados em Inteligência Artificial (IA) (JUEZ-GIL *et al.*, 2020).

Além disso, a utilização de metodologias baseadas em IA apresentam ganho de relevância em estudos recentes, fato que se deve às características como o reconhecimento de padrões defeituosos sem que informações paramétricas da máquina sejam previamente conhecidas (SESHADRINATH; SINGH; PANIGRAHI, 2013).

Siddique, Yadava e Singh (2004) aplicam uma abordagem de reconhecimento de padrões associados a condições de sobretensão, subtensão, sobrecarga e falta de fase mediante o emprego de redes neurais artificiais (RNA) de base radial. Neste estudo, as medições instantâneas de tensão e corrente de linha são utilizadas como entradas para o classificador de padrões. Contudo, a quantidade de resultados de validação é baixa para a quantidade de classes de saída.

Os estudos conduzidos por Rodriguez, Alves e Guzman (2006) tem por abordagem o diagnóstico de falhas de estator ocasionadas pelo curto-circuito entre espiras, barras e anéis quebrados em MIT a partir de análises nos domínios do tempo e da frequência, cuja detecção é baseada na interpretação das variações de frequência estimada no fluxo magnético no entreferro. Ainda assim, os efeitos da falha de curto-circuito no fluxo magnético do entreferro é baixo e depende de uma instrumentação precisa e muitas vezes invasiva.

Suetake (2012) apresenta a aplicação de estratégias *on-line* baseadas em sistemas inteligentes e processadores digitais de sinais para a detecção do rompimento de barras em rotores do tipo gaiola de esquilo em MIT alimentados diretamente pela rede elétrica e por inversores de

frequência. Os resultados obtidos são promissores, porém não há a consolidação da solução em um modelo dedicado ao acompanhamento da evolução da falha por meio da identificação do estágio de severidade em que se encontra.

Seshadrinath, Singh e Panigrahi (2013) estudam a identificação de falhas de curto-circuito entre espiras e de rolamentos em MIT acionados por conversores mediante controle vetorial, onde utiliza-se transformadas *Wavelets* complexas em assinaturas vibratórias da máquina. Os padrões defeituosos são identificados em classificadores do tipo Máquina de Vetores de Suporte (em inglês *Support Vector Machine - SVM*) e *k*-Vizinhos Mais Próximos (em inglês *k-Nearest Neighbors - kNN*) alocados em classes "Saudável", "Curto-Circuito entre Espiras", "Curto-Circuito Entre Espiras em Progressão" e "Danos de Rolamento".

Gongora *et al.* (2016) utilizam-se de redes neurais artificiais para a reconhecimento de padrões defeituosos com assinaturas pertinentes à falha de rolamentos nos sinais de corrente elétrica. Estas assinaturas são originadas pela vibração mecânica nos componentes dos rolamentos, de forma a introduzir variações na intensidade de fluxo magnético devido às oscilações no entreferro da máquina. Neste estudo, os sinais amostrados são sujeitos à transformada rápida de Fourier (em inglês *Fast Fourier Transform - FFT*) e introduzidos em um classificador de padrões baseado em redes neurais artificiais.

Vitor *et al.* (2016) dedicam-se ao estudo da identificação de múltiplas falhas em MIT com metodologia baseada nas transformações dos sinais de corrente elétrica em referenciais estacionário e síncrono, mediante a aplicação das respectivas transformações de Clarke e Park. Então, os sinais são decompostos com a aplicação da transformada Wavelet e as falhas identificadas a partir de mapas auto-organizáveis de Kohonen (em inglês *Self Organized Maps - SFO*) capazes de formar *clusters* e ativar certos neurônios associados a ocorrência de anomalias específicas.

A abordagem de Guedes *et al.* (2019) baseia-se na estimativa de parâmetros do modelo de regime estacionário do MIT a partir da medição dos sinais de corrente de linha, tensão elétrica e velocidade de rotação, cujo método de estimação consiste em um algoritmo evolutivo com mecanismos de seleção natural e genética de populações denominado evolução diferencial. Assim, detecta-se a ocorrência de falhas de estator a partir da variação no valor estimado de indutância de magnetização para MIT conectados diretamente à rede de energia elétrica.

Khanjani e Ezoji (2021) abordam a utilização de imagens termográficas de MIT para diagnóstico de falhas mediante a aplicação de sistemas inteligentes, destaca-se neste método o emprego de redes neurais convolucionais, *k-Means* e SVM para reconhecimento de padrões. A validação do método ocorre com severidade de curto-circuito entre 10% e 30%, o que pode tornar esta metodologia pouco aderente aos desafios relacionados à identificação da falha de curto-

circuito incipiente, com a primeira etapa de reconhecimento da falha com nível de severidade não superior a 3%.

Estudos de Cunha, Jr e Medeiros (2021) buscam a detecção de falhas em MIT, ainda em estágio incipiente, a partir de 1,41% de espiras em curto-circuito, por meio de um algoritmo que combina a transformada de Wavelet discreta (em inglês *Discrete Wavelet Transform - DWT*) para análise multi-resolução, análise de indicadores estatísticos e elementos de aprendizado de máquina (em inglês *Machine Learning - ML*) para reconhecimento de padrões, mediante a medição da tensão induzida pelo fluxo de disperso. Entretanto, o custo computacional associado a esta metodologia não é levado em consideração.

Pesquisas recentes empregam elementos da teoria da informação ao diagnóstico de falhas em MIT, de forma a reduzir o custo computacional associados ao uso de modelos com aplicação de métodos matemáticos diversos e sofisticados (BAZAN *et al.*, 2019). A teoria da informação se faz presente em diversas vertentes da ciência moderna, sendo relacionada com a estatística, economia, matemática, ciência da computação, física, teoria da comunicação e da probabilidade (THOMAS; JOY, 2006).

Neste contexto, Bazan *et al.* (2019) propõe uma abordagem em dois estágios, em que a primeira consiste na extração de características a partir de elementos da teoria da informação, de forma a possibilitar o reconhecimento de padrões baseada em sistemas inteligentes. Este método baseia-se na Informação Mútua Deslocada (em inglês *Delayed Mutual Information - DMI*) e classificadores de padrões baseados em RNA e Árvores de Decisões (em inglês *Decision Trees - DT*), o que mostrou-se adequado para o diagnóstico de falhas em condições de variação de conjugado, desequilíbrios de tensão de alimentação e alterações no nível de severidade da falha.

Bazan *et al.* (2022) dão sequência em seus estudos com uma abordagem embarcada, aplicando uma versão melhorada do algoritmo de diagnóstico de falha de curto-circuito em estator em um sistema embarcado de baixo custo. Nesta abordagem, utiliza-se a DMI para extração de características e um classificador de padrões do tipo *Perceptron* Multicamadas (em inglês *Multilayer Perceptron - MLP*), de maneira a centralizar as etapas de aquisição de dados, extração de características e reconhecimento de padrões em processador digital de sinais (em inglês *Digital Signal Processor - DSP*) TMS320F28379D. Nota-se que neste estudo é apresentada a possibilidade de emprego da DMI no contexto de sistemas embarcados, visto que o erro quadrático médio da DMI é pouco afetado pela quantidade de amostras disponíveis. Porém, este estudo considera apenas as contribuições entre as fases A e B do motor de indução visando a redução do custo computacional.

Porém, os estudos de Bazan *et al.* (2019, 2022) não consideram a contribuição dos sinais de

corrente de linhas das três fases, em que mais etapas de amostragem e processamento seriam necessárias. Além disso, há uma carência de trabalhos aplicados não somente ao reconhecimento da falha de curto-circuito em estator, como também capazes de identificar o estágio em que a falha se encontra.

Considerando tais estudos, a proposta deste trabalho consiste em analisar os efeitos de inclusão dos sinais de corrente de linha das três fases, aplicando-se a Transformação de Clarke, a fim de obter um sistema equivalente descrito em componentes α e β , de maneira a reduzir para uma única interação necessária capaz de considerar a contribuição de todas as fases do MIT. Ainda, este estudo dedica-se não somente ao diagnóstico da ocorrência da falha de curto-circuito de estator, como também na identificação do nível de severidade em que a falha se encontra. Para este fim, critérios de desempenho são analisados para constatar a aderência do sistema bifásico equivalente para execução do diagnóstico proposto em motores de indução trifásicos conectados diretamente à rede de energia elétrica.

Assim, verifica-se inicialmente se a metodologia proposta mantém a robustez de classificação para MIT submetidos à desequilíbrio de tensão, alternância de conjugado de carga e variações no nível de severidade. Por fim, coloca-se o sistema desenvolvido para identificação do nível de severidade em que a máquina se encontra. A robustez da abordagem de extração de características utilizada é atestada com o uso de classificadores de padrões MLP, SVM e kNN.

1.1 DELIMITAÇÃO DO TEMA

O presente trabalho possui ênfase no desenvolvimento de um sistema de diagnóstico da falha de curto-circuito em estator em MIT, não invasivo, com capacidade de reconhecimento de seu nível de severidade. O sistema de extração de características deve considerar a contribuição da corrente de linha das três fases da máquina, transformados em um sistema bifásico equivalente em coordenadas estacionárias a partir da transformação de Clarke. Ainda, utilizam-se os algoritmos de reconhecimento de padrões MLP, SVM e kNN para verificação da aderência do método de extração de características para submissão a estes modelos de classificadores de padrões.

1.2 JUSTIFICATIVA

Esta metodologia é centrada em uma abordagem de manutenção de motores de indução trifásicos amparada pelo monitoramento da condição de falha de curto-circuito a máquina está sujeita, visto que os MIT são abrangentes em aplicações industriais, sendo utilizados para

execução de diversas funções associadas a equipamentos que necessitam de energia motriz (SOUZA *et al.*, 2022), sendo a falha de curto-circuito em bobinas de estator responsável por uma parcela significativa das paradas não programadas em MIT, que podem resultar em prejuízos financeiros (GONGORA *et al.*, 2016).

Desta maneira, o desenvolvimento de sistemas capazes de diagnosticar a ocorrência de falhas em MIT e acompanhar a evolução do nível de severidade destas condições são aliadas à melhoria do gerenciamento de manutenção e gestão de ativos em âmbito industrial. Neste contexto, utilizam-se como dados de entrada as medições de corrente de linha da máquina, visto que está variável pode ser medida e condicionada de maneira não-invasiva.

1.3 OBJETIVOS

A presente seção aborda os objetivos deste trabalho. O objetivo geral consiste no cerne da pesquisa, ao passo que os objetivos específicos descrevem etapas construtivas da pesquisa para atingimento do objetivo específico.

1.3.1 Objetivo Geral

O objetivo geral deste trabalho consiste em desenvolver um algoritmo para extração de características associadas à ocorrência da falha de curto-circuito, com a utilização da informação mútua deslocada ao considerar a contribuição das três fases de motores de indução trifásicos conectados diretamente à rede de energia elétrica, com o emprego da transformação em coordenadas estacionárias para redução do custo computacional.

1.3.2 Objetivos Específicos

Com o intuito de atingir o objetivo geral do trabalho, são elencados objetivos específicos, tais quais:

- Realizar a transformação de Clarke para sinais de corrente de linha de um motor de indução trifásico a partir de uma base de dados experimentais;
- Desenvolver um algoritmo de cálculo da Informação Mútua entre sinais de corrente elétrica em referencial estacionário;
- Desenvolver um sistema especialista, para classificação do nível de severidade baseado nos modelos de reconhecimento de padrões MLP, SVM e kNN;

- Confrontar o desempenho da metodologia proposta com métodos encontrados na bibliografia;
- Validar a metodologia proposta por meio de dados coletados em laboratório.

1.4 ORGANIZAÇÃO DO TEXTO

Além da introdução, o texto é organizado em outros cinco capítulos. No Capítulo 2 são abordados conceitos sobre MIT, bem como as características construtivas destes equipamentos e as falhas presentes na máquina de indução. Os conceitos relativos à transformação de Clarke, assim como os fundamentos da extração de características a partir da DMI e utilização de classificadores de padrões são apresentados no Capítulo 3.

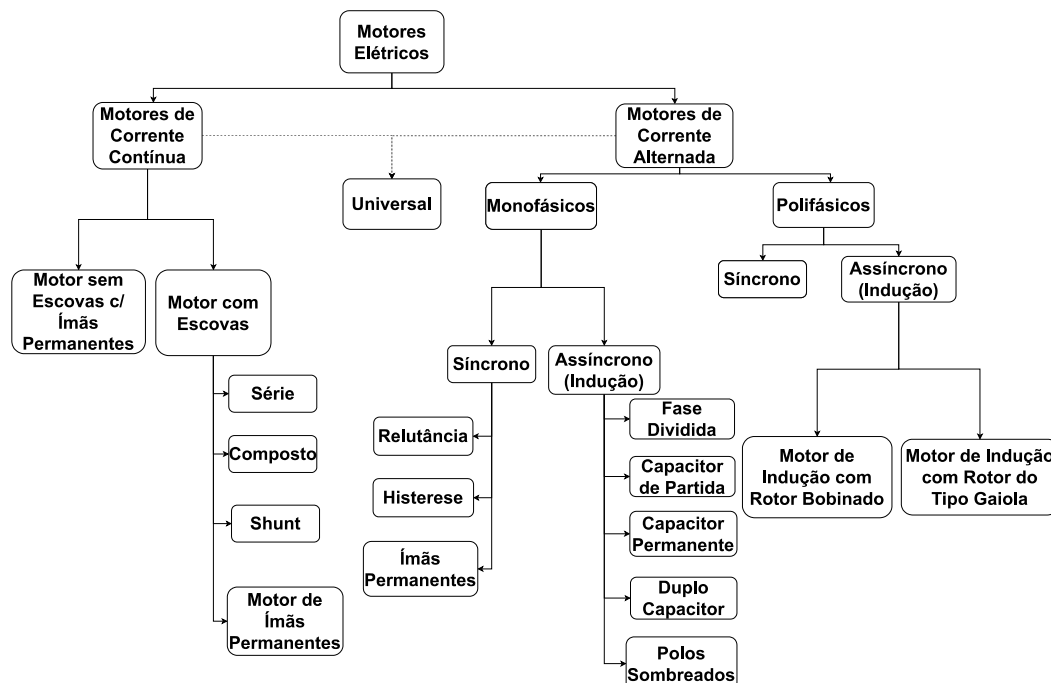
No Capítulo 4 são explorados os aspectos metodológicos associados ao desenvolvimento do algoritmo proposto. No Capítulo 5 são apresentados resultados obtidos a partir de dados provenientes de aquisições em uma bancada de teste, capaz de simular diversas condições de operação de MIT.

Por fim, no Capítulo 6 são apresentadas as considerações finais em relação a utilização do sistema proposto com base nos resultados obtidos.

2 MOTORES DE INDUÇÃO TRIFÁSICOS

Os motores elétricos consistem em um meio atrativo de conversão de energia elétrica em energia mecânica motriz, sendo estes equipamentos considerados máquinas elétricas dinâmicas (CHAPMAN, 2013). O método de aplicação de energia elétrica nos terminais dos motores elétricos pode variar de acordo com o tipo da máquina. Pode-se alimentar motores com tensão em corrente contínua (CC) ou corrente alternada (CA), os motores CA polifásicos consistem no tipo de máquina mais frequente, representando aproximadamente 50% da totalidade de motores comercializados (DE ALMEIDA *et al.*, 2017). A Figura 2 ilustra a categorização de motores elétricos convencionais.

Figura 2: Categorização dos motores elétricos.



Fonte: Adaptado de (ALMEIDA *et al.*, 2008).

Segundo Souza *et al.* (2022), somente três tipos de motores elétricos são majoritariamente

reconhecidos pelo uso na indústria. Inicialmente, destacam-se os motores de corrente contínua, devido à simplicidade de controle de velocidade por meio do controle da tensão de armadura e de enfraquecimento do campo. Todavia, esta tecnologia apresenta desvantagens como elevado custo, necessidade frequente de manutenção, elevado nível de faiscamento em seu comutador e incapacidade de alimentação diretamente pela rede em corrente alternada.

Historicamente os motores síncronos são utilizados em aplicações industriais com demanda por velocidade constante para cargas elevadas. Porém, fatores como alto custo de aquisição e frequente necessidade de dispositivos para suporte na partida contribuem para a delimitação de uso deste tipo de máquina em condições específicas.

Estudos apontam que dentre os motores elétricos com alimentação em corrente alternada polifásicos representam cerca de 72% do valor investido em aquisição de motores com potência entre 0,75 e 375 kW ao redor do mundo. Além disso, os MIT são considerados como um dos tipos de motores com tendência de ganho de relevância no mercado de máquinas elétricas rotativas, junto aos motores de ímãs permanentes (DE ALMEIDA *et al.*, 2017).

2.1 CONSTRUÇÃO DE MOTORES DE INDUÇÃO TRIFÁSICOS

Em termos construtivos, os MIT são constituídos por uma parte estática, denominada estator, e um componente rotativo conhecido como rotor. O estator é resumidamente composto pela carcaça, núcleo e enrolamentos, ao passo que o rotor é composto por seu núcleo, enrolamento e eixo. A constituição das principais partes de um MIT assíncrono são (MUÑOZ, 1987):

- Estrutura: Construção mecânica da máquina, que pode conter ou não suportes em sua base e pode ser descrito como *frame* na placa de identificação do motor, com um código padronizado;
- Núcleo do estator: Empilhamento de chapas moldadas ou estampadas de material ferromagnético isoladas entre si, alojadas no interior da carcaça para formação da parte estática da máquina;
- Bobinas de estator: Enrolamentos de fio condutor isolado alojado em ranhuras do núcleo do estator;
- Rotor: Componente giratório da máquina, em MIT assíncronos denomina-se rotor em curto-circuito ou gaiola de esquilo;

- Núcleo do rotor: Empilhamento de chapas moldadas ou estampadas de material ferromagnético isoladas entre si, alojadas na parte girante da máquina, fixas ao eixo do rotor, com ranhuras;
- Anéis de Curto-Circuito: Elementos circulares empregados em motores de indução assíncronos para curto-circuito entre as barras do rotor;
- Barras do Rotor: Barras que unem os anéis condutores, cujas extremidades permanecem em curto-circuito em MIT assíncronos.

A estrutura de um rotor em curto-circuito é composta por barras condutoras conectadas a anéis. Este conceito de rotor, teve origem nos anos 80, sendo introduzido pela empresa AEG (Allgemeine Elektrizitäts-Gesellschaft) (SOUZA *et al.*, 2022). Atualmente, as barras contidas nos rotores são inclinadas com relação ao eixo, este aspecto construtivo contribui para redução do conjugado de relutância e melhoria do formato senoidal da tensão induzida, atenuando efeitos de harmônicas (BIM, 2018) (MUÑOZ, 1987).

Com relação às vantagens associadas à utilização de MIT com rotor em curto-circuito em comparação com outras tecnologias, pode-se citar (SOUZA *et al.*, 2022):


- Baixo custo de aquisição e manutenção;
- Facilidade de fabricação devido a simplicidade construtiva;
- Simplicidade de reposição devido a alta padronização de carcaças e conexões;
- Elevado tempo de vida útil;
- Alta margem de controle de velocidade quando alimentado por conversores;
- Dimensões compactas;
- Não produz faíscas como no caso de máquinas à comutador ou com anéis deslizantes;
- Maior segurança operacional devido a ausência de contato elétrico entre rotor e estator;
- Capacidade de acionamento por conexão direta da rede, sem obrigatoriedade de uso de conversores;
- Processo produtivo consolidado;
- Abundância de recursos naturais necessários para produção.

Os enrolamentos trifásicos de MIT são espacialmente distribuídos no núcleo ferromagnético do estator (UMANS, 2014). Enrolamentos imbricados são mais abrangentes, principalmente com passo fracionário, visto que esta técnica contribui para a redução de componentes harmônicas e melhora o aspecto senoidal da distribuição espacial de força magnetomotriz (MUÑOZ, 1987), outra técnica comum na fabricação de motores é a montagem com enrolamentos de camada dupla (CHAPMAN, 2013).

Ademais, citam-se os rolamentos rígidos de esfera, que são frequentemente utilizados em MIT, estes elementos auxiliam no suporte do rotor com baixa interferência no movimento de rotação, são frequentemente compostos por um anel interno, um anel externo, esferas e uma gaiola separadora (CARVALHO, 2010). Estes componentes estão frequentemente sujeitos a desgastes por atrito, lubrificação inadequada e eletroerosão (GONGORA *et al.*, 2016).

A Figura 3 ilustra um MIT com partes elétricas e mecânicas em evidência.

Figura 3: Motor de indução trifásico com rotor gaiola de esquilo.



Fonte: Autoria própria (2023).

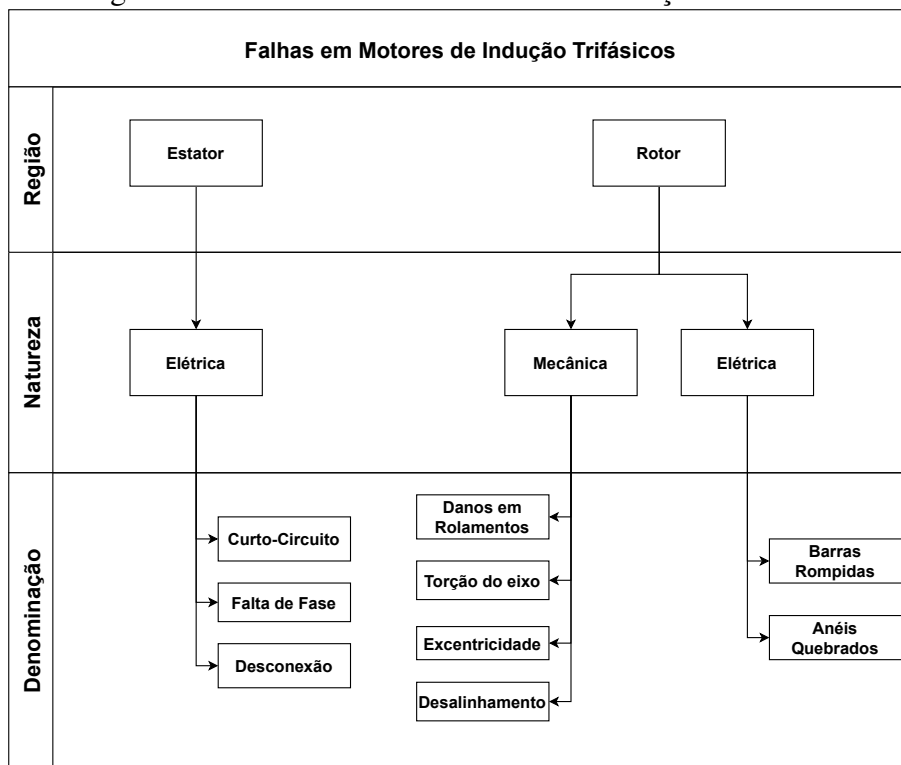
Por fim, destaca-se que em termos de isolamento entre o núcleo e as bobinas, os fios destinados para confecção dos enrolamentos são revestidos por esmalte isolante. Além disso, utilizam-se abas isolantes para separação entre os condutores de fases distintas e para isolamento do núcleo.

2.2 FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

Como todo equipamento eletromecânico, os MIT sofrem com desgastes em suas partes e degradação dos materiais dielétricos que os compõem. Em virtude destes fenômenos, observa-se o surgimento de falhas mecânicas e elétricas na máquina (GUEDES *et al.*, 2019).

As falhas mais comuns em MIT são passíveis de classificação de acordo com sua região de influência, isto é, estator ou rotor. Ainda, pode-se descrever sua natureza como elétrica ou mecânica, estas associações são ilustradas conforme Figura 4. Dentre as falhas do espectro elétrico, pode-se citar a quebra de barras ou anéis do rotor, desconexão e curto-circuito entre espiras de uma mesma bobina do estator, entre fases ou entre fase e carcaça. Por outro lado, as falhas mecânicas são frequentemente associadas à folgas ou danos nos rolamentos, excentricidade do eixo do rotor, torção do eixo e desalinhamento (GODOY *et al.*, 2016).

Figura 4: Falhas comuns em motores de indução trifásicos.



Fonte: Autoria própria (2023).


As falhas em rolamentos são frequentes em MIT, decorrentes dos desgastes mecânicos em que os rolamentos são submetidos, este tipo de falha é objeto de investigação em diversos trabalhos encontrados na literatura (CARVALHO, 2010; GONGORA, 2013). Sendo capaz de afetar, entre outros fatores, a vibração do motor, a temperatura dos enrolamentos e a amplitude de corrente de linha, além de contribuir para o desenvolvimento de outras falhas como o curto-

circuito.

A falha de excentricidade está associada ao desvio da posição do eixo em relação ao seu referencial axial, este tipo de falha pode acarretar variações dimensionais no entreferro, sendo capaz de impactar de maneira severa na distribuição espacial de fluxo magnético entre o rotor e o estator. A torção do eixo pode ocorrer em decorrência de defeitos no acoplamento mecânico entre a máquina e a carga, bem como consequência de condições de conjugado resistente superiores aos valores suportados pela máquina (GODOY *et al.*, 2016; GONGORA *et al.*, 2016; BIM, 2018).

A falta de fase pode ocorrer por divergências na instalação da máquina ou mesmo por desconexão de condutores no interior da máquina ou presentes na infraestrutura de instalação, sendo prejudiciais às bobinas e contribuindo com a queima do equipamento. Apesar disto, estima-se que falhas de estator associadas a ocorrência de curto-circuito representam entre 30% e 40% da totalidade de falhas observadas em MIT (BAZAN *et al.*, 2022). Este tipo de falha pode ser ilustrada a partir do diagrama planejado de um MIT, conforme a Figura 5.

Figura 5: Diagrama planejado com ilustração de falhas de curto-circuito no estator.



Fonte: Autoria própria (2023).

Além disso, o intenso estresse térmico provocado pela ocorrência de curto-circuito resulta em uma rápida dinâmica de evolução, de forma a intensificar o nível de severidade da falha devido ao calor produzido. Frequentemente, faltas severas são reflexo da ocorrência de falhas incipientes, cuja intervenção para reparo não foi gerida.

Ainda, falhas severas no interior de ranhuras são capazes de resultar na fusão entre o material

do fio condutor com as chapas que formam o núcleo do motor, como ilustrado na Figura 6. Este tipo de ocorrência pode inviabilizar a manutenção da máquina, visto que o efeito das correntes de Foucault na região de fusão são intensificadas, com o surgimento de pontos quentes que reduzem a vida útil do material isolante (AL-ALI; DABBOUSI, 2013).

Figura 6: Fusão no núcleo do estator decorrente de curto-circuito.



Fonte: Autoria própria (2023).

2.3 ESTRATÉGIAS PARA IDENTIFICAÇÃO DE FALHAS

A presente seção dedica-se a introdução sobre algumas estratégias comumente encontradas na literatura para observação e diagnóstico de falhas em motores de indução trifásicos.

Em geral, a identificação de falhas em MIT ocorre a partir da leitura de suas variáveis elétricas ou mecânicas. Destacam-se a vibração mecânica, temperatura, som emitido, correntes de linha, tensões elétricas e velocidade de rotação do eixo, como características observadas e associadas entre si para fins de identificação de falhas.

Observa-se que em condições operativas normais, os MIT constituem um sistema elétrico equilibrado. Porém, quando sujeitos à falhas, perde-se o equilíbrio, tornando o fenômeno causador perceptível mediante a análise de sinais, como as vibrações ou distorções nos sinais de corrente elétrica (GONGORA *et al.*, 2016).

Os estudos de Germen, Başaran e Fidan (2014) utilizam-se da aquisição de sinais acústicos a partir de cinco microfones posicionados ao redor da máquina. Os dados amostrados possibilitam a criação de imagens bidimensionais que são submetidas a classificadores de padrões. Neste estudo, parte da energia associada às falhas de rotor e estator tende a contribuir na construção do sinal sonoro, de forma a tornar possível sua identificação.

Em Drif e Cardoso (2007) utiliza-se a aquisição de sinais de corrente elétrica para análise de

componentes espectrais associadas à quebra de barras no rotor. Neste cenário, a falha torna-se detectável devido à reação nos sinais de corrente elétrica à alteração do fluxo magnético no entreferro, cujas assinaturas apresentam frequências especificamente posicionadas na análise espectral.

Ainda no âmbito da análise espectral de sinais, Gongora *et al.* (2018) parte da amostragem de sinais de tensão e corrente de linha da máquina para análise de frequências características relacionadas à ocorrência de falhas nos rolamentos de MIT por meio da FFT.

Estratégias baseadas na análise espectral também podem ser aplicadas à aquisição da vibração mecânica dos MIT, visto que as falhas resultam em vibrações mecânicas axiais, radiais e tangenciais devido aos desgastes em rolamentos ou distorções na distribuição do fluxo magnético no entreferro. O estudo de Seshadrinath, Singh e Panigrahi (2013) utiliza-se deste princípio mediante a utilização de acelerômetros de três eixos para a coleta de dados da máquina, submetendo a informação coletada em bancos de filtros baseados na DTW.

Como anteriormente citado, tanto as falhas de origem mecânica como as de origem elétrica possuem influências de elevação de temperatura em MIT. Neste contexto, existem métodos baseados na aquisição de temperatura dos enrolamentos, núcleo e/ou carcaça da máquina.

Em termos gerais, os métodos mais comuns deste segmento empregam a coleta por sensores de temperatura ou aquisição de imagens termográficas. Utilizando-se deste princípio, Khanjani e Ezoji (2021) recorrem ao processamento de imagens termográficas para identificação da elevação excessiva de temperatura associada à ocorrência de falhas.

Guedes *et al.* (2019) empregam a amostragem de corrente e tensão para estimar por meio de um algoritmo evolutivo variações paramétricas no modelo de regime permanente do motor de indução trifásico. Neste estudo, a falha de curto-circuito entre espiras no estator torna-se visível a partir dos seus efeitos nos sinais das variáveis medidas, que têm influência no valor estimado da indutância de magnetização.

Recorrendo-se exclusivamente da medição dos sinais de corrente de linha de MIT, Bazan *et al.* (2019) aproveitam-se das assinaturas originadas por falhas em rolamentos para identificação desta falha. Além disso, encontra-se na bibliografia estratégias direcionadas à identificação de falhas de curto-circuito mediante a aquisição restrita de corrente elétrica, como em Bazan *et al.* (2022).

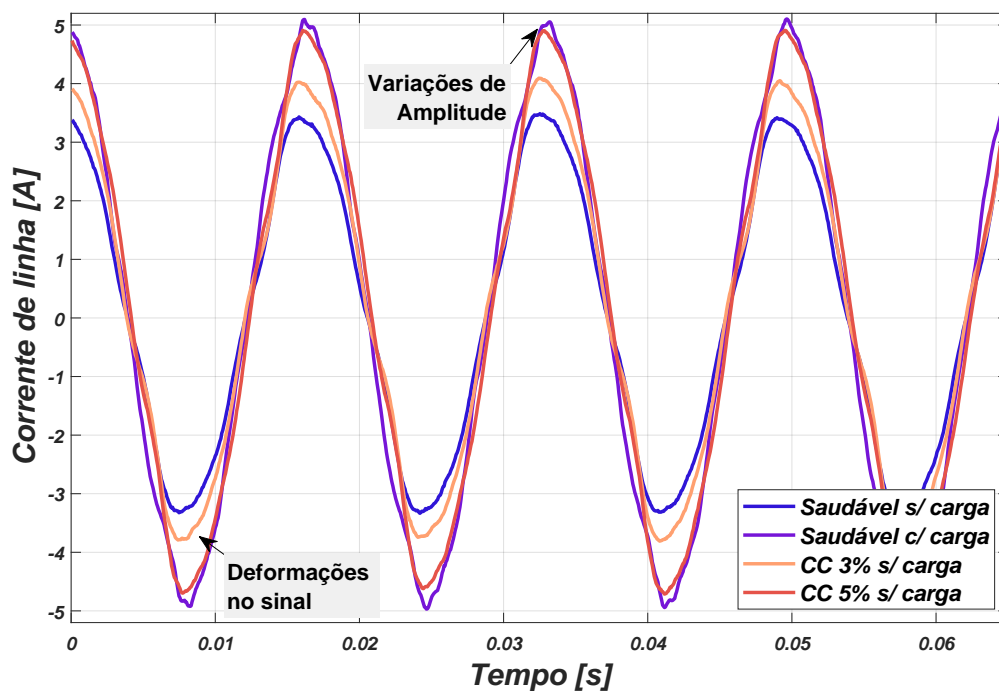
Os sinais de corrente elétrica são consideravelmente sensíveis à ocorrência de falhas mecânicas e principalmente às elétricas, apresentando assinaturas de amplitude e forma quando sujeito às condições de defeito (BAZAN *et al.*, 2021).

Pesquisas recentes buscam lidar com a identificação e acompanhamento da progressão de falhas ainda em seus estágios iniciais, sendo capazes de realizar o diagnóstico da falha mesmo quando a máquina opera em condições de desequilíbrio na tensão de alimentação e sujeita a variadas condições de conjugado de carga aplicado em seu eixo (GUEDES *et al.*, 2019; BAZAN *et al.*, 2022).

A Figura 7 ilustra o comportamento das correntes de estator em MIT sujeitos à falha de curto-circuito, quando em diferentes níveis de severidade relacionados com o percentual de espiras em curto-circuito e com alimentação em uma mesma fonte de tensão. Em geral, variações de amplitude nos sinais de corrente são observadas tanto em condições de falha quanto em variações de conjugado ou quando aplicados desequilíbrios de tensão.

Apesar da frequente relação entre as deformações no sinal de corrente com o conteúdo harmônico na fonte de alimentação. A ocorrência de curto-circuito entre espiras nas bobinas de estator em MIT intensificam este efeito, devido ao impacto da distribuição espacial irregular de força magnetomotriz no entreferro de enrolamentos distribuídos sujeitos à esta condição de falha. Além disso, a elevação na amplitude da corrente elétrica que circular nos enrolamentos de estator podem influenciar na histerese do material do núcleo, acarretando em mais distorções (UMANS, 2014; CHAPMAN, 2013).

Figura 7: Sinais de corrente elétrica em um MIT sujeito a condições de curto-circuito.

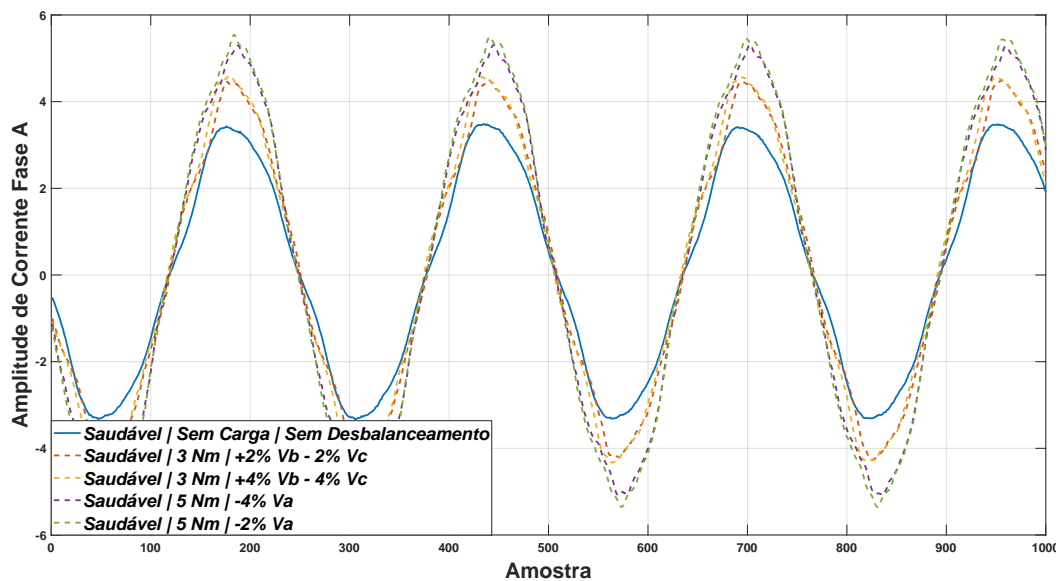


Fonte: Autoria própria (2023).

Por este motivo, encontra-se com frequência em trabalhos recentes o uso de classificadores de padrões baseados em sistemas inteligentes para fins de identificação de falhas (SUETAKE, 2012).

Com o intuito de possibilitar uma comparação, a Figura 8 ilustra as influências de variação de amplitude provocadas por variações de conjugado aplicado ao eixo e desbalanceamento na tensão de alimentação de MIT, que podem ser classificadas erroneamente como falhas incipientes.

Figura 8: Dinâmica da variação de conjugado de carga e desbalanceamento de tensão em MIT.



Fonte: Autoria própria (2023).

Para associar algoritmos de reconhecimento de padrões baseados em sistemas inteligentes, capazes de diferenciar as assinaturas provocadas por falhas de outros efeitos dinâmicos, é comum utilizá-los em conjunto com uma técnica de extração de características.

2.4 SÍNTESE DO CAPÍTULO

No Capítulo 2 são apresentados os principais elementos que compõem os MIT. Além disso, foi abordada a natureza das falhas neste tipo de equipamento e os métodos convencionais encontrados na bibliografia para fins de diagnóstico. Ademais, dá-se ênfase às assinaturas nos sinais de corrente elétrica provocadas por falhas e por efeitos dinâmicos convencionais dos MIT. Estes conceitos são pertinentes para a abordagem de diagnóstico da falha de curto-circuito em MIT do presente projeto.

3 EXTRAÇÃO DE CARACTERÍSTICAS E CLASSIFICAÇÃO DE PADRÕES

O presente capítulo dedica-se à apresentação das ferramentas de extração de características e suas associações, com ênfase nos aspectos aderentes à aplicação proposta.

3.1 A TRANSFORMAÇÃO DE CLARKE

Visando simplificar o processo de cálculo de tensões e correntes em sistemas elétricos sujeito à ocorrência de faltas entre fase e terra, Walter Wallace Lewis introduziu em 1917 a utilização de componentes modais. Sendo modificadas e amplamente difundidas após a publicação do artigo "*Problems Solved by Modified Symmetrical Components*" por Edith Clarke em 1938 (OLIVEIRA *et al.*, 2000).

Para fins de interpretação geométrica dos sistemas de referência e transformações aplicadas em sistemas trifásicos, representações em forma de fasores ou cartesianas são frequentemente utilizadas. Como característica, a representação fasorial representa os componentes do sistema em um espaço vetorial complexo com um eixo real e outro imaginário. No contexto da representação cartesiana, um sistema trifásico pode ser ilustrado como um vetor $\vec{i}(t)$ que varia com o tempo no espaço \mathbb{R}^3 . Uma transformação linear pode ser aplicada neste vetor, na forma da Equação (3.1) (OROURKE *et al.*, 2019).

$$T(\vec{i}) = \mathbf{A} \cdot \vec{i} \quad (3.1)$$

onde \mathbf{A} representa uma matriz de transformação, representada como $\mathbf{C}_{\alpha,\beta}$ no contexto da transformação de Clarke.

Esta ferramenta, conhecida como Transformação de Clarke, utiliza-se de uma transformação linear que representa as variáveis de circuitos elétricos estacionários em um sistema de referência também estacionário, isto é, um modelo em que a velocidade do sistema de referência é nula (GURGEL *et al.*, 2021).

Para desenvolvimento da representação matemática, utilizam-se as forças magnetomotrizes de distribuição senoidal estacionária no espaço produzidas por MIT. Portanto, o estator deste tipo de máquina pode ser representado a partir de uma bobina com N_e espiras alocada no eixo magnético para cada uma das fases, cujo vetor espacial de magnitude da força magnetomotriz no eixo magnético de cada fase é descrito conforme a Equação (3.2) (BIM, 2018).


$$fmm_{fe}(t) = \frac{4}{\pi} \cdot \frac{N_e}{p} \cdot i_{fe}(t) \cdot e^{j\theta}, \quad (3.2)$$

em que fmm_{fe} denota a força magnetomotriz na fase genérica f no referencial do estator, N_e representa o número de espiras efetivo em série para a fase f , p consiste no número de polos da máquina, $i_{fe}(t)$ representa a corrente elétrica de estator da fase f no domínio do tempo. Por fim, $e^{j\theta}$ representa a posição espacial do eixo magnético da respectiva fase.

Um motor de indução trifásico pode ser representado a partir de três componentes de forças magnetomotrizes (fmm_{Ue} , fmm_{Ve} e fmm_{We}) provenientes das correntes que circulam cada fase e com defasagem de 120° (i_{Ue} , i_{Ve} e i_{We}). Desse modo, estas componentes defasadas em 120° podem ser decompostas em componentes ortogonais, cujos eixos são denominados α e β .

Então, a transformação de Clarke representa o modelo trifásico em um sistema bifásico equivalente, cujas bobinas representativas do sistema devem possuir N_{eq} espiras e são excitadas por correntes elétricas equivalentes em quadratura no tempo, denominadas respectivamente $i_{e\alpha}(t)$ e $i_{e\beta}(t)$. A disposição espacial é ilustrada conforme a Figura 9.

Figura 9: Representação dos eixos α e β .



Fonte: Autoria própria (2023).

Assim, a decomposição dos componentes trifásicas de força magnetomotriz em componentes

bifásicas equivalentes é efetuada conforme as Equações (3.3) e (3.4).

$$fmm_{e\alpha}(t) = \frac{4}{\pi} \cdot \frac{N_e}{p} \dots \left[i_{Ue}(t) + i_{Ve}(t)\cos\left(\frac{2\pi}{3}\right) + i_{We}(t)\cos\left(\frac{4\pi}{3}\right) \right] \quad (3.3)$$

$$fmm_{e\beta}(t) = \frac{4}{\pi} \cdot \frac{N_e}{p} \left[i_{Ve}(t)\sen\left(\frac{2\pi}{3}\right) + i_{We}(t)\sen\left(\frac{4\pi}{3}\right) \right] \quad (3.4)$$

Analogamente, a força magnetomotriz nas referências α e β podem ser descritas a partir das Equações (3.5) e (3.6), respectivamente.

$$fmm_{e\alpha}(t) = \frac{4}{\pi} \cdot \frac{N_{eq}}{p} \cdot i_{\alpha e}(t) \quad (3.5)$$

$$fmm_{e\beta}(t) = \frac{4}{\pi} \cdot \frac{N_{eq}}{p} \cdot i_{\beta e}(t) \quad (3.6)$$


A partir das Equações (3.3), (3.4), (3.5) e (3.6). É extraída a relação entre as correntes do sistema trifásico e seu modelo bifásico equivalente, expresso conforme (3.7).

$$\begin{cases} i_{e\alpha}(t) = \frac{N_e}{N_{eq}} \left[i_{Ue}(t) + i_{Ve}(t)\cos\left(\frac{2\pi}{3}\right) + i_{We}(t)\cos\left(\frac{4\pi}{3}\right) \right] \\ i_{e\beta}(t) = \frac{N_e}{N_{eq}} \left[i_{Ve}(t)\sen\left(\frac{2\pi}{3}\right) + i_{We}(t)\sen\left(\frac{4\pi}{3}\right) \right] \end{cases} \quad (3.7)$$

Ainda, é possível representar uma componente de corrente de sequência zero i_0 , com isso, é obtida a expressão matricial. Além disso, a razão $\frac{N_e}{N_{eq}}$ pode ser definida como $\frac{2}{3}$, desse modo o número total de espiras no estator não é afetado com a transformação. Ajustam-se os termos multiplicativos da componente zero do sistema matricial para $\frac{1}{2}$, de forma a garantir a existência de uma solução única e que a matriz seja inversível, possibilitando que a transformação inversa seja verdadeira (BIM, 2018). Logo, têm-se o formato matricial, composto pela matriz de transformação $C_{\alpha,\beta}$ conforme (3.8), a comparação entre o sinal do sistema trifásico e seu equivalente bifásico é ilustrada conforme a Figura 10.

$$\begin{bmatrix} i_{e\alpha}(t) \\ i_{e\beta}(t) \\ i_0(t) \end{bmatrix} = \frac{2}{3} \cdot \begin{bmatrix} 1 & \cos\left(\frac{2\pi}{3}\right) & \cos\left(\frac{4\pi}{3}\right) \\ 0 & \sen\left(\frac{2\pi}{3}\right) & \sen\left(\frac{4\pi}{3}\right) \\ 1/2 & 1/2 & 1/2 \end{bmatrix} \cdot \begin{bmatrix} i_{Ue}(t) \\ i_{Ve}(t) \\ i_{We}(t) \end{bmatrix} \quad (3.8)$$

Figura 10: Comparação sinais transformados.



Fonte: Autoria própria (2023).

A Equação (3.8) é conhecida como o formato padrão da transformação de Clarke (OROURKE *et al.*, 2019). Neste caso, se faz necessário ajusta o valor multiplicativo da matriz de transformação para que se tenha um valor de potência igual ao sistema trifásico originário. Portanto, a Equação (3.8) pode ser ajustada conforme (3.9), expressão que representa a Transformação de Clarke Invariante em Potência (BIM, 2018).

$$\begin{bmatrix} i_e\alpha(t) \\ i_e\beta(t) \\ i_0(t) \end{bmatrix} = \sqrt{\frac{2}{3}} \cdot \begin{bmatrix} 1 & \cos\left(\frac{2\pi}{3}\right) & \cos\left(\frac{4\pi}{3}\right) \\ 0 & \sin\left(\frac{2\pi}{3}\right) & \sin\left(\frac{4\pi}{3}\right) \\ 1/\sqrt{2} & 1/\sqrt{2} & 1/\sqrt{2} \end{bmatrix} \cdot \begin{bmatrix} i_{Ue}(t) \\ i_{Ve}(t) \\ i_{We}(t) \end{bmatrix} \quad (3.9)$$

A Equação (3.9) pode ser reescrita conforme a expressão (3.10).

$$\vec{i}_{\alpha,\beta,0}(t) = \mathbf{C}_{\alpha,\beta} \cdot \vec{i}_{U,V,W}(t) \quad (3.10)$$

em que,

$$\vec{i}_{\alpha,\beta,0}(t) = \begin{bmatrix} i_e\alpha(t) \\ i_e\beta(t) \\ i_0(t) \end{bmatrix} \quad (3.11)$$

$$\mathbf{C}_{\alpha,\beta} = \sqrt{\frac{2}{3}} \cdot \begin{bmatrix} 1 & \cos\left(\frac{2\pi}{3}\right) & \cos\left(\frac{4\pi}{3}\right) \\ 0 & \sin\left(\frac{2\pi}{3}\right) & \sin\left(\frac{4\pi}{3}\right) \\ 1/\sqrt{2} & 1/\sqrt{2} & 1/\sqrt{2} \end{bmatrix} \quad (3.12)$$

$$\vec{i}_{U,V,W}(t) = \begin{bmatrix} i_{Ue}(t) \\ i_{Ve}(t) \\ i_{We}(t) \end{bmatrix} \quad (3.13)$$

É possível realizar o processo inverso, ou seja, a partir de um sistema em referencial estacionário em um sistema bifásico equivalente, retorná-lo para o seu modelo trifásico. Para tanto, utiliza-se a transformação inversa de Clarke, utilizando a matriz de transformação inversa $\mathbf{C}_{\alpha,\beta}^{-1}$. Por se tratar de uma matriz ortogonal, a matriz inversa é igual à sua transposta, portanto a Equação (3.14) expressa a inversão da transformação de Clarke (OROURKE *et al.*, 2019).

$$\begin{bmatrix} i_{Ue}(t) \\ i_{Ve}(t) \\ i_{We}(t) \end{bmatrix} = \sqrt{\frac{2}{3}} \cdot \begin{bmatrix} 1 & 0 & 1/\sqrt{2} \\ \cos\left(\frac{2\pi}{3}\right) & \sin\left(\frac{2\pi}{3}\right) & 1/\sqrt{2} \\ \cos\left(\frac{4\pi}{3}\right) & \sin\left(\frac{4\pi}{3}\right) & 1/\sqrt{2} \end{bmatrix} \cdot \begin{bmatrix} i_e\alpha(t) \\ i_e\beta(t) \\ i_0(t) \end{bmatrix} \quad (3.14)$$

Este processo é possível, visto que o determinante de $\mathbf{C}_{\alpha,\beta}$ não é nulo.

Dentre as características de interesse associadas à transformação de Clarke, pode-se citar:

- Capacidade de simplificação de sistemas trifásicos como os MIT;
- Preservação da sensibilidade à ocorrência de defeitos;
- Preservação das Leis de Kirchhoff (OLIVEIRA *et al.*, 2000).

Com relação à sensibilidade de ocorrência de defeitos, por se tratar de uma transformação linear, as distorções presentes em sinais elétricos são mantidas quando o sistema é sujeito à transformação de Clarke. Além disso, Oliveira *et al.* (2000) ilustra a capacidade de simplificação de defeitos entre fase e terra utilizando-se a representação de um sistema trifásico em termos da transformação de Clarke.

3.2 SIMILARIDADE ENTRE VARIÁVEIS E INFORMAÇÃO MÚTUA DESLOCADA

O interesse na análise comportamental de um conjunto de variáveis é comum no estudo de modelos ou sistemas dinâmicos. Neste contexto, para avaliação do comportamento de similaridade entre séries temporais provenientes de amostras de corrente elétrica em MIT, pode-se recorrer à noções de probabilidade e estatística como ferramenta.

As observações do comportamento de múltiplas variáveis de um sistema frequentemente tornam possível a extração de informações a partir de grupos de dados associados ao comportamento marginal ou conjunto entre variáveis. A partir da análise de frequências marginais e conjuntas, bem como suas distribuições conjuntas pode-se representar o comportamento de variáveis discretas e contínuas, de maneira qualitativa e quantitativa (MAGALHÃES; LIMA, 2015).

De fato, a dinâmica operativa de motores de indução trifásicos apresenta efeitos relacionados, como a elevação na corrente de linha mediante o aumento da carga resistente acoplada ao eixo ou a relação entre os sinais de corrente de fases distintas. Porém, dois sinais senoidais submetidos à defasagem angular de 90° possuem baixa correlação.

Desta maneira, a medida de similaridade entre variáveis é relevante para a aplicação de sistemas de informação para fins de diagnóstico de falhas em MIT, principalmente quando são utilizados conceitos relacionados à teoria da informação como ferramenta.

A teoria da informação aplica-se principalmente, a problemas associados à teoria da comunicação. Porém, Thomas e Joy (2006) apresentam diversos campos em que ferramentas associadas à este campo da ciência se aplicam, como economia, estatística, teoria da probabilidade, termodinâmica e ciência da computação.

Atualmente, os princípios da teoria da informação são incorporados em aplicações diversas. Pesquisas recentes empregam estes conceitos para categorização de voz com o intuito de identificar patologias (SCALASSARA *et al.*, 2009) e medições de similaridade entre imagens representativas de equipamentos de tomografia computadorizada e ressonância magnética (LOECKX *et al.*, 2010). No campo dos MIT estudos que associam elementos da teoria da informação à extração de características são encontrados na literatura (BAZAN *et al.*, 2019), (BAZAN *et al.*, 2017), além de outras aplicações que envolvem o aprendizado de máquina (VERGARA; ESTÉVEZ, 2014).

Os principais elementos que direcionam a aplicação dos princípios da teoria da informação

baseiam-se na capacidade de medição de incertezas ou dependência entre variáveis aleatórias (THOMAS; JOY, 2006), (DIONISIO; MENEZES; MENDES, 2004). A medida de incerteza de uma variável aleatória é definida como Entropia (H). Elevados valores de Entropia podem ser traduzidos em eventos com probabilidade de ocorrência similar, ao passo que probabilidades dispersas de ocorrência refletem em baixa Entropia e pode ser expressa em *bits* conforme a Equação (3.15), ao se considerar uma variável aleatória discreta x , com função de probabilidade $p(x) = Pr\{X = x\}$ em que x pertence ao alfabeto de eventos X (VERGARA; ESTÉVEZ, 2014).

$$H(X) = - \sum_{i=1}^n p(x) \log_2 p(x) \quad (3.15)$$

Ao considerar duas variáveis aleatórias, a análise se torna bidimensional, dando origem à Entropia conjunta e Entropia condicional. Naturalmente o conceito de Entropia aplicado a um par de variáveis aleatórias consiste na Entropia de uma variável adicionada à Entropia condicional da outra, isto é.

$$H(X, Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log_2 p(x, y) \quad (3.16)$$

e

$$H(Y|X) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log_2 p(y|x) \quad (3.17)$$


Portanto, $H(X, Y) = H(X) + H(X|Y)$.

A Entropia conjunta tem como abordagem a soma da incerteza para o caso bidimensional, porém a redução da incerteza da variável aleatória X devido ao conhecimento da variável aleatória Y é denominado informação mútua (I), conforme representado na Equação (3.18) (VERGARA; ESTÉVEZ, 2014).

$$I(X; Y) = \begin{cases} H(Y) - H(Y|X) \\ H(X) - H(X|Y) \\ H(X) + H(Y) - H(X, Y) \end{cases} \quad (3.18)$$

Portanto, as relações entre os conceitos de informação mútua, Entropia conjunta e Entropia condicional são passíveis de representação gráfica por meio do diagrama de Venn, ilustrado conforme a Figura 11.

Figura 11: Relação entre informação mútua e Entropia.



Fonte: Adaptado de (VERGARA; ESTÉVEZ, 2014).

A informação mútua pode ser determinada em termos de funções de probabilidade, conforme expresso em (3.19) (THOMAS; JOY, 2006).

$$I(X; Y) = \sum_{i=1}^n \sum_{j=1}^n p(x_i, y_j) \cdot \log_2 \left(\frac{p(x_i, y_j)}{p(x_i) \cdot p(y_j)} \right) \quad (3.19)$$

Os valores associados às funções de probabilidade podem ser determinados a partir da contextualização dos dados brutos provenientes do conjunto de amostras em uma tabela de frequência conjunta associada às variáveis X e Y . Assim, obtém-se a função de probabilidade conjunta. De forma análoga, determina-se a função de probabilidade marginal a partir da tabela de frequência marginal (MAGALHÃES; LIMA, 2015). Neste contexto, as frequências absolutas para as variáveis X e Y podem ser dispostas em termos de um determinado agrupamento conforme a Tabela 1.

Tabela 1: Tabela de frequência.

Agrupamento	1	2	3	...	j
X	n_{x1}	n_{x2}	n_{x3}	...	n_{xj}
Y	n_{y1}	n_{y2}	n_{y3}	...	n_{yj}

Desta forma, ao utilizar-se das frequências conjuntas $N(n_{xi}, n_{yi})$ pode-se construir a distribuição que representa a probabilidade conjunta das variáveis, representada conforme a Tabela 2.

Tabela 2: Função de probabilidade conjunta.

(X, Y)	$p(x, y)$
$N(n_{x1}, n_{y1})$	$p(x_1, y_1)$
$N(n_{x1}, n_{y2})$	$p(x_1, y_2)$
$N(n_{x1}, n_{y3})$	$p(x_1, y_3)$
$N(n_{x1}, \dots)$	$p(x_1, \dots)$
$N(n_{x2}, n_{y1})$	$p(x_2, y_1)$
$N(n_{x2}, n_{y2})$	$p(x_2, y_2)$
$N(n_{x2}, n_{y3})$	$p(x_2, y_3)$
$N(n_{x2}, \dots)$	$p(x_2, \dots)$
$N(\dots, \dots)$...
$N(n_{xj}, n_{yj})$	$p(x_j, y_j)$

Com isso, dada a quantidade total de agrupamentos N_a , as distribuições de probabilidade conjunta são determinadas a partir das frequências conjuntas $N(n_{xi}, n_{yi})$ conforme a Equação (3.20).

$$p(x_i, y_i) = \left(\frac{N(n_{xi}, n_{yi})}{N_a} \right) \quad (3.20)$$

Analogamente, os termos marginais são descritos conforme as Equações (3.21) e (3.22).

$$p(x_i) = \left(\frac{n_{xi}}{N_a} \right) \quad (3.21)$$

$$p(y_i) = \left(\frac{n_{yi}}{N_a} \right) \quad (3.22)$$

Os conceitos de Entropia e informação mútua são utilizados como ferramenta em estudos relacionados a área de telecomunicações (THOMAS; JOY, 2006).

Ademais, pesquisas recentes aplicam estes conceitos para realizar o diagnósticos de falhas em máquinas elétricas, (PEDROSA, 2016; BAZAN *et al.*, 2017; LEITE, 2018; BAZAN *et al.*, 2021). Destaca-se o baixo custo computacional associado a essas técnicas, tornando-as adequadas para aplicação no contexto de sistemas embarcados (BAZAN *et al.*, 2022).

De acordo com Bazan *et al.* (2016), a DMI consiste em outra medida de informação que busca detectar dependências estatísticas em função de um deslocamento temporal τ . Desta forma, uma série temporal é mantida sem alterações, ao passo que o deslocamento de uma amostra é aplicado sequencialmente à outra, sendo expresso matematicamente conforme a Equação (3.23).

$$I(X; Y^\tau) = \sum_{i=1}^n \sum_{j=1+\tau}^{n+\tau} p(x_i, y_j) \cdot \log_2 \left(\frac{p(x_i, y_j)}{p(x_i) \cdot p(y_j)} \right) \quad (3.23)$$


Tendo isso em vista, pode-se obter a medida de associação entre dois sinais de corrente de linhas provenientes de um MIT ao utilizar a DMI como ferramenta de extração de características, visto que a aplicação do deslocamento temporal τ permite a avaliação de similaridade entre os sinais senoidais inicialmente defasados em 90° , de forma a superar o problema de baixa correlação.

Em virtude da disposição necessária dos dados para determinar as funções de probabilidade e, posteriormente a informação mútua, representa-se os sinais objeto de estudo na disposição de histogramas (BAZAN *et al.*, 2019). O histograma consiste em um arranjo gráfico composto por retângulos cuja base é dada pelas faixas de valores da variável (MAGALHÃES; LIMA, 2015).

Portanto, utilizam-se 16 classes de frequência, com o intuito de comparar os resultados obtidos com estudos recentes que empregam este mesmo parâmetro (BAZAN *et al.*, 2017, 2022). O valor δ que determina o intervalo entre o início e fim de uma barra pode ser expresso em termos de I_α . Então, δ pode ser expresso a partir da Equação (3.24).


$$\delta = \frac{(\max \{I_\alpha\} - \min \{I_\alpha\})}{n_{classes}} \quad (3.24)$$

Graficamente, a divisão dos sinais em 16 partições com intervalo δ é ilustrada conforme a Figura 12.

Figura 12: Partições sinal I_α .

Fonte: Autoria própria (2023).


Para o presente projeto adota-se por convenção a componente α da transformação de Clarke posicionada sobre o fasor associado a componente de corrente de linha com maior amplitude no sistema trifásico originário. Desta forma, a amplitude de I_α é superior ou igual a I_β , conforme ilustrado na Figura 13.

Figura 13: Partições sinais I_α e I_β .

Fonte: Autoria própria (2023).

Em virtude das partições, as contagens de pontos amostrados são agrupadas conforme as divisões em intervalos δ . Logo, a representação gráfica por meio de histogramas apresenta o perfil ilustrado conforme a Figura 14. A frequência observada é utilizada para determinar as funções de probabilidade marginais, conforme Equações (3.21) e (3.22).

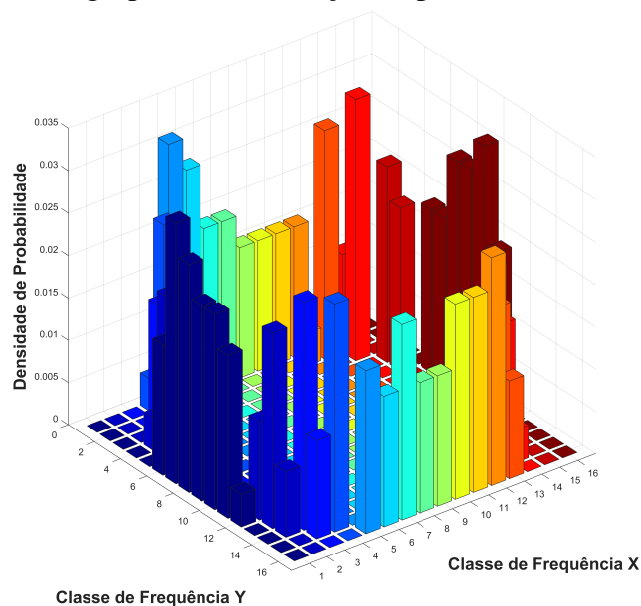
Figura 14: Representação por histograma.



Fonte: Autoria própria (2023).

Ao relacionar os histogramas associados às componentes α e β em sua representação conjunta, pode-se determinar a função de probabilidade conjunta $p(x, y)$, conforme a Equação (3.20). Este agrupamento pode ser representado graficamente conforme a Figura 15.

Figura 15: Agrupamento da função de probabilidade conjunta.




Fonte: Autoria própria (2023).

É necessário observar sobretudo que uma repetição única do processo de determinação dos histogramas e das funções de probabilidade convergem para que se tenha pontualmente a medida de similaridade. Por convenção, a extração de características é realizada aplicando-se o deslocamento τ no conjunto de dados da componente β .

Ressalta-se que o valor de τ pode ser variado conforme a frequência de amostragem adotada para a aquisição de dados para que se tenha um perfil de DMI capaz de quantificar a similaridade para um ciclo completo de medição. Com isso, a característica de DMI deve apresentar traços conforme ilustrado na Figura 16.

Figura 16: Perfil de informação mútua deslocada.



Fonte: Autoria própria (2023).

3.3 SISTEMAS INTELIGENTE APLICADOS À CLASSIFICAÇÃO DE PADRÕES

Segundo Lugosi (2002), o reconhecimento de padrões trata do problema de prever ou adivinhar, a partir de observações, uma classe de pertencimento do conjunto amostral observado que não é previamente conhecido. A divisão em classes consiste em uma representação categórica, em geral as características dos dados associados a uma amostra de entrada possuem a informação que possibilita a um algoritmo de aprendizado de máquina definir a classe que melhor representa esta amostra (ABE, 2005).

O projeto de classificadores de padrões envolve de maneira geral as etapas de aquisição de dados, pré-processamento, representação de dados e tomada de decisões. Além disso, é

conveniente que a estruturação do problema seja bem definida e a base de dados suficientemente representativa para execução do treinamento do algoritmo classificador (BIANCHI, 2006).

Pode-se dividir o treinamento em modelos supervisionado e não-supervisionado. Os modelos supervisionados contém o atributo alvo associado ao conjunto de entradas, de maneira a caracterizar-se como um caso de inferência indutiva. Portanto, o treinamento não-supervisionado independe do conhecimento de valores desejados na saída, sendo o algoritmo de classificação capaz de identificar as particularidades entre os elementos do conjunto de treinamento e formar aglomerações entre amostras de acordo com sua similaridade (SILVA; SPATTI; FLAUZINO, 2010).

O emprego das técnicas de aprendizado de máquina para a resolução de problemas em diversos campos da ciência como aplicações voltadas à medicina e biologia humana (KHUSHABA *et al.*, 2018; SWEENEY; MUSAVI; GUIDI, 1993; MESRABADI; FAEZ, 2018; JAYALAKSHMY; RITHIKA; RAJASRI, 2019), reconhecimento de proteínas termoestáveis (LIU *et al.*, 2008), monitoramento de atividades e gestos (NAZEMI; MALEKI, 2014; ÇATALBAŞ; ÇATALBAŞ; MORGÜL, 2017), controle de acesso (DENG; WANG, 2007), detecção de posicionamento de dispositivos móveis (BAYAR; EFE, 2018), reconhecimento de caracteres e idiomas (MEHTA; SINGLA; MAHAJAN, 2016), processamento e reconhecimento de imagens (BIANCHI, 2006; ZHAN; WANG; XIONG, 2011), segurança cibernética (GAYATHRI, 2017) e estimação paramétrica ou diagnóstico de falhas em MIT (GOEDTEL, 2007; GODOY *et al.*, 2016; BAZAN *et al.*, 2021).

No contexto das aplicações em detecção de falhas em MIT, são frequentemente encontrados na literatura estudos que utilizam algoritmos de reconhecimento de padrões baseados em redes neurais artificiais, máquinas de vetores de suporte e no algoritmo de k -vizinhos mais próximos (PALÁCIOS *et al.*, 2015).

Portanto, a presente seção aborda os conceitos fundamentais destes algoritmos.

3.3.1 Redes Neurais Artificiais do Tipo *Perceptron* Multicamadas - MLP

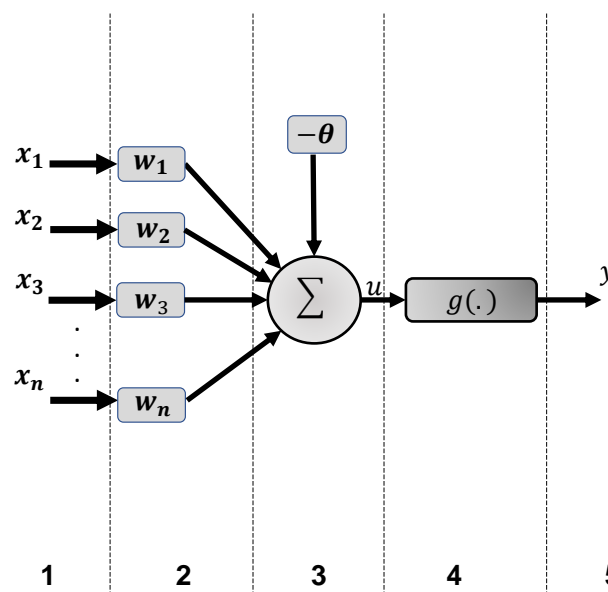
As RNAs são definidas como modelos computacionais bioinspirados que possuem a capacidade de aquisição e manutenção do conhecimento, aptas ao aprendizado por experiência e extrapolação do conhecimento adquirido (SILVA; SPATTI; FLAUZINO, 2010; HAYKIN, 2009).

Neste contexto, estes modelos formam estruturas caracteristicamente paralelas com a habilidade de produzir saídas adequadas para entradas não apresentadas durante a etapa de treinamento. Além disso, têm-se como vantagem associada ao uso de RNAs a tolerância à ocorrência de

falhas, isto é, a obtenção de saídas adequadas é possível ainda que as estruturas do modelo sejam parcialmente danificadas (LUDWIG; COSTA, 2007).

O modelo básico do neurônio artificial parte do conhecimento prévio acerca do comportamento de sistemas nervosos biológicos, garantindo paralelismo e conectividade, conforme a representação da Figura 17 (HAYKIN, 2009).

Figura 17: Modelo de um neurônio artificial.



Fonte: Autoria própria (2023).

Os segmentos que dividem o neurônio artificial representado na Figura 17 representam sequencialmente partes de interesse do modelo de neurônio artificial que possuem respectivamente o conjunto de sinais de entrada (1), pesos sinápticos (2), limiar de ativação (θ) e combinador linear (3), potencial de ativação (4) e sinal de saída (5). Em síntese, os sinais de entrada são provenientes do sistema em estudo, os pesos sinápticos representam fatores de ponderação para cada sinal de entrada do conjunto amostral, o limiar de ativação consiste em uma variável que representa o potencial adequado para que haja um disparo, o combinador linear consiste em um agregador dos sinais de entrada ponderados pelos respectivos pesos sinápticos, cuja diferença representa o potencial de ativação. Por fim, a função de ativação visa limitar a saída do neurônio em um intervalo coerente (SILVA; SPATTI; FLAUZINO, 2010).

As funções de ativação clássicas convencionalmente utilizadas em RNAs do tipo MLP são, degrau unitário, degrau bipolar, rampa simétrica, logística e tangente hiperbólica, cujas expressões matemáticas são representadas sequencialmente conforme as Equações (3.25) a (3.29). Estas funções podem ser graficamente ilustradas conforme a Figura 18.

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (3.25)$$


$$g(u) = \begin{cases} 1, & \text{se } u > 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (3.26)$$

$$g(u) = \begin{cases} a, & \text{se } u > a \\ u, & \text{se } -a \leq u \leq a \\ -a, & \text{se } u < -a \end{cases} \quad (3.27)$$

$$g(u) = \frac{1}{1 + e^{-\beta_c \cdot u}} \quad (3.28)$$

$$g(u) = \frac{1 - e^{-\beta_c \cdot u}}{1 + e^{-\beta_c \cdot u}} \quad (3.29)$$

Figura 18: Funções de ativação.



Fonte: Autoria própria (2023).

Outras funções de ativação são comuns em aplicações que envolvem RNA, dentre as quais pode-se citar as funções unidade linear retificada (do inglês *Rectified Linear Unit - ReLU*), unidade linear exponencial (do inglês *Exponential Linear Unit - ELU*) e *Softmax* (IDE; KURITA, 2017; T.; DEEPA, 2021; HU, 2018; RAO *et al.*, 2019).


Redes neurais artificiais do tipo MLP são frequentemente empregadas em problemas de classificação de padrões, fato que se deve à sua capacidade de aplicação em problemas sem soluções analíticas definidas, ou demasiadamente complexas, além da aplicabilidade a sistemas não lineares e classes não linearmente separáveis. Este tipo de rede neural artificial é composta por ao menos duas camadas formadas por diversos neurônios artificiais (SILVA; SPATTI; FLAUZINO, 2010).

A primeira camada é responsável pelo recebimento dos dados provenientes do sinal a ser analisado, nesta partição da RNA não há, necessariamente, neurônios artificiais. A última camada de uma RNA é denominada camada de saída constituída de neurônios, sendo responsável pela apresentação dos resultados provenientes do processamento da rede. Por fim, denomina-se como camada escondida qualquer camada em uma RNA do tipo MLP posta entre a entrada e a saída (HAYKIN, 2009; SILVA; SPATTI; FLAUZINO, 2010; LUDWIG; COSTA, 2007).

Além disso, o algoritmo empregado é denominado *backpropagation*, que pode ser dividido em duas etapas. A primeira denominada *forward* consiste na apresentação do conjunto de amostras à entrada da rede neural artificial, com isso, estes valores se propagam através das ponderações dos pesos sinápticos e funções de ativação de cada neurônio produzindo um determinado valor de saída. Assim, o algoritmo de treinamento inicia a etapa de propagação reversa *backward*, em que o erro da saída é verificado, os gradientes locais são determinados e por fim ajustam-se os pesos sinápticos e limiares de ativação, de maneira a reduzir a soma dos erros nas épocas posteriores. O detalhamento das etapas do algoritmo *backpropagation* para fins de implementação de redes neurais artificiais do tipo MLP são descritos detalhadamente em (SILVA; SPATTI; FLAUZINO, 2010).

No contexto das redes neurais artificiais do tipo MLP, cada entrada é apresentada a todos os neurônios da camada à frente, mediante a ponderação pelo respectivo peso sináptico. Por se tratar de uma composição de múltiplos neurônios por camada, o conjunto de pesos sinápticos em cada camada apresenta estrutura matricial com dimensões (i, j) em que i representa a quantidade de elementos na camada de destino e j a quantidade de elementos na camada de origem. A Figura 19 ilustra uma arquitetura MLP com n entradas, 14 neurônios na primeira camada escondida, 9 neurônios na segunda camada escondida, 3 neurônios na terceira camada escondida e 1 neurônio na camada de saída.

Figura 19: Ilustração arquitetura MLP.



Fonte: Autoria própria (2023).

Mediante a conclusão da etapa de treinamento, os pesos sinápticos permanecem ajustados para retenção do aprendizado obtido. Portanto, a etapa *forward* é passada a conjuntos de sinais de entrada do sistema a ser diagnosticado.

Estratégias envolvendo redes neurais artificiais do tipo MLP são de frequente utilização para as técnicas de diagnóstico de falhas em MIT encontradas na literatura (BARZEGARAN; MAZLOOMZADEH; MOHAMMED, 2013; DONGARE *et al.*, 2022).

A pesquisa de Barzegaran, Mazloomzadeh e Mohammed (2013) utiliza-se da medição de fluxo magnético radiado por meio de uma antena com intervalo de frequência de recepção entre 20 e 500 kHz afastada em 30 cm da máquina para identificação da falha de curto-circuito nas bobinas do estator de MIT, mediante a leitura por analisador espectral, considerando-se também condições de desequilíbrio na corrente de linha da máquina. A classificação de padrões é baseada em RNA do tipo *perceptron* multicamadas, com 85% das amostras destinadas para treinamento, 10% para validação e 5% para teste.

Dongare *et al.* (2022) recorrem às redes neurais artificiais do tipo MLP para o reconhecimento de padrões defeituosos de motores de indução trifásicos quando sujeitos à falha de excentricidade estática (*em inglês Static Eccentricity - SEC*), dinâmica (*em inglês Dynamic Eccentricity - DEC*) e mista (*em inglês Mixed Eccentricity - MEC*) e suas possíveis combinações. Para tanto, são apresentados como dados de entrada as correntes de linha e tensões de alimentação das três fases,

temperatura dos enrolamentos, temperatura dos rolamentos, temperatura da carcaça da máquina, velocidade de rotação, ruído sonoro e fator de potência, sendo as amostras separadas em um conjunto de testes com 70% da totalidade, 15% para validação cruzada e 15% para testes, com o atingimento de taxas de acerto na ordem de 98%.

3.3.2 Máquina de Vetores de Suporte - SVM

A máquina de vetores de suporte consiste em uma técnica dentre as mais populares para aplicação em problemas de classificação de padrões, com sucesso em algumas aplicações práticas (PASHAEI; YILMAZ; AYDIN, 2016; PARVEEN; SINGH, 2015). Esta ferramenta dedica-se a busca de hiperplanos separadores entre as classes de amostras com a melhor margem possível (SUYKENS; SIGNORETTO; ARGYRIOU, 2014).

Dentre as características da SVM, a separação de duas classes ocorre mediante a resolução de problemas de otimização matemática de funções quadráticas, de forma a originar hiperplanos separadores ótimos (ABE, 2005).

Casos de maior simplicidade são passíveis de reconhecimento por meio de ferramentas que lidam exclusivamente com classes linearmente separáveis. No contexto da SVM, a técnica de margem rígida (*em inglês Hard-Margin Support Vector Machines - HMSVM*) é utilizada para solução de problemas desta natureza, sendo capaz de separar duas classes a partir de um hiperplano descrito conforme a Equação (3.30), em que \mathbf{w} consiste em um vetor de dimensão m , \mathbf{x} representa as i entradas e b representa um termo *bias* (ABE, 2005; SUYKENS; SIGNORETTO; ARGYRIOU, 2014).

$$D(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + b \quad (3.30)$$

Desta maneira, a separação entre classes ocorre conforme a desigualdade expressa conforme a Equação (3.31).

$$D(x_i) = \begin{cases} \geq 1, & \text{para } y_i = 1 \\ \leq -1, & \text{para } y_i = -1 \end{cases} \quad (3.31)$$

O hiperplano $D(\mathbf{x})$ pode ser representado entre dois hiperplanos auxiliares posicionados nas margens -1 e 1 , conforme a Equação (3.32). Com isso, origina-se a margem que constitui-se a partir da distância entre o ponto amostral mais próximo do hiperplano separador, cuja região de generalização da função de decisão consiste no intervalo $\{\mathbf{x} \mid -1 \leq D(\mathbf{x}) \leq 1\}$ (ABE, 2005).

$$D(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + b = c \quad | -1 < c < 1 \quad (3.32)$$

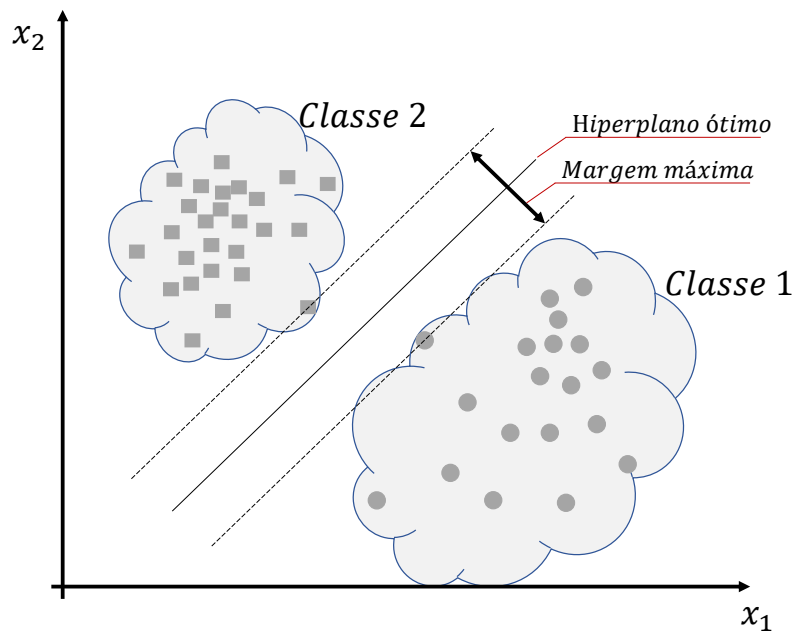
Portanto, os dados de treinamento devem satisfazer a condição relacional com a margem δ_s , conforme a Equação (3.33).

$$\frac{D(\mathbf{x}_k)}{\|\mathbf{w}\|} \geq \delta_s \quad (3.33)$$

Assim, o hiperplano separador ótimo é obtido a partir da minimização da Equação (3.34). Com isso, obtém-se a estrutura de separação ilustrada na Figura 20.

$$Q(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (3.34)$$

Figura 20: Separação de classes HMSVM.



Fonte: Autoria própria (2023).

O problema de minimização apresentado na Equação (3.34) pode ser expandido e representado em termos dos multiplicadores de Lagrange não negativos α_i , conforme a Equação (3.35).

$$Q(\mathbf{w}, b, \alpha) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^M \alpha_i \{y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1\} \quad (3.35)$$

A condição de separação não linear é frequente em aplicações de engenharia (SILVA; SPATTI; FLAUZINO, 2010), por este motivo a HMSVM pode não ser a estrutura baseada na máquina de vetores de suporte mais adequada para aplicação em situações em que a separação entre classes não é linear.

Com o intuito de prover solução adequada para aplicações com esta característica, utilizam-se máquinas de vetores de suporte de margem suave (*em inglês Soft-Margin Support Vector Machines - SMSVM*). Então, são introduzidas variáveis de folga ξ_i , esta adição implica na redução de margem para os pontos em que $0 < \xi_i < 1$ e o problema de minimização passa a considerar a obtenção do hiperplano ótimo em que a quantidade de pontos cuja margem não atinge o valor máximo é mínimo, conforme a minimização da Equação (3.36) (ABE, 2005).

$$Q(\mathbf{w}) = \sum_{i=1}^M \theta(\xi_i) \quad (3.36)$$

onde

$$\theta(\xi_i) = \begin{cases} 1, & \text{para } \xi_i > 0 \\ 0, & \text{para } \xi_i = 0 \end{cases} \quad (3.37)$$

Portanto, a Equação (3.35) pode ser reescrita para a abrangência de casos não linearmente separáveis em termos das variáveis de folga ξ_i e dos multiplicadores de Lagrange não negativos α_i, β_i . Ainda, o parâmetro C é adicionado para ponderação da relação entre maximização da margem e minimização do erro de classificação, conforme a Equação (3.38) (ABE, 2005).

$$Q(\mathbf{w}, b, \xi, \alpha, \beta) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^M \xi_i - \sum_{i=1}^M \alpha_i (y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1 + \xi_i) - \sum_{i=1}^M \beta_i \xi_i \quad (3.38)$$

Além disso, a adição de um *kernel* pode mapear a função de decisão $D(x)$ a partir do vetor de entrada \mathbf{x} m -dimensional em um espaço de l dimensões denominado espaço de características. Portanto, a função de decisão pode ser reescrita conforme a Equação (3.39) (ABE, 2005).

$$D(\mathbf{x}) = \mathbf{w}^T \cdot g(\mathbf{x}) + b \quad (3.39)$$

Esta alteração simplifica a classificação em problemas não linearmente separáveis, tendo como principal vantagem a possibilidade de manipular uma função simétrica do formato $H(\mathbf{x}, \mathbf{x}')$ que cumpre a teoria de Hilbert-Schmidt, não sendo necessário operar com a função $g(\mathbf{x})$ direta-

mente quando esta satisfaz a condição da Equação (3.40) (ABE, 2005).

$$H(\mathbf{x}, \mathbf{x}') = g^T(\mathbf{x}) \cdot g(\mathbf{x}') \quad (3.40)$$

Para a SVM aplicada neste projeto, utiliza-se o *kernel* de função de base radial de característica gaussiana (*em inglês Radial Basis Function - RBF*), expresso conforme a Equação 3.41 em que γ consiste em um hiper parâmetro com influência no raio da RBF, conseqüentemente, alterando a capacidade de generalização do modelo (ABE, 2005).

$$H(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (3.41)$$

Assim como o caso das RNAs, classificadores de padrões baseados em SVM são encontrados com frequência na literatura, devido a características como bom desempenho de classificação e possibilidade de treinamento com base de dados reduzida em comparação às redes neurais artificiais do tipo MLP (SUYKENS; SIGNORETTO; ARGYRIOU, 2014).

Konar e Chattopadhyay (2011) aplicam a SVM para detecção da falha de rolamentos em MIT a partir da aquisição de sinais de vibração da carcaça e aplicação da transformada *wavelet* contínua (*em inglês Continuous Wavelet Transform - CWT*). Neste estudo, a carga aplicada ao eixo é variada entre 0%, 50% e 100% do valor nominal e comparou-se o desempenho da taxa de acerto obtida na classificação com um classificador baseado em RNA, em que a abordagem com a máquina de vetores de suporte apresentou melhor desempenho geral.

Ainda, Li *et al.* (2013) utilizam o classificador SVM para identificação do desvio de pista das esferas dos rolamentos de MIT operando em conjunto com o algoritmo de otimização melhorado bioinspirado em colônias de formigas (*em inglês Improved Ant Colony Optimization - IACO*), 120 amostras são utilizadas para treinamento do modelo e 80 amostras destinadas à calibração e teste em uma primeira abordagem e posteriormente alterado para 80 amostras para treinamento e 120 para as etapas de validação. Os autores apresentam resultados com taxas de acerto de 93,75% e 92,50% nos respectivos cenários.

3.3.3 k-Vizinhos Mais Próximos - kNN

O algoritmo aprendizado de máquina dos k-vizinhos mais próximos consiste em um modelo estatístico de padrões a partir do cálculo de proximidade entre conjuntos de classes previamente conhecidas (BAZAN, 2020; LAAKSONEN; OJA, 1996).

Devido à confinidade entre a razão de erro assintótico obtido por classificadores baseados

no algoritmo kNN com a classificação teórica do Teorema de Bayes, este tipo de classificador é frequentemente utilizado como referência de comparação quando novos métodos para reconhecimento de padrões são propostos (LAAKSONEN; OJA, 1996).

Além disso, trata-se de um método de simples implementação quando comparado às RNA do tipo MLP, visto que a distância entre vizinhos pode ser determinada com base na distância Euclidiana, conforme a Equação (3.42) (ASTUTI *et al.*, 2018).

$$D = \sqrt{\sum_{i=1}^d (x_i - x_{ki})^2} \quad (3.42)$$

Assim, determina-se um valor de afiliação associado à vizinhança da amostra, de forma a relacioná-la com uma das classes existentes (ASTUTI *et al.*, 2018).

Aplicações do classificador de padrões baseado na análise de k-vizinhos mais próximos para a problemática da detecção de falhas em máquinas elétricas são encontradas na literatura.

Ondel, Boutleux e Clerc (2006) empregam o algoritmo de k-vizinhos mais próximos para a classificação de falhas de rolamentos em MIT, sujeitos a variação de conjugado aplicado ao eixo nas condições de 0%, 25%, 50% e 75% de seu valor nominal. Neste estudo sinais de corrente de linha e tensão de alimentação da máquina são coletados e submetidos à análise no domínio da frequência.

No estudo de Ebrahimi *et al.* (2013), o classificador kNN é utilizado para identificar o tipo de excentricidade em um sistema de diagnóstico de falhas de excentricidade em motores síncronos de ímãs permanentes (*em inglês Permanent Magnet Synchronous Motors - PMSM*) mediante a medição dos sinais de corrente de linha da máquina.

3.4 SÍNTESE DO CAPÍTULO

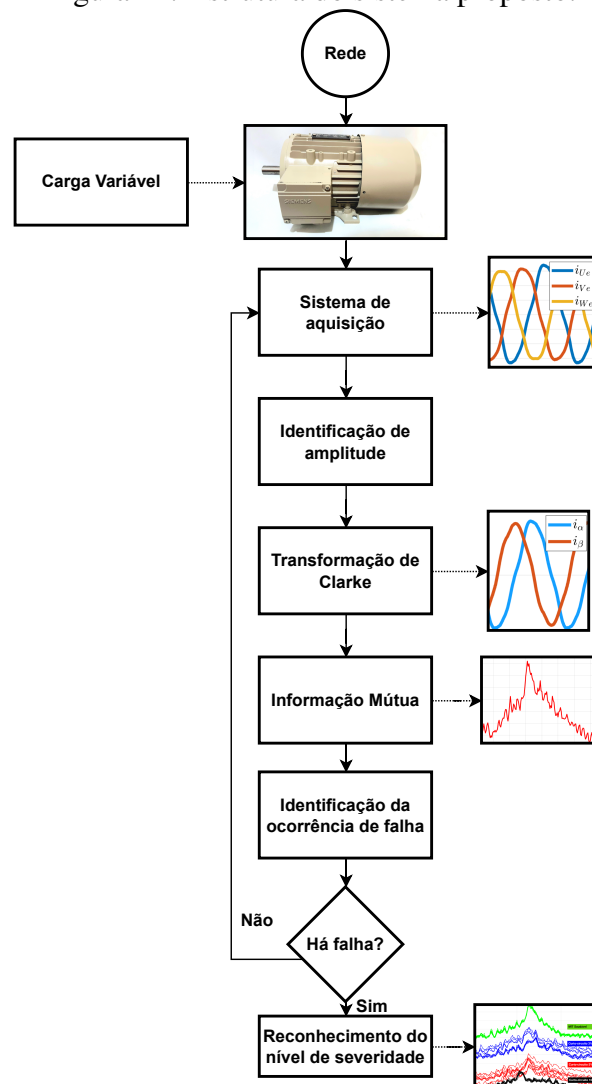
No Capítulo 3 foram apresentados os fundamentos relacionados à extração de características a partir da DMI, bem como os conceitos associados à transformação de Clarke, que torna possível a representação de um sistema trifásico em um modelo bifásico equivalente. Estes conceitos fundamentam a abordagem de diagnóstico da falha de curto-circuito em MIT do presente projeto.

Além disso, descreveu-se as principais características dos métodos de reconhecimento de padrões baseados em redes neurais artificiais do tipo *Perceptron* multicamadas, máquina de vetores de suporte e k-vizinhos mais próximos, que são encontrados na literatura em aplicações relacionadas ao diagnóstico de falhas em MIT.

4 METODOLOGIA

O Capítulo 4 destina-se à apresentação dos aspectos metodológicos relacionados ao diagnóstico da falha de curto-circuito em MIT com a utilização do conceito de DMI em sinais submetidos à transformação de Clarke. A estrutura do sistema proposto é ilustrada conforme a Figura 21.

Figura 21: Estrutura do sistema proposto.



Fonte: Autoria própria (2023).

O diagrama de blocos expresso na Figura 21 representa uma sequência de ações executadas no contexto da metodologia proposta. Inicialmente, o sistema de aquisição dedica-se à amostragem e condicionamento dos sinais de corrente de linha das fases. Posteriormente, identifica-se a amplitude dos sinais para posicionamento da componente α sobreposta à fase cuja corrente apresenta o maior valor de pico. Assim, a transformação de Clarke é aplicada para representação dos sinais trifásicos em um sistema bifásico equivalente, possibilitando então o cálculo da DMI.

A partir da geração de um perfil de DMI, aplica-se um modelo de aprendizado de máquina para identificação da ocorrência de falha. Caso haja falha, uma nova etapa de reconhecimento de padrões é iniciada para determinar o nível de severidade em que o defeito se encontra.

Ressalta-se a necessidade de conduzir etapas de treinamento adequadas para que os blocos de identificação da ocorrência de falha e reconhecimento do nível de severidade atinjam resultados satisfatórios. Desta forma, são abordados no presente capítulo os aspectos de aquisição experimental dos dados utilizados para diagnóstico em motores de indução sujeito à alimentação diretamente provida pela rede de energia elétrica sob condições de desbalanceamento na tensão de alimentação. Ademais, os procedimentos relativos a formação do conjunto de dados e a aplicação dos conceitos abordados no Capítulo 3 são direcionados no contexto da aplicação proposta. Assim, pode-se estabelecer a elaboração do sistema proposto a partir dos aspectos listados abaixo.

- Aquisição e tratamento de dados
- Pré-processamento
- Extração de características
- Reconhecimento de padrões

A etapa de aquisição e tratamento de dados apresenta os conceitos básicos e parâmetros de aquisição destinados para as etapas de treinamento e validação dos modelos de aprendizado de máquina. Assim, são descritos os materiais e equipamentos disponíveis para a amostragem dos sinais de corrente elétrica, bem como a distribuição do conjunto de amostras e os aspectos de balanceamento entre as condições de severidade, desbalanceamento de tensão e conjugado resistente. Em termos da condição operacional dos testes, características de rede de energia desfavoráveis ao sistema de diagnóstico são utilizadas com o intuito de desenvolver o sistema de reconhecimento de padrões de maneira robusta ao considerar condições agressivas a que MIT podem estar sujeitos em âmbito industrial.

Além disso, define-se como pré-processamento a estruturação e organização dos dados provenientes da amostragem, incluindo a aplicação da transformação de Clarke.

Ainda, variados níveis de severidade da falha de curto-circuito são utilizadas para diagnóstico, em um primeiro momento visando a identificação da ocorrência ou não desta falha. Posteriormente integrada a um sistema de diagnóstico de maior abrangência, com capacidade de apontar o nível de severidade de curto-circuito entre espiras do estator a qual a máquina é submetida.

Devido à necessidade de manter o conjunto de dados destinado ao treinamento dos classificadores de padrões devidamente representativo e equilibrado, as diferentes combinações possíveis, associadas aos cenários de conjugado de carga, nível de severidade e condição de desequilíbrio da tensão de alimentação, são estruturadas para apresentação ao sistema de maneira equilibrada, todavia em sequência aleatória.


Portanto, as etapas necessárias para o desenvolvimento do sistema de diagnóstico proposto são apresentadas no presente capítulo conforme a sequência abaixo.

4.1 AQUISIÇÃO E ORGANIZAÇÃO DE DADOS

Para a reprodução das condições operacionais do MIT, utilizou-se na etapa de aquisição de dados a estrutura disponível no Laboratório de Sistemas Inteligentes (LSI) do Centro Integrado de Pesquisa em Controle e Automação (CIPECA) da Universidade Tecnológica Federal do Paraná Campus Cornélio Procópio (UTFPR-CP). Este arranjo possibilita a medição e análise de grandezas elétricas e mecânicas de MIT sujeitos à estudos, sendo aplicada em diversas pesquisas do ramo que empregam medidas de corrente elétrica de linha, velocidade de rotação do eixo, aplicação de variações de conjugado resistente, desequilíbrio de tensão e análise vibratória (GOEDTEL, 2007; BRONIERA *et al.*, 2013; GONGORA, 2013; COSTA *et al.*, 2015; GONGORA *et al.*, 2016; GODOY *et al.*, 2016; BAZAN *et al.*, 2016, 2017, 2019; BAZAN, 2020; BAZAN *et al.*, 2021; GUEDES *et al.*, 2018, 2019; BAZAN *et al.*, 2022).

Este arranjo é composto por uma bancada com o MIT destinado aos testes, acoplado a um gerador de corrente contínua por meio de acoplamentos elásticos associados a um torquímetro digital. Além disso, há um painel com variadores de tensão individuais para cada fase para reprodução de desequilíbrios seletivos na tensão de alimentação da máquina. A carga acoplada ao eixo é controlada a partir da excitação controlada do gerador de corrente contínua (GCC) por meio da fonte de alimentação externa. Bem como a seleção de carga de dissipação associada ao GCC, com seleção a partir do painel destacado na Figura 22.

Figura 22: Estrutura de testes e aquisição de dados.



Fonte: Autoria própria (2023).

A aquisição dos sinais de corrente de linha provém de sensores de efeito Hall em placas de aquisição e condicionamento de sinais, que são amostrados por um sistema de aquisição de dados *DAQ USB-6221* do fabricante *National Instruments*, modelo que oferece 2 saídas analógicas de 833 kS/s , 24 portas digitais multipropósito e 16 entradas analógicas com resolução de 16 bits. A taxa de amostragem é configurada a $15,5 \text{ kHz}$, resultando em 260 amostras por ciclo na frequência da rede. O sistema de aquisição é conectado à estação de trabalho destacada conforme a Figura 22. As características dos MIT utilizados para aquisição de dados são descritas conforme a Tabela 3.

Tabela 3: Características dos MIT utilizados.

Motor	M1	M2
Fabricante	WEG	WEG
Potência nominal [kW]	0.74	1.48
Tensão nominal [V] (Δ/Y)	220/380	220/380
Corrente nominal [A]	3.02/1.75	6.16/3.57
Frequência [Hz]	60	60
Rotação nominal [rpm]	1730	1750
Torque [$N \cdot m$]	4.1	8.17

Ressalta-se que, os motores utilizado possuem enrolamentos adaptados para que o nível de severidade de curto-circuito entre espiras seja propositalmente induzido a partir de derivações. Para tanto, foi realizado um processo de rebobinagem, respeitando-se suas características originais como seção nominal do fio esmaltado, quantidade de espiras por conjunto de bobina e classe

de isolamento . Além disso, foram realizados testes com diferentes níveis de desbalanceamento entre as fases e diferentes condições de carga acoplada ao eixo do motor,. conforme dados representados nas Tabelas 4 e 5, respectivamente.

Tabela 4: Condições de desbalanceamento de tensão.

Condição de Desbalanceamento	D1	D2	D3	D4
Fase U	0%	0%	0%	+2%
Fase V	0%	+2%	+4%	0%
Fase W	0%	-2%	-4%	0%

Tabela 5: Condições de variação do conjugado de carga.

Condição Conjugado	T1	T2	T3	T4	T5	T6
Torque em relação ao valor nominal	0%	25%	50%	75%	100%	120%

Apenas as amostras do motor M1 são utilizadas para o desenvolvimento do sistemas de reconhecimento de padrões. Para o caso deste motor, o conjunto de amostras disponíveis é distribuído de forma a garantir a devida abrangência para cada condição possível. Portanto, 6048 amostras de DMI, individualmente provenientes de 260 aquisições de corrente de linha, são destinadas para implementação do sistema de diagnóstico. Neste contexto, a organização das amostras entre as condições possíveis segue a distribuição da Tabela 6, em que destaca-se o agrupamento de amostras em termos da severidade da falha, condição de desbalanceamento de tensão e regime de conjugado de carga.

Tabela 6: Organização dos dados amostrais.

Condição	Amostras M1	Amostras M2
Motor Saudável	3024	162
Curto-Circuito Severidade 5%	1008	160
Curto-Circuito Severidade 3%	1008	160
Curto-Circuito Severidade 10%	1008	160
Condição desbalanceamento 1	1512	214
Condição desbalanceamento 2	1512	214
Condição desbalanceamento 3	1512	-
Condição desbalanceamento 4	1512	214
Condição Conjugado 1	1008	107
Condição Conjugado 2	1008	107
Condição Conjugado 3	1008	107
Condição Conjugado 4	1008	107
Condição Conjugado 5	1008	107
Condição Conjugado 6	1008	107

Os conjuntos de dados representados conforme a Tabela 6 são compartilhados entre as diversas condições possíveis. Desta forma, a Tabela 7 reproduz os agrupamentos de dados entre condições.

Tabela 7: Combinações de dados amostrais de M1 por condição.

Condição	Saudável	3% CC	5% CC	10% CC
T1	504	168	168	168
T2	504	168	168	168
T3	504	168	168	168
T4	504	168	168	168
T5	504	168	168	168
T6	504	168	168	168
Condição	Saudável	3% CC	5% CC	10% CC
D1	756	252	252	252
D2	756	252	252	252
D3	756	252	252	252
D4	756	252	252	252
Condição	D1	D2	D3	D4
T1	252	252	252	252
T2	252	252	252	252
T3	252	252	252	252
T4	252	252	252	252
T5	252	252	252	252
T6	252	252	252	252

No contexto do motor M2, são formadas 642 amostras de DMI a partir das aquisições dos sinais de corrente, as aquisições compreendem condições de conjugado de $0,5N \cdot m$ a $9N \cdot m$, sujeito às mesmas condições de severidade de curto-circuito observadas em M1 e condições de desbalanceamento de tensão de até 2%. Estes dados são destinados exclusivamente para a etapa de validação, sem adição de nenhuma amostra para reforço no treinamento dos modelos de aprendizado de máquina, os agrupamentos por condição são descritos conforme a Tabela 8.

Tabela 8: Combinações de dados amostrais de M2 por condição.

Condição	Saudável	3% CC	5% CC	10% CC
T1	27	27	27	27
T2	27	27	27	27
T3	27	27	27	27
T4	27	27	27	27
T5	27	26	26	26
T6	27	26	26	26

Condição	Saudável	3% CC	5% CC	10% CC
D1	54	54	54	54
D2	54	53	53	53
D3	-	-	-	-
D4	54	53	53	53

Condição	D1	D2	D3	D4
T1	36	36	-	36
T2	36	36	-	36
T3	36	36	-	36
T4	36	36	-	36
T5	35	35	-	35
T6	35	35	-	35

Por fim, destaca-se que os procedimentos relacionados à geração da base de dados utilizados no presente trabalho são descritos em maiores detalhes nos trabalhos de Palácios (2016).

4.2 PRÉ-PROCESSAMENTO

O pré-processamento consiste em uma etapa relevante para o desempenho da metodologia adotada neste trabalho, cujo objetivo consiste na formatação dos dados de maneira adequada à aplicação da DMI para extração de características. Neste contexto, emprega-se o software MATLAB[®] para execução dos cálculos necessários neste passo.

Em princípio, os dados provenientes da aquisição são importados no MATLAB[®] e organizados em forma de vetores para viabilizar as operações matemáticas pertinentes à transformação de Clarke. Porém, para padronização das características dos sinais sujeitos às operações aplicam-se rotinas auxiliares para garantir o alinhamento da componente α da transformação de Clarke

sincronizada com o sinal de corrente de maior amplitude.

Além disto, o conjunto amostral é segmentado conforme as características descritas na Tabela 2, em que cada conjunto amostral provém de 260 pontos de corrente elétrica representada na componente α e 410 associadas à componente β devido ao deslocamento de 150 amostras necessário para aplicação da DMI. Desta forma, os vetores que contém os dados de corrente de linha são segregados em grupos com menor quantidade de medições pontuais.

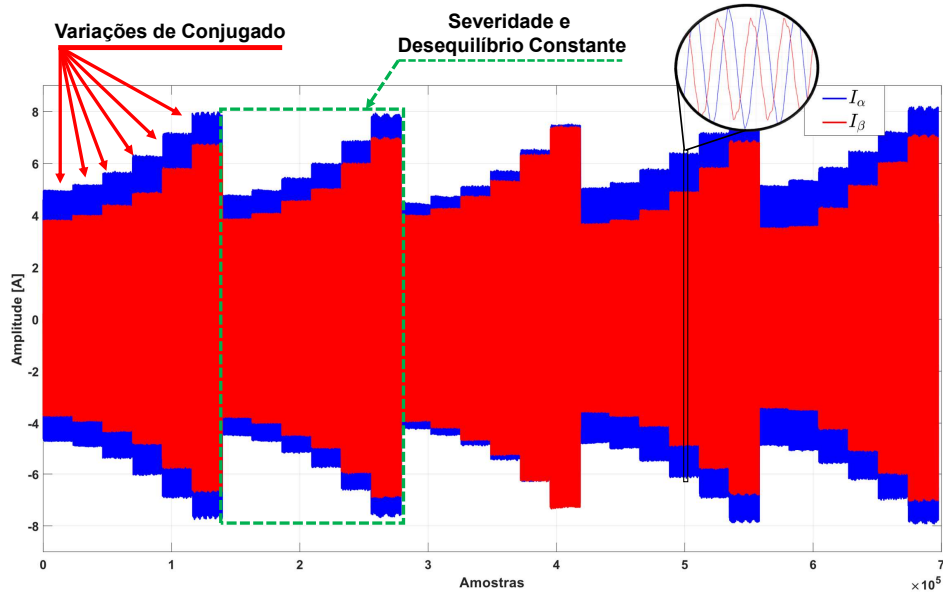
Desta forma, determina-se a transformação de Clarke descrita conforme a Equação (3.9), com o posicionamento da componente α sobreposto ao fasor da fase do sistema cuja corrente de linha apresenta a maior amplitude. De maneira a evitar consequências associadas à ordenação aleatória da transformação, dando prioridade à componente sujeita ao maior impacto quando a condição de curto-circuito se faz presente.

Então, os impactos associados às condições de falha, variação de conjugado de carga e desbalanceamento de tensão de alimentação mantém-se evidentes nos sinais de corrente elétrica sujeitos à transformação de Clarke, conforme ilustrado na Figura 23.

Assim, pode-se observar que variações de conjugado afetam diretamente a amplitude dos sinais de corrente de linha, consequentemente, seus valores em referencial estacionário. Além disso, a observação da Figura 23 clarifica a visualização dos efeitos associados a cada uma das condições descritas na Tabela 5 de acordo com os destaques sinalizados por setas vermelhas. Outro aspecto relevante consiste na possibilidade de identificar regiões em que os níveis de severidade da falha de curto-circuito e o desequilíbrio de tensão são mantidos constantes, conforme destacado em verde.

Por fim, a etapa de pré-processamento executa operações matemáticas que antecedem a aplicação da informação mútua deslocada que é aplicada a extração de características, conforme explorado na Seção 4.3. Ainda, pode-se observar que as assinaturas nos sinais de corrente elétrica associadas à ocorrência da falha de curto-circuito e variações na condição operacional do MIT são preservadas quando aplica-se a transformação de Clarke.

Figura 23: Sinais em referencial estacionário sujeitos à diferentes condições de severidade de falha, desequilíbrio de tensão e conjugado de carga.



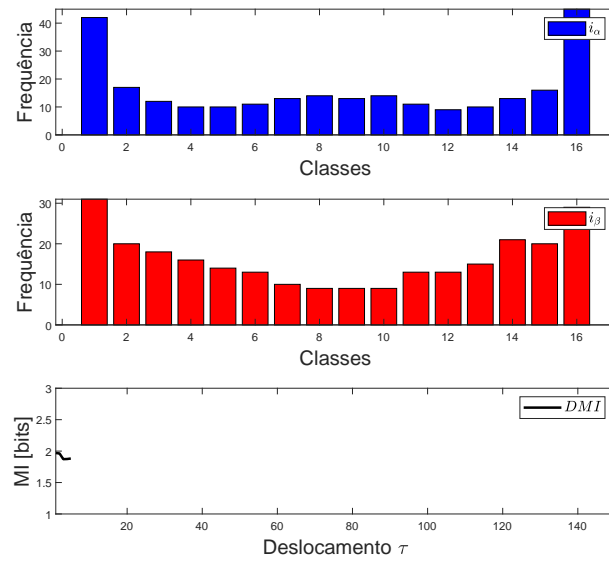
Fonte: Autoria própria (2023).

4.3 EXTRAÇÃO DE CARACTERÍSTICAS

Mediante a conclusão da etapa de pré-processamento, o conjunto de dados é disponibilizado à rotina de extração de características, conforme descrito na Seção 3.2. Determinam-se as funções de probabilidade a partir da representação por histogramas a partir de 260 pontos da componente α e 410 pontos relacionados à componente β . Devido ao posicionamento da componente α junto ao fasor associado à corrente de maior amplitude, mantém-se este atributo de maior magnitude da componente α sobre β em condições de desbalanceamento. Portanto, os intervalos das 16 barras dos histogramas são determinados a partir de i_α , conforme ilustrado na Seção 3.2 nas figuras 12 e 13.

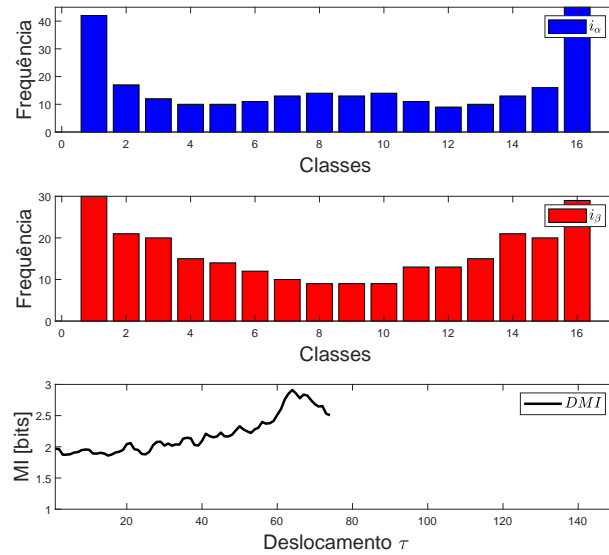
Neste contexto, as assinaturas associadas à ocorrência de falhas em seus distintos níveis de severidade impactam na formação do perfil de DMI, devido à influência na formação dos histogramas destinados a determinação das funções de probabilidade. As figuras 24 a 26 ilustram os histogramas das componentes α e β sujeitos a três pontos de deslocamento τ , provenientes de medições no motor de indução em condição saudável.

Figura 24: Histogramas de i_α , i_β e perfil de DMI para $\tau = 3$ em MIT saudável.



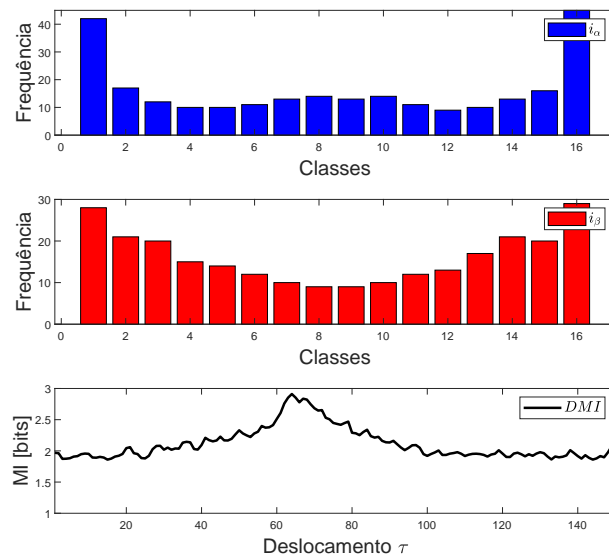
Fonte: Autoria própria (2023).

Figura 25: Histogramas de i_α , i_β e perfil de DMI para $\tau = 75$ em MIT saudável.



Fonte: Autoria própria (2023).

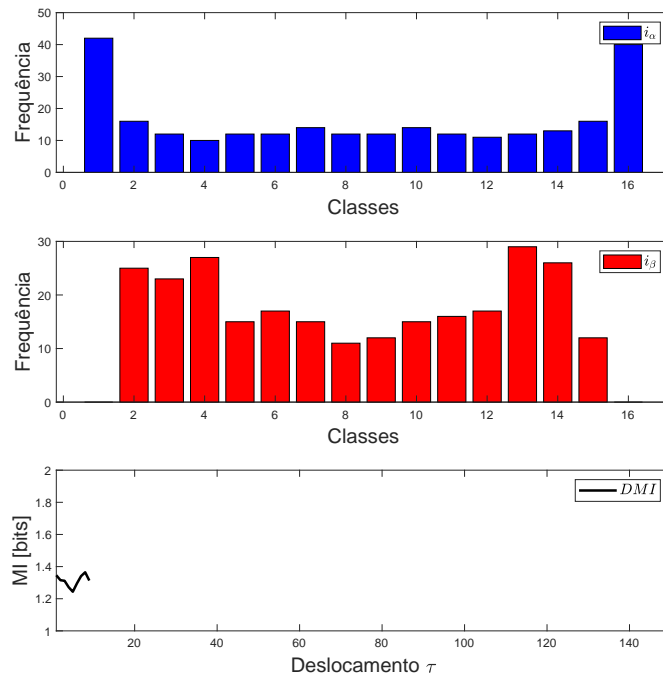
Figura 26: Histogramas de i_α , i_β e perfil de DMI para $\tau = 150$ em MIT saudável.



Fonte: Autoria própria (2023).

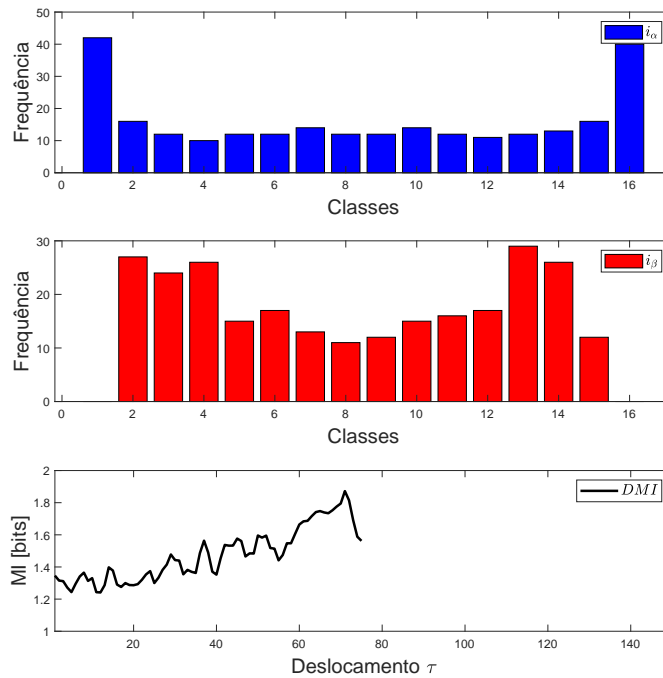
Ao se aplicar as mesmas condições em amostras provenientes do mesmo MIT sujeito à condição de falha de curto-circuito, pode-se observar conforme as figuras 27 a 29 diferenças substanciais no posicionamento e valor do pico no perfil de DMI e na formação dos histogramas, com destaque àqueles provenientes da componente i_β , cujas contagens na primeira e última barra apresentam valores iguais a zero. Fato que se deve à diferença de amplitude entre os sinais em referencial estacionário nesta condição.

Figura 27: Histogramas de i_α , i_β e perfil de DMI para $\tau = 3$ em MIT sujeito a curto-circuito de estator.



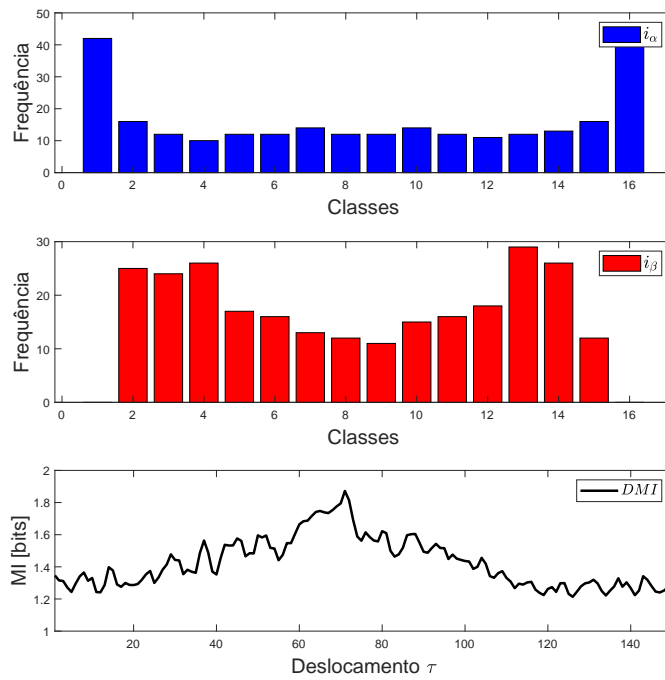
Fonte: Autoria própria (2023).

Figura 28: Histogramas de i_α , i_β e perfil de DMI para $\tau = 75$ em MIT sujeito a curto-circuito de estator.



Fonte: Autoria própria (2023).

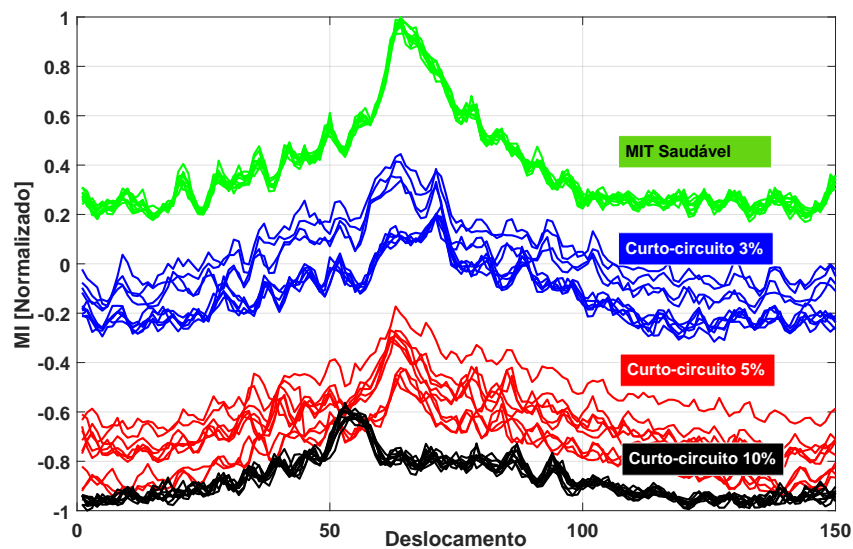
Figura 29: Histogramas de i_α , i_β e perfil de DMI para $\tau = 150$ em MIT sujeito a curto-circuito de estator.



Fonte: Autoria própria (2023).

Os perfis de DMI para cada conjunto amostral são normalizados entre -1 e 1, desta forma os efeitos do curto-circuito nos perfis de DMI são ilustrados conforme a Figura 30 para 10 amostras para cada condição de severidade.

Figura 30: Perfis de DMI sujeitos às condições de MIT saudável, 3% de CC, 5% de CC e 10% de CC.

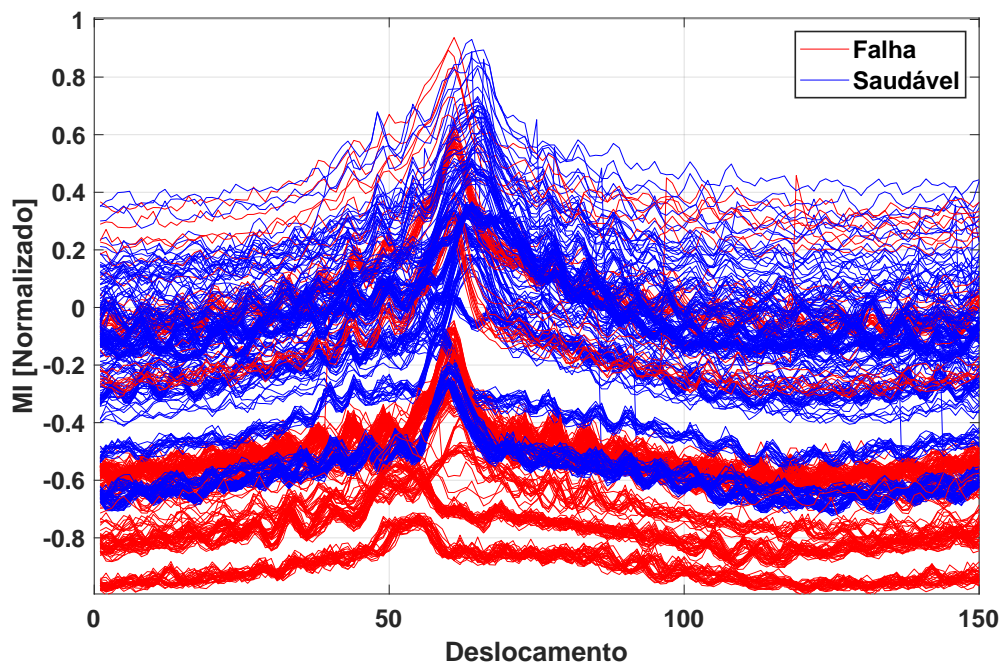


Fonte: Autoria própria (2023).

A partir da Figura 30, é possível notar um padrão na dinâmica da característica de DMI associada a uma determinada condição de severidade de curto-circuito a qual o MIT está sujeito, ocasionando o surgimento de *clusters*.

Porém, este comportamento tende a ser afetado pela intensidade das condições dinâmicas a qual o motor é sujeito, como as variações de conjugado e o desequilíbrio na tensão de alimentação. Com isso, o comportamento de regiões de falha torna-se mais disperso, conforme ilustra a Figura 31 mediante a comparação entre 250 amostras saudáveis e 250 amostras sujeitas a condições defeituosas, em ambos os casos com a presença de condições dinâmicas diversas conforme apresentado na Seção 4.2.

Figura 31: Influência de efeitos dinâmicos na característica de DMI.



Fonte: Autoria própria (2023).

Portanto, as influências dinâmicas representadas conforme a Figura 31 tornam o problema com características não linearmente separáveis, em que não se aplicam sistemas de reconhecimento de padrões como RNA do tipo *Perceptron* de camada única ou máquina de vetores de suporte de margem rígida. Com isso, a assertividade de identificação da ocorrência de falha e sua respectiva severidade depende de ferramentas de reconhecimento de padrões suficientemente robustas para separação de classes sujeitas às diversas condições de variação de conjugado e desequilíbrio de tensão possíveis, conforme explorado na Seção 4.4.

4.4 RECONHECIMENTO DE PADRÕES

O processo de reconhecimento de padrões é realizado mediante a aplicação dos métodos descritos na Seção 3.3. Para tanto, os perfis de DMI obtidos na etapa de extração de características são normalizados entre -1 e 1, conforme citado na Seção 4.3 e expresso na Equação (4.1). Então, estes dados são organizados em um conjunto de treinamento e outro de testes.

$$x_{norm} = \frac{x \cdot (x_n^{max} - x_n^{min}) - x_n^{max} \cdot x_a^{min} + x_n^{min} \cdot x_a^{max}}{x_a^{max} - x_a^{min}}, \quad (4.1)$$

A separação destes conjuntos tem por objetivo fornecer uma quantidade suficiente de amostras para ajustes dos parâmetros de separação entre as classes durante a fase de treinamento. Posteriormente, apresenta-se amostras desconhecidas pelo classificador de padrões com o intuito de testar sua capacidade de generalização com o conjunto de dados de validação.

Portanto, são adotadas duas estratégias de reconhecimento de padrões, sendo a primeira um sistema de diagnóstico da presença de falha, composto por duas classes. Ao obter saída de classificação igual a 1, determina-se que a condição do MIT é saudável, ao passo que a classe indicativa da presença de falha possui identificador -1.

A segunda abordagem de classificação consiste em um sistema especialista capaz de apontar o nível de severidade. Para ambos os casos, as ferramentas de reconhecimento de padrões utilizadas são RNA do tipo MLP, SVM de margem suave e kNN. Ressalta-se que os dados são divididos em conjuntos de treinamento e validação, para esta primeira etapa, 70% dos dados são disponibilizados, sendo os 30% remanescentes destinados à etapa de validação. Neste contexto, ambos os conjuntos de dados são balanceados de forma a manter a proporção das amostras que abrangem todas as condições dinâmicas e de severidade abordadas.

Além disso, com o intuito de ponderar o custo computacional associado ao classificador baseado em RNA, testa-se o desempenho de 10 topologias candidatas. Este teste tem como o objetivo avaliar a relação entre taxa de acerto e quantidade de memória de dados necessária para implementação. Fato que se deve à característica das matrizes de pesos sinápticos, que aumentam de forma diretamente proporcional a quantidade de entradas e de neurônios na primeira camada escondida. Então, as topologias candidatas são destacadas conforme a Tabela 9.

Tabela 9: Topologias candidatas para RNA do tipo MLP.

Topologia	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10
1º Camada Escondida	5	8	10	20	40	3	5	6	8	30
2ª Camada Escondida	1	1	1	1	1	2	3	3	3	12
3ª Camada Escondida	-	-	-	-	-	1	1	1	1	1

Para todos os neurônios a função de ativação tangente hiperbólica foi utilizada, com o parâmetro β_c ajustado em 0,5 e taxa de aprendizado η_c igual a 0,1. Além disso, utilizou-se o termo *momentum* (α_c) de aceleração do algoritmo *backpropagation*. Para este classificador de padrões, a implementação das etapas de treinamento e validação são realizadas no software MATLAB[®].

Os algoritmos de reconhecimento de padrões baseados em SVM e kNN são desenvolvidos com o auxílio do pacote de software *Waikato Environment for Knowledge Analysis* (WEKA). Para a SVM, esta ferramenta utiliza como padrão o método de otimização mínima sequencial (em inglês *Sequential Minimal Optimization* - SMO) para treinamento. Com o intuito de ponderar a capacidade de generalização e atingimento de maior taxa de acerto de classificação, os hiper parâmetros C e γ são modificados, de forma que C varia entre 1 e 3 em passos unitários para ponderação da soma das variáveis de folga ξ_i enquanto γ assume os valores 10^{-1} , 1 e 10. No contexto do algoritmo kNN, varia-se k em valores ímpares compreendidos entre 1 e 10, com o intuito de observar mudanças no desempenho de classificação.

Como métricas de avaliação de desempenho são analisados percentual de reconhecimentos corretos sobre o atributo alvo e sobre os demais padrões, média de acertos, precisão, revocação, medida-F e índice *Kappa*.

Neste contexto, a precisão (P) indica a taxa de acerto associada às classificações positivas do modelo, conforme a Equação (4.2). A revocação (R) concentra-se em determinar a fração de classificações positivas que de fato são realizadas em comparação com a quantidade esperada, conforme a relação da Equação (4.3). Portanto, a medida-F consiste em uma média harmônica ponderada entre P e R , frequentemente denominada *F1-Score* quando o coeficiente β_F é igual a 1, de acordo com a Equação (4.4) (DERCZYNSKI, 2016). Neste trabalho, considerou-se a medida-F no caso particular do coeficiente de balanceamento β_F unitário.

$$P = \frac{VP}{VP + FP} \quad (4.2)$$

$$R = \frac{VP}{VP + FN} \quad (4.3)$$

$$F_{\beta_F} = (1 + \beta_F^2) \frac{P \cdot R}{\beta_F^2 \cdot P + R} \quad (4.4)$$

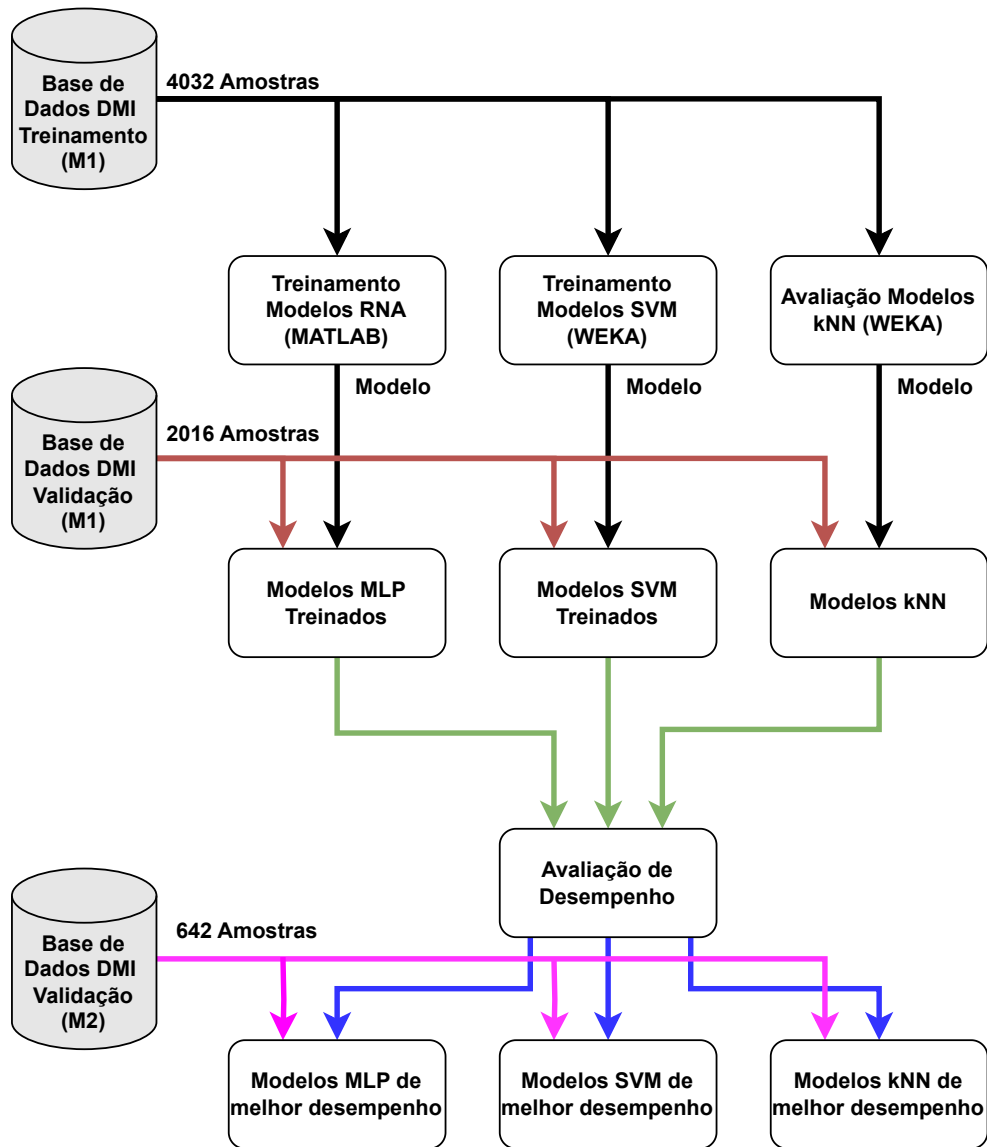
O índice *Kappa* consiste em uma medida de associação que descreve o grau de concordância obtido na identificação em um conjunto de amostras determinado, indicando maiores níveis de concordância quando obtém-se valores próximos a 1 e baixos valores de concordância quando tende a 0. Determina-se este indicador conforme a Equação (4.5) (BAZAN, 2020; SUN *et al.*, 2021).

$$Kappa = \frac{P_o - P_e}{1 - P_e} \quad (4.5)$$

em que, $P_o = \frac{VP+VN}{N}$ e $P_e = \frac{(VP+FP) \cdot (VP+FN) + (VN+FN) \cdot (VN+FP)}{N^2}$.

Os modelos com melhor desempenho durante a etapa de validação para as funções de identificação da ocorrência da falha de curto-circuito e diagnóstico do nível de severidade com dados provenientes do MIT M1, são utilizados para uma segunda etapa de validação com dados provenientes de aquisições do MIT M2, sem que nenhum dado do motor M2 seja utilizado para reforço ou treinamento dos modelos. A estrutura de reconhecimento de padrões é ilustrada conforme a Figura 32.

Figura 32: Estrutura de treinamento e validação dos algoritmos de aprendizado de máquina.



Fonte: Autoria própria (2023).

4.5 SÍNTESE DO CAPÍTULO

No Capítulo 4 são apresentados os aspectos metodológicos relacionados ao desenvolvimento do presente trabalho, introduzindo com maior nível de detalhes as etapas de aquisição de dados, condições de operação consideradas e organização da base de dados destinada para treinamento e validação dos algoritmos de reconhecimento de padrões.

Por fim, são introduzidas as estruturas utilizadas para verificação do desempenho de classificação dos classificadores inteligentes adotados, com detalhes de topologias e parâmetros considerados.

5 RESULTADOS

O presente capítulo dedica-se à apresentação dos resultados obtidos neste projeto, bem como adicionar comentários acerca de observações.

Neste contexto, são apresentadas as taxas de acerto e as métricas de desempenho dos algoritmos de reconhecimento de padrões inteligentes baseados em RNA do tipo MLP, SVM e kNN. Para as redes neurais artificiais são avaliadas as topologias candidatas descritas na Tabela 9.

Em se tratando do reconhecimento de padrões baseado na técnica SVM, verifica-se o desempenho de classificação com a variação dos hiper parâmetros C e γ conforme descrito na Seção 4.4. Por fim, o algoritmo kNN é avaliado com os 1, 3, 5, 7 e 9 vizinhos mais próximos, utilizando-se a distância euclidiana.

Para todos os modelos, os dados de entrada são perfis de DMI, devidamente normalizados e sujeitos às condições e nas proporções descritas no Capítulo 4. Inicialmente, avalia-se o desempenho de classificação à ocorrência de falha para o motor M1, com posterior abrangência ao diagnóstico do nível de severidade o qual a máquina está sujeita. Portanto, o processo é reproduzido novamente com a adição dos dados do motor M2 sem etapa de treinamento complementar.

5.1 DIAGNÓSTICO DA FALHA DE CURTO-CIRCUITO EM ESTATOR

A avaliação do desempenho da classificação acerca da ocorrência de falha é realizada a partir da divisão entre os diferentes métodos de reconhecimento de padrões utilizados. Portanto, as tabelas 10 a 19 demonstram os resultados obtidos mediante o reconhecimento de padrões a partir de RNA do tipo MLP em cada uma das topologias descritas na Tabela 9.

Tabela 10: Desempenho RNA Topologia 1.

Métrica	Desempenho
Padrão Defeituoso	98,21 %
Padrão Saudável	98,81 %
Média	98,51 %
Precisão	98,21 %
Revocação	98,81 %
Medida-F	0,985
Kappa	0,970

Tabela 11: Desempenho RNA Topologia 2.

Métrica	Desempenho
Padrão Defeituoso	98,21 %
Padrão Saudável	98,81 %
Média	98,51 %
Precisão	98,21 %
Revocação	98,81 %
Medida-F	0,985
Kappa	0,970

Tabela 12: Desempenho RNA Topologia 3.

Métrica	Desempenho
Padrão Defeituoso	98,71 %
Padrão Saudável	99,31 %
Média	99,01 %
Precisão	98,71 %
Revocação	99,31 %
Medida-F	0,990
Kappa	0,980

Tabela 13: Desempenho RNA Topologia 4.

Métrica	Desempenho
Padrão Defeituoso	96,33 %
Padrão Saudável	94,35 %
Média	95,34 %
Precisão	96,33 %
Revocação	94,35 %
Medida-F	0,953
Kappa	0,907

Tabela 14: Desempenho RNA Topologia 5.

Métrica	Desempenho
Padrão Defeituoso	97,82 %
Padrão Saudável	97,02 %
Média	97,42 %
Precisão	97,82 %
Revocação	97,02 %
Medida-F	0,974
Kappa	0,948

Tabela 15: Desempenho RNA Topologia 6.

Métrica	Desempenho
Padrão Defeituoso	99,11 %
Padrão Saudável	99,50 %
Média	99,31 %
Precisão	99,11 %
Revocação	99,50 %
Medida-F	0,993
Kappa	0,986

Tabela 16: Desempenho RNA Topologia 7.

Métrica	Desempenho
Padrão Defeituoso	98,41 %
Padrão Saudável	99,01 %
Média	98,71 %
Precisão	98,41 %
Revocação	99,01 %
Medida-F	0,987
Kappa	0,974

Tabela 17: Desempenho RNA Topologia 8.

Métrica	Desempenho
Padrão Defeituoso	99,11 %
Padrão Saudável	99,40 %
Média	99,26 %
Precisão	99,11 %
Revocação	99,40 %
Medida-F	0,993
Kappa	0,985

Tabela 18: Desempenho RNA Topologia 9.

Métrica	Desempenho
Padrão Defeituoso	98,51 %
Padrão Saudável	98,91 %
Média	98,71 %
Precisão	98,51 %
Revocação	98,91 %
Medida-F	0,987
Kappa	0,974

Tabela 19: Desempenho RNA Topologia 10.

Métrica	Desempenho
Padrão Defeituoso	98,41 %
Padrão Saudável	99,01 %
Média	98,71 %
Precisão	98,41 %
Revocação	99,01 %
Medida-F	0,987
Kappa	0,974

Dentre as topologias sujeitas à análise, destacam-se pela capacidade de reconhecimento de padrões defeituosos as topologias 6 e 8. Com relação à capacidade de identificar padrões saudáveis, a maior taxa de acerto é verificada na topologia 6, que apresenta o melhor desempenho de classificação geral. Além disso, verifica-se nesta topologia o melhor equilíbrio no que tange ao reconhecimento das diferentes classes, consequentemente, o melhor resultado observado nas métricas Medida-F e índice Kappa, indicando seu elevado nível de concordância.

Com relação ao classificador de padrões baseado em máquina de vetores de suporte, os resultados obtidos são apresentados conforme as tabelas 20 a 27, variando-se os hiper parâmetros C e γ .

Tabela 20: Desempenho SVM $C = 1, \gamma = 0, 1$. Tabela 21: Desempenho SVM $C = 1, \gamma = 1$.

Métrica	Desempenho
Padrão Defeituoso	98,51 %
Padrão Saudável	91,07 %
Média	94,79 %
Precisão	98,51 %
Revocação	91,07 %
Medida-F	0,946
Kappa	0,896

Métrica	Desempenho
Padrão Defeituoso	99,11 %
Padrão Saudável	99,21 %
Média	99,16 %
Precisão	99,11 %
Revocação	99,21 %
Medida-F	0,992
Kappa	0,983

Tabela 22: Desempenho SVM $C = 2, \gamma = 0, 1$. Tabela 23: Desempenho SVM $C = 2, \gamma = 1$.

Métrica	Desempenho
Padrão Defeituoso	98,21 %
Padrão Saudável	94,15 %
Média	96,18 %
Precisão	98,21 %
Revocação	94,15 %
Medida-F	0,961
Kappa	0,924

Métrica	Desempenho
Padrão Defeituoso	98,81 %
Padrão Saudável	99,60 %
Média	99,21 %
Precisão	98,81 %
Revocação	99,60 %
Medida-F	0,992
Kappa	0,984

Tabela 24: Desempenho SVM $C = 2, \gamma = 10$. Tabela 25: Desempenho SVM $C = 3, \gamma = 0, 1$.

Métrica	Desempenho
Padrão Defeituoso	94,64 %
Padrão Saudável	99,90 %
Média	97,27 %
Precisão	94,64 %
Revocação	99,90 %
Medida-F	0,972
Kappa	0,945

Métrica	Desempenho
Padrão Defeituoso	98,81 %
Padrão Saudável	95,54 %
Média	97,17 %
Precisão	98,81 %
Revocação	95,54 %
Medida-F	0,971
Kappa	0,943

Tabela 26: Desempenho SVM $C = 3, \gamma = 1$. Tabela 27: Desempenho SVM $C = 3, \gamma = 10$.

Métrica	Desempenho
Padrão Defeituoso	98,81 %
Padrão Saudável	99,70 %
Média	99,26 %
Precisão	98,81 %
Revocação	99,70 %
Medida-F	0,993
Kappa	0,985

Métrica	Desempenho
Padrão Defeituoso	94,64 %
Padrão Saudável	99,90 %
Média	97,27 %
Precisão	94,64 %
Revocação	99,90 %
Medida-F	0,972
Kappa	0,945

Com base nas tabelas 20 a 27, o melhor desempenho é obtido quando os hiper parâmetros C e γ são respectivamente iguais a 3 e 1. O índice Kappa obtido é igual a 0,985 indicando um nível de concordância próximo à Topologia 6 de RNA.

O desempenho associado à classificação de padrões baseada no algoritmo kNN é apresentada conforme as tabelas 28 a 32.

Tabela 28: Desempenho kNN $k = 1$.

Métrica	Desempenho
Padrão Defeituoso	99,01 %
Padrão Saudável	98,81 %
Média	98,91 %
Precisão	99,01 %
Revocação	98,81 %
Medida-F	0,989
Kappa	0,978

Tabela 29: Desempenho kNN $k = 3$

Métrica	Desempenho
Padrão Defeituoso	97,12 %
Padrão Saudável	100 %
Média	98,56 %
Precisão	97,12 %
Revocação	100 %
Medida-F	0,985
Kappa	0,971

Tabela 30: Desempenho kNN $k = 5$.

Métrica	Desempenho
Padrão Defeituoso	97,12 %
Padrão Saudável	100 %
Média	98,56 %
Precisão	97,12 %
Revocação	100 %
Medida-F	0,985
Kappa	0,971

Tabela 31: Desempenho kNN $k = 7$

Métrica	Desempenho
Padrão Defeituoso	96,92 %
Padrão Saudável	99,70 %
Média	98,31 %
Precisão	96,92 %
Revocação	99,70 %
Medida-F	0,983
Kappa	0,966

Tabela 32: Desempenho kNN $k = 9$.

Métrica	Desempenho
Padrão Defeituoso	96,03 %
Padrão Saudável	99,70 %
Média	97,87 %
Precisão	96,03 %
Revocação	99,70 %
Medida-F	0,978
Kappa	0,957

Para o método de classificação baseado no algoritmo kNN, é obtido o melhor resultado para identificação de padrões defeituosos para $k = 1$, assim como o maior desempenho geral para este método. Com relação à identificação de padrões saudáveis, o melhor resultado é obtido quando $k = 3$ e $k = 5$ em que todas as amostras saudáveis foram corretamente classificadas durante a etapa de validação.

5.2 DIAGNÓSTICO DE SEVERIDADE DA FALHA DE CURTO-CIRCUITO EM ESTATOR

Na conjuntura do diagnóstico do nível de severidade da falha de curto-circuito, são comparados os desempenhos dos métodos de reconhecimento de padrões com os parâmetros que atingem melhor performance geral obtidos durante a identificação da ocorrência de falha. Com isso, emprega-se a topologia 6 de RNA, SVM com hiper parâmetros $C = 3$; $\gamma = 1$ e kNN com parâmetro $k = 1$.

Desta maneira, é realizado isoladamente o reconhecimento dos estados "Curto-circuito com Severidade de 3%", "Curto-circuito com Severidade de 5%" e "Curto-circuito com Severidade de 10%". A performance de reconhecimento da severidade de curto-circuito em 3% como atributo alvo é organizada para cada ferramenta de reconhecimento de padrões nas tabelas 33 a 35, respectivamente aplicados à RNA, SVM e kNN.

Tabela 33: Severidade 3% RNA.

Métrica	Desempenho
Atributo Alvo	99,80 %
Outros Padrões	98,21 %
Média	99,01 %
Precisão	98,21 %
Revocação	99,80 %
Medida-F	0,990
Kappa	0,980

Tabela 34: Severidade 3% SVM.

Métrica	Desempenho
Atributo Alvo	99,50 %
Outros Padrões	97,32 %
Média	98,41 %
Precisão	97,32 %
Revocação	99,50 %
Medida-F	0,984
Kappa	0,968

Tabela 35: Severidade 3% kNN

Métrica	Desempenho
Atributo Alvo	99,31 %
Outros Padrões	97,02 %
Média	98,16 %
Precisão	97,02 %
Revocação	99,31 %
Medida-F	0,982
Kappa	0,963

De maneira análoga, a performance associada ao reconhecimento de padrões defeituosos

cujo nível de severidade é de 5% são descritos conforme as tabelas 36 a 38.

Tabela 36: Severidade 5% RNA.

Métrica	Desempenho
Atributo Alvo	100 %
Outros Padrões	99,11 %
Média	99,55 %
Precisão	99,11 %
Revocação	100 %
Medida-F	0,996
Kappa	0,991

Tabela 37: Severidade 5% SVM.

Métrica	Desempenho
Atributo Alvo	100 %
Outros Padrões	99,11 %
Média	99,55 %
Precisão	99,11 %
Revocação	100 %
Medida-F	0,996
Kappa	0,991

Tabela 38: Severidade 5% kNN.

Métrica	Desempenho
Atributo Alvo	99,80 %
Outros Padrões	99,70 %
Média	99,75 %
Precisão	99,70 %
Revocação	99,80 %
Medida-F	0,998
Kappa	0,995

Por fim, a análise para a condição de maior severidade é realizada a partir dos resultados descritos nas tabelas 39 a 42.

Tabela 39: Severidade 10% RNA.

Métrica	Desempenho
Atributo Alvo	100 %
Outros Padrões	99,90 %
Média	99,95 %
Precisão	99,90 %
Revocação	100 %
Medida-F	1,00
Kappa	0,999

Tabela 40: Severidade 10% SVM.

Métrica	Desempenho
Atributo Alvo	100 %
Outros Padrões	99,40 %
Média	99,70 %
Precisão	99,40 %
Revocação	100 %
Medida-F	0,997
Kappa	0,994

Tabela 41: Severidade 10% kNN.

Métrica	Desempenho
Atributo Alvo	100 %
Outros Padrões	99,90 %
Média	99,95 %
Precisão	99,90 %
Revocação	100 %
Medida-F	1,000
Kappa	0,999

É possível observar que a performance de classificação é ligeiramente inferior para o diagnóstico do menor nível de severidade de falha de curto-circuito. Este fato se deve à característica incipiente da falha, com forte semelhança às condições saudáveis quando são consideradas variações severas de conjugado de carga e desequilíbrio de tensão de alimentação. Mesmo diante do exposto, o desempenho geral dos classificadores baseados em RNA do tipo MLP são superiores a 99% para todos os casos.

Tabela 42: Avaliação geral de desempenho por modelo.

Avaliação	Capacidade de reconhecimento da presença de falha em qualquer condição																	
	MLP						kNN						SVM ($\gamma = 1$)					
Modelo	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	k = 1	k = 3	k = 5	k = 7	k = 9	C = 1	C = 2	C = 3
Parâmetros	98,21	98,21	98,71	96,33	97,82	99,11	98,41	99,11	98,51	98,41	99,01	97,12	97,12	97,12	96,92	99,11	98,81	98,81
Precisão [%]	98,81	98,81	99,31	94,35	97,02	99,50	99,01	99,40	98,91	99,01	98,81	100	100	100	99,70	99,21	99,60	99,70
Revocação [%]	98,51	98,51	99,01	95,34	97,42	99,31	98,71	99,26	98,71	98,71	98,91	98,56	98,56	98,91	97,87	99,16	99,21	99,70
Desempenho Geral [%]	0,985	0,985	0,990	0,953	0,974	0,993	0,987	0,993	0,987	0,987	0,989	0,985	0,985	0,983	0,978	0,992	0,992	0,993
Medida F1	0,970	0,970	0,980	0,907	0,948	0,986	0,974	0,985	0,974	0,974	0,978	0,971	0,971	0,966	0,957	0,983	0,984	0,985
Índica Kappa	Capacidade de reconhecimento da presença de falha com severidade de 3%																	
Avaliação	MLP						kNN						SVM ($\gamma = 1$)					
Modelo	T6						k = 1						C = 3					
Parâmetros	98,21						97,02						97,32					
Precisão [%]	99,80						99,31						99,50					
Revocação [%]	99,01						98,16						98,41					
Desempenho Geral [%]	0,990						0,982						0,984					
Medida F1	0,980						0,963						0,968					
Índica Kappa	Capacidade de reconhecimento da presença de falha com severidade de 5%																	
Avaliação	MLP						kNN						SVM ($\gamma = 1$)					
Modelo	T6						k = 1						C = 3					
Parâmetros	99,11						99,70						99,11					
Precisão [%]	100						99,80						100					
Revocação [%]	99,55						99,75						99,55					
Desempenho Geral [%]	0,996						0,998						0,996					
Medida F1	0,991						0,995						0,991					
Índica Kappa	Capacidade de reconhecimento da presença de falha com severidade de 10%																	
Avaliação	MLP						kNN						SVM ($\gamma = 1$)					
Modelo	T6						k = 1						C = 3					
Parâmetros	99,90						99,90						99,40					
Precisão [%]	100						100						100					
Revocação [%]	99,95						99,95						99,70					
Desempenho Geral [%]	1,00						1,00						0,997					
Medida F1	0,999						0,999						0,994					
Índica Kappa																		

5.3 DIAGNÓSTICO APLICADO A UMA MÁQUINA DE 2 CV

No contexto das seções 5.1 e 5.2, foram realizadas validações de diagnóstico de falha e de seu nível de severidade para novas aquisições de dados provenientes da máquina de 1 CV descrita conforme a Tabela 3.

Com o intuito de agregar parâmetros de análise à etapa de validação, realiza-se na presente seção a aplicação do sistema de diagnóstico desenvolvido em um segundo motor (MIT M2), este com os parâmetros descritos conforme a Tabela 43. Conforme descrito na Seção 4.4, os modelos baseados em aprendizado de máquina são treinados exclusivamente com os dados provenientes do motor M1 e nenhuma etapa de reforço ao treinamento é realizada com os dados amostrados do motor M2.

Tabela 43: Informações MIT M2.

Parâmetro	Valor
Fabricante	WEG
Potência Nominal	2 CV
Tensão Nominal	220/380 V
Corrente Nominal	6,16/3,57 A
Número de Fases	3
Frequência de Operação	60 Hz
Número de Polos	4
Velocidade de Rotação Nominal	1750 RPM
Torque Nominal	8,17 N · m

No contexto da validação, ocorre a apresentação de 642 amostras de DMI provenientes de sinais de corrente elétrica da máquina descrita conforme a Tabela 43, estes dados compreendem condições de conjugado de carga até 110% em 6 estágios (de $0,5N \cdot m$ a $9N \cdot m$), 4 condições de severidade de curto-circuito (0%, 3%, 5% e 10%) e condições de desbalanceamento de tensão de até $\pm 2\%$.

Para realizar este processo, faz-se necessário fixar os parâmetros x_a^{max} e x_a^{min} conforme obtidos durante a geração das bases de treinamento para normalização da DMI conforme a Equação (4.1). Então, $x_a^{max} = 4,1127$ e $x_a^{min} = 0,2672$.

Os resultados obtidos durante a etapa de validação com o emprego de RNA do tipo MLP são apresentados conforme a Tabela 44, em que o desempenho de classificação é avaliado para

cada condição de desbalanceamento na tensão de alimentação. Analogamente, são expostos conforme as tabelas 45 e 46 os resultados obtidos quando aplicados os algoritmos SVM e kNN para reconhecimento de padrões, respectivamente.

Tabela 44: Desempenho RNA MIT 2.

Métrica	Desempenho
Padrão Defeituoso	94,20 %
Padrão Saudável	96,58 %
Média	95,39 %
Precisão	94,20 %
Revocação	96,58 %
Medida-F	0,954
Kappa	0,908

Tabela 45: Desempenho SVM MIT 2.

Métrica	Desempenho
Padrão Defeituoso	98,20 %
Padrão Saudável	99,10 %
Média	98,65 %
Precisão	98,20 %
Revocação	99,10 %
Medida-F	0,987
Kappa	0,973

Tabela 46: Desempenho kNN MIT 2.

Métrica	Desempenho
Padrão Defeituoso	98,40 %
Padrão Saudável	71,40 %
Média	84,90 %
Precisão	98,40 %
Revocação	71,40 %
Medida-F	0,846
Kappa	0,697

A partir dos resultados apresentados, é possível verificar que os algoritmos baseados em RNA e SVM apresentam melhor desempenho quando comparado ao kNN.

Ainda no contexto da validação sem etapa de reforço adicionada ao treinamento, os resultados obtidos no reconhecimento do nível de severidade são apresentados conforme a Tabela 47.

Tabela 47: Desempenho aplicado ao reconhecimento do nível de severidade no MIT 2.

Severidade de Curto-Circuito - 3%	
Modelo	Taxa de Acerto
RNA	86,26 %
SVM	83,85 %
kNN	76,93 %
Severidade de Curto-Circuito - 5%	
Modelo	Taxa de Acerto
RNA	83,41 %
SVM	87,05 %
kNN	85,86 %
Severidade de Curto-Circuito - 10%	
Modelo	Taxa de Acerto
RNA	99,75 %
SVM	98,96 %
kNN	98,71 %

Os resultados obtidos demonstram que o sistema de diagnóstico é capaz de manter o nível de desempenho com taxa de acerto acima de 90%, exceto quando utilizado o algoritmo kNN. Reconhecendo corretamente padrões associados à falha de curto-circuito em uma máquina de maior potência, cujos sinais não participam da etapa de treinamento.

No contexto do reconhecimento do nível de severidade de curto-circuito, é notável uma queda de desempenho frente ao diagnóstico dos estágios iniciais de 3% e 5%, isto ocorre principalmente devido à proximidade das características de informação mútua deslocada entre estes dois estágios de falha. Ainda, é possível observar que a taxa de acerto permanece acima de 98% quando o nível de severidade alcança o estágio de 10%.

5.4 SÍNTESE DO CAPÍTULO

No Capítulo 5 são apresentados os resultados obtidos em quatro estágios. O primeiro caracteriza-se pela identificação da ocorrência da falha de curto-circuito. Posteriormente o escopo de diagnóstico é ampliado ao reconhecimento do nível de severidade o qual a máquina está sujeita. Este processo é repetido para um MIT de 2 CV, sem a execução de reforço no treinamento.

Durante a etapa de validação no contexto da máquina de 1 CV, são verificadas topologias candidatas para cada uma das três ferramentas de aprendizado de máquina empregadas. A partir desta análise, uma topologia é selecionada para cada algoritmo aplicado ao reconhecimento de padrões levando em consideração a melhor relação entre desempenho e custo computacional e os resultados consolidados são evidenciados conforme a Tabela 42.

Estes modelos são então submetidos à validação com dados provenientes de uma máquina de maior potência, com o objetivo de verificar a robustez do método proposto, em que o método baseado em SVM apresenta as melhores taxas de acerto ao passo que o algoritmo kNN apresenta desempenho médio inferior. Os resultados consolidados são encontrados conforme a Tabela 48.

Tabela 48: Comparação taxa de acerto por atributo alvo e motor.

Ocorrência de curto-circuito		
Modelo	1 CV	2 CV
RNA	99,31 %	95,39 %
SVM	99,26 %	98,65 %
kNN	98,91 %	84,90 %
Severidade de Curto-Circuito - 3%		
Modelo	1 CV	2 CV
RNA	99,01 %	86,26 %
SVM	98,41 %	83,85 %
kNN	98,16 %	76,93 %
Severidade de Curto-Circuito - 5%		
Modelo	1 CV	2 CV
RNA	99,55 %	83,41 %
SVM	99,55 %	87,05 %
kNN	99,75 %	85,86 %
Severidade de Curto-Circuito - 10%		
Modelo	1 CV	2 CV
RNA	99,95 %	99,75 %
SVM	99,70 %	98,96 %
kNN	99,95%	98,71 %

6 CONCLUSÃO

O presente trabalho introduz uma abordagem para diagnóstico da falha de curto-circuito em estator em MIT sujeitos à alimentação senoidal, que norteia-se na utilização da medida de similaridade baseada na informação mútua dos sinais de corrente de linha sujeitos à transformação de Clarke, com a aplicação de sistemas inteligentes como ferramenta de reconhecimento de padrões.

Neste contexto, o conjunto de dados possui abrangência para diversas condições de operação da máquina quando sujeita a variações de conjugado de carga, bem como condições de desequilíbrio na tensão de alimentação. Além disso, distintos níveis de severidade da falha de curto-circuito são emulados, ainda visando o diagnóstico incipiente da condição defeituosa.

A partir da amostragem dos sinais de corrente elétrica, aplica-se a transformação de Clarke com o intuito de agrupar as assinaturas dinâmicas presentes nas três fases do MIT. Este processo é realizado com o posicionamento da componentes i_α sobreposta à fase cuja corrente de linha apresenta maior amplitude.

Com base nas transformações dos sinais determina-se pontualmente a similaridade entre as componentes i_α e i_β , aplicando-se o deslocamento τ até o atingimento de 150 pontos, originando um perfil de informação mútua deslocada sensível às condições dinâmicas que impactam os sinais de corrente elétrica da máquina.

Desta forma, foram apresentados os efeitos em perfis de informação mútua deslocada associados à ocorrência da falha de curto-circuito em múltiplos níveis de severidade, cujos aglomerados tornam possível a identificação da gravidade relacionada ao defeito. Além disso, são adicionados os padrões sujeitos às condições de variação do conjugado de carga e desequilíbrio da tensão de alimentação em circunstâncias variadas.

Neste âmbito, os perfis caracterizam-se como não linearmente separáveis, o que demanda a aplicação de ferramentas de reconhecimento de padrões suficientemente robustas. São utilizadas neste trabalho os algoritmos de reconhecimento de padrões baseados em RNA do tipo MLP, SVM de margem suave e kNN.

Para as ferramentas empregadas, utilizam-se diferentes configurações de hiper-parâmetros com o intuito de observar variações em termos de performance. Os resultados experimentais obtidos em todos os cenários demonstram aderência ao diagnóstico da falha de curto-circuito em estator.

Em função da aderência do método proposto à identificação do defeito em análise, expande-se a abrangência para o diagnóstico particular ao nível de severidade, em que o algoritmo de reconhecimento de padrões baseado em RNA do tipo MLP atinge taxa de acerto superior à 99% no reconhecimento da falha de curto-circuito em todos os níveis de severidade objetos de estudo. Destaca-se que o desempenho de reconhecimento é superior quanto maior encontra-se a severidade da falha, fato que se deve ao maior impacto nos sinais de corrente de linha.

Além disso, destaca-se o desempenho do algoritmo de reconhecimento baseado em SVM por meio da acurácia observada na etapa de validação com as amostras provenientes do MIT M2, com taxa de acerto de 98,65% na identificação da ocorrência de falha. No contexto do diagnóstico do nível de severidade, o resultado obtido é considerado satisfatório, visto que mais de 86% das amostras foram corretamente identificadas no estágio incipiente e aproximadamente 99% quando a severidade atinge 10%.

No contexto do algoritmo de reconhecimento de padrões baseado nos k -vizinhos mais próximos, há uma perda significativa de desempenho potencialmente relacionado com a característica dos efeitos dinâmicos nos perfis de DMI, bem como a alta dimensionalidade dos dados de entrada associados a baixos valores de k , tornando esta solução mais suscetível aos efeitos relacionados com o fenômeno conhecido como *Curse of Dimensionality* (LIU; ÖZSU, 2009).

Ressalta-se que somente a adoção da transformação de Clarke pode reduzir em aproximadamente 67% o custo computacional relacionado ao armazenamento de variáveis e processamento quando comparado ao método empregado no estudo de Bazan *et al.* (2022), provendo vantagens à uma abordagem embarcada frente à utilização individualizada dos sinais diretamente amostrados da máquina. Ainda, o desempenho de classificação demonstra a metodologia adotada como promissora ao diagnóstico da falha de curto-circuito em estator.

Em termos práticos, a metodologia proposta apresenta a retenção do conhecimento obtido durante a etapa de treinamento, sendo capaz de extrapolar o desempenho de reconhecimento da ocorrência de falha e seu respectivo nível de severidade sem a necessidade de reforço no aprendizado. Esta característica contribui para a aplicação deste tipo de sistema em campo, em que a aquisição massiva de dados e o treinamento de algoritmos de aprendizado de máquinas localmente podem ser tecnicamente ou financeiramente impraticáveis.

Por fim, a aplicação do sistema proposto pode partir de abordagens centralizada ou descentra-

lizada. O primeiro pode ser ilustrado em uma máquina de processamento de dados central, capaz de receber dados de sensores distribuídos. No caso da estratégia descentralizada, há potencial para áreas produtivas dispersas, em que uma solução embarcada pode localmente diagnosticar a condição operativa de uma máquina. Destaca-se que em ambos os casos a integração a uma solução CMMS é possível dadas condições suficientes em termos de conectividade.

REFERÊNCIAS

- ABE, S. *Support vector machines for pattern classification*. New York: Springer, 2005.
- AL-ALI, S.; DABBOUSI, R. Rotor hot spot detection and resolution in large oil and gas industry motors. In: *Industry Applications Society 60th Annual Petroleum and Chemical Industry Conference*. Manhattan: IEEE, 2013. p. 1–8.
- ALMEIDA, A. T. D. *et al. Eup lot 11 motors*. 2008.
- ASTUTI, W. *et al.* A performance of k-nearest neighbor classification in paraphilia disease. In: *2018 2nd East Indonesia Conference on Computer and Information Technology (EIconCIT)*. Manhattan: IEEE, 2018. p. 223–226.
- BARZEGARAN, M.; MAZLOOMZADEH, A.; MOHAMMED, O. A. Fault diagnosis of the asynchronous machines through magnetic signature analysis using finite-element method and neural networks. In: . Manhattan: IEEE, 2013. v. 28, n. 4, p. 1064–1071.
- BAYAR, V.; EFE, M. Detection of smart phone position on user using artificial neural network classifier. In: *2018 26th Signal Processing and Communications Applications Conference (SIU)*. Manhattan: IEEE, 2018. p. 1–4.
- BAZAN, G. H. *Identificação inteligente de falhas em máquinas elétricas utilizando informação mútua*. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná, Cornélio Procópio, 2020.
- BAZAN, G. H. *et al.* Rotor fault diagnosis of frequency inverter fed or line-connected induction motors using mutual information. *Soft Computing*, Springer, New York, v. 25, n. 2, p. 1309–1324, 2021.
- BAZAN, G. H. *et al.* An embedded system for stator short-circuit diagnosis in three-phase induction motors using information theory and artificial neural networks. In: *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. Manhattan: IEEE, 2022.
- BAZAN, G. H. *et al.* *Medidas de informação e sistemas inteligentes aplicados no diagnóstico de curto-circuito do estator de motores de indução trifásicos*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2016.
- BAZAN, G. H. *et al.* Stator fault analysis of three-phase induction motors using information measures and artificial neural networks. *Electric Power Systems Research*, Elsevier, New York, v. 143, p. 347–356, 2017.
- BAZAN, G. H. *et al.* Information theoretical measurements from induction motors under several load and voltage conditions for bearing faults classification. In: *IEEE Transactions on Industrial Informatics*. Manhattan: IEEE, 2019. v. 16, n. 6, p. 3640–3650.
- BIANCHI, M. F. d. *Extração de características de imagens de faces humanas através de wavelets, PCA e IMPCA*. Tese (Doutorado) — Universidade de São Paulo, 2006.

BIM, E. *Máquinas elétricas e acionamento*. Rio de Janeiro: Elsevier, 2018.

BRONIERA, P. *et al.* Diagnosis of stator winding inter-turn short circuit in three-phase induction motors by using artificial neural networks. In: *2013 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)*. Manhattan: IEEE, 2013. p. 281–287.

CACHADA, A. *et al.* Maintenance 4.0: Intelligent and predictive maintenance system architecture. In: *2018 IEEE 23rd international conference on emerging technologies and factory automation (ETFA)*. Manhattan: IEEE, 2018. v. 1, p. 139–146.

CARVALHO, R. V. *Análise Dinâmica de Rolamento de Esferas*. Dissertação (Mestrado) — Universidade Estadual de Campinas, Campinas, 2010.

CHAPMAN, S. J. *Fundamentos de máquinas elétricas*. Porto Alegre: AMGH Editora, 2013. v. 5.

COSTA, B. L. G. *et al.* Differential evolution applied to dtc drive for three-phase induction motors using an adaptive state observer. *Journal of Control, Automation and Electrical Systems*, Springer, New York, v. 26, n. 4, p. 403–420, 2015.

CUNHA, R. G. C.; JR, E. T. da S.; MEDEIROS, C. M. de S. Machine learning and multiresolution decomposition for embedded applications to detect short-circuit in induction motors. *Computers in Industry*, Elsevier, New York, v. 129, p. 103461, 2021.

DE ALMEIDA, A. T. *et al.* Policy options to promote energy efficient electric motors and drives in the eu. *Renewable and Sustainable Energy Reviews*, v. 74, p. 1275–1286, 2017. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032117301223>>.

DENG, H.-R.; WANG, Y.-H. An artificial-neural-network-based multiple classifiers intrusion detection system. In: *2007 International Conference on Wavelet Analysis and Pattern Recognition*. Manhattan: IEEE, 2007. v. 2, p. 683–686.

DERCZYNSKI, L. Complementarity, f-score, and nlp evaluation. In: *Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16)*. Portorož, Slovenia: European Language Resources Association (ELRA), 2016. p. 261–266.

DIONISIO, A.; MENEZES, R.; MENDES, D. A. Mutual information: a measure of dependency for nonlinear time series. *Physica A: Statistical Mechanics and its Applications*, Elsevier, New York, v. 344, n. 1-2, p. 326–329, 2004.

DONGARE, U. *et al.* Design of optimal mlp-neural network-based induction motor fault classifier. In: *2022 IEEE International Conference on Power Electronics, Smart Grid, and Renewable Energy (PESGRE)*. Manhattan: IEEE, 2022. p. 1–6.

DRIF, M.; CARDOSO, A. M. Rotor cage fault diagnostics in three-phase induction motors, by the instantaneous non-active power signature analysis. In: *2007 IEEE International Symposium on Industrial Electronics*. Manhattan: IEEE, 2007. p. 1050–1055.

EBRAHIMI, B. M. *et al.* Advanced eccentricity fault recognition in permanent magnet synchronous motors using stator current signature analysis. In: . Manhattan: IEEE, 2013. v. 61, n. 4, p. 2041–2052.

- EPE. *Anuário Estatístico de Energia Elétrica*. 2021. Disponível em: <<https://www.epe.gov.br/>>.
- GAYATHRI, S. Phishing websites classifier using polynomial neural networks in genetic algorithm. In: *2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN)*. Manhattan: IEEE, 2017. p. 1–4.
- GERMEN, E.; BAŞARAN, M.; FIDAN, M. Sound based induction motor fault diagnosis using kohonen self-organizing map. *Mechanical Systems and Signal Processing*, Elsevier, New York, v. 46, n. 1, p. 45–58, 2014.
- GODOY, W. F. *et al.* An application of artificial neural networks and pca for stator fault diagnosis in inverter-fed induction motors. In: *2016 XXII International Conference on Electrical Machines (ICEM)*. Manhattan: IEEE, 2016. p. 2165–2171.
- GOEDEL, A. *Estimador neural de velocidade para motores de indução trifásicos*. Tese (Doutorado) — Universidade de São Paulo, 2007.
- GONGORA, W. S. *Uma abordagem neural no diagnóstico de falhas em rolamentos de motores de indução trifásicos*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2013.
- GONGORA, W. S. *et al.* Embedded system to detect bearing faults in line-connected induction motors. In: *2018 XIII International Conference on Electrical Machines (ICEM)*. Manhattan: IEEE, 2018. p. 1841–1847.
- GONGORA, W. S. *et al.* Neural approach to fault detection in three-phase induction motors. In: *IEEE Latin America Transactions*. Manhattan: IEEE, 2016. v. 14, n. 3, p. 1279–1288.
- GUEDES, J. J. *et al.* Parameters estimation of three-phase induction motors using differential evolution. *Electric Power Systems Research*, Elsevier, New York, v. 154, p. 204–212, 2018.
- GUEDES, J. J. *et al.* Differential evolution applied to line-connected induction motors stator fault identification. *Soft Computing*, Springer, New York, v. 23, n. 21, p. 11217–11226, 2019.
- GURGEL, N. *et al.* Transformações em sistemas elétricos de potência: Análise das transformadas de clarke e park. *Revista Eletrônica de Engenharia Elétrica e Engenharia Mecânica*, v. 3, n. 1, p. 01–12, 2021.
- HAYKIN, S. *Neural Networks and Learning Machines*. New York: Pearson, 2009.
- HU, H. vrelu activation functions for artificial neural networks. In: *2018 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*. Manhattan: IEEE, 2018. p. 856–860.
- HUO, Z. *et al.* Cmmms based reliability centered maintenance. In: *2005 IEEE/PES Transmission & Distribution Conference & Exposition: Asia and Pacific*. Manhattan: IEEE, 2005. p. 1–6.
- IDE, H.; KURITA, T. Improvement of learning for cnn with relu activation by sparse regularization. In: *2017 International Joint Conference on Neural Networks (IJCNN)*. Manhattan: IEEE, 2017. p. 2684–2691.
- IEA. *Key World Energy Statistics 2021*. 2021. 1-81 p. Disponível em: <<https://www.iea.org/reports/key-world-energy-statistics-2021>>.

- JAYALAKSHMY, S.; RITHIKA, S.; RAJASRI, S. Average power based classification of respiratory sounds using svm classifier. In: *2019 IEEE International Conference on System, Computation, Automation and Networking (ICSCAN)*. Manhattan: IEEE, 2019. p. 1–5.
- JUEZ-GIL, M. *et al.* Early and extremely early multi-label fault diagnosis in induction motors. *ISA transactions*, Elsevier, New York, v. 106, p. 367–381, 2020.
- KESTELYN, X. *et al.* Towards a hybrid twin for infrastructure asset management: Investigation on power transformer asset maintenance management. In: *IEEE. 2022 7th International Advanced Research Workshop on Transformers (ARWtr)*. Manhattan, 2022. p. 109–114.
- KHANJANI, M.; EZOJI, M. Electrical fault detection in three-phase induction motor using deep network-based features of thermograms. *Measurement*, Elsevier, New York, v. 173, p. 108622, 2021.
- KHUSHABA, R. N. *et al.* Spatio-temporal inertial measurements feature extraction improves hand movement pattern recognition without electromyography. In: *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Manhattan: IEEE, 2018. p. 2108–2111.
- KONAR, P.; CHATTOPADHYAY, P. Bearing fault detection of induction motor using wavelet and support vector machines (svms). *Applied Soft Computing*, Elsevier, New York, v. 11, n. 6, p. 4203–4211, 2011.
- LAAKSONEN, J.; OJA, E. Classification with learning k-nearest neighbors. In: *Proceedings of International Conference on Neural Networks (ICNN'96)*. Manhattan: IEEE, 1996. v. 3, p. 1480–1483 vol.3.
- LEITE, G. d. N. P. *Diagnóstico de falhas em componentes de turbinas eólicas através da aplicação de quantificadores da teoria da informação*. Pernambuco: Universidade Federal de Pernambuco, 2018.
- LI, X. *et al.* Rolling element bearing fault detection using support vector machine with improved ant colony optimization. New York: Elsevier, 2013. 2726–2734 p.
- LIU, H.-C. *et al.* A novel classification algorithm of thermostable proteins by using hurst exponent and svm classifier. In: *2008 Fourth International Conference on Natural Computation*. Manhattan: IEEE, 2008. v. 5, p. 24–28.
- LIU, L.; ÖZSU, M. T. *Encyclopedia of database systems*. New York: Springer, 2009. v. 6.
- LOECKX, D. *et al.* Nonrigid image registration using conditional mutual information. In: *IEEE Transactions on Medical Imaging*. Manhattan: IEEE, 2010. v. 29, n. 1, p. 19–29.
- LUDWIG, O.; COSTA, E. *Redes neurais-fundamentos e aplicações com programas em C*. Rio de Janeiro: Editora Ciência Moderna, 2007.
- LUGOSI, G. Pattern classification and learning theory. In: *Principles of nonparametric learning*. New York: Springer, 2002. p. 1–56.
- MAGALHÃES, M. N.; LIMA, A. C. P. D. *Noções de probabilidade e estatística*. São Paulo: Editora da Universidade de São Paulo, 2015.

MEHAIRJAN, R. Statistical life data analysis for electricity distribution cable assets - an asset management approach. *IET Conference Proceedings*, Institution of Engineering and Technology, p. 15–15(1), January 2011.

MEHTA, H.; SINGLA, S.; MAHAJAN, A. Optical character recognition (ocr) system for roman script english language using artificial neural network (ann) classifier. In: *2016 International Conference on Research Advances in Integrated Navigation Systems (RAINS)*. Manhattan: IEEE, 2016. p. 1–5.

MESRABADI, H. A.; FAEZ, K. Improving early prostate cancer diagnosis by using artificial neural networks and deep learning. In: *2018 4th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS)*. Manhattan: IEEE, 2018. p. 39–42.

MOAT, G.; COLEMAN, S. Survival analysis and predictive maintenance models for non-sensored assets in facilities management. In: *IEEE. 2021 IEEE international conference on big data (Big Data)*. Manhattan, 2021. p. 4026–4034.

MUÑOZ, N. T. *Cálculo de enrolamentos de máquinas elétricas e sistemas de alarme*. Rio de Janeiro: Freitas Bastos, 1987.

NAZEMI, A.; MALEKI, A. Artificial neural network classifier in comparison with lda and ls-svm classifiers to recognize 52 hand postures and movements. In: *2014 4th International Conference on Computer and Knowledge Engineering (ICCKE)*. Manhattan: IEEE, 2014. p. 18–22.

OLIVEIRA, C. C. B. de *et al.* *Introdução a sistemas elétricos de potência: componentes simétricas*. São Paulo: Editora Blucher, 2000.

ONDEL, O.; BOUTLEUX, E.; CLERC, G. A method to detect broken bars in induction machine using pattern recognition techniques. In: *IEEE Transactions on industry applications*. Manhattan: IEEE, 2006. v. 42, n. 4, p. 916–923.

OROURKE, C. J. *et al.* A geometric interpretation of reference frames and transformations: dq0, clarke, and park. In: *IEEE Transactions on Energy Conversion*. Manhattan: IEEE, 2019. v. 34, n. 4, p. 2070–2083.

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

PALÁCIOS, R. H. C. *et al.* A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. *Electric Power Systems Research*, Elsevier, New York, v. 127, p. 249–258, 2015.

PARVEEN; SINGH, A. Detection of brain tumor in mri images, using combination of fuzzy c-means and svm. In: *2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN)*. Manhattan: IEEE, 2015. p. 98–102.

PASHAEI, E.; YILMAZ, A.; AYDIN, N. A combined svm and markov model approach for splice site identification. In: *2016 6th International Conference on Computer and Knowledge Engineering (ICCKE)*. Manhattan: IEEE, 2016. p. 200–204.

- PEDROSA, G. T. M. d. C. *Detecção e diagnóstico de falhas na performance de aerogeradores*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2016.
- RAO, Q. *et al.* Regularization and iterative initialization of softmax for fast training of convolutional neural networks. In: *2019 International Joint Conference on Neural Networks (IJCNN)*. Manhattan: IEEE, 2019. p. 1–8.
- RODRIGUEZ, I.; ALVES, R.; GUZMAN, V. Analysis of air gap flux to detect induction motor faults. In: *Proceedings of the 41st International Universities Power Engineering Conference*. Manhattan: IEEE, 2006. v. 2, p. 690–694.
- SCALASSARA, P. R. *et al.* Relative entropy measures applied to healthy and pathological voice characterization. *Applied Mathematics and Computation*, Elsevier, New York, v. 207, n. 1, p. 95–108, 2009.
- SESHADRINATH, J.; SINGH, B.; PANIGRAHI, B. K. Investigation of vibration signatures for multiple fault diagnosis in variable frequency drives using complex wavelets. In: *IEEE Transactions on Power Electronics*. Manhattan: IEEE, 2013. v. 29, n. 2, p. 936–945.
- SIDDIQUE, A.; YADAVA, G.; SINGH, B. Identification of three phase induction motor incipient faults using neural network. In: *Conference Record of the 2004 IEEE International Symposium on Electrical Insulation*. Manhattan: IEEE, 2004. p. 30–33.
- SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. *Redes neurais artificiais para engenharia e ciências aplicadas - fundamentos teóricos e aspectos práticos*. São Paulo: Artliber, 2010.
- SOUZA, D. F. de *et al.* A performance evaluation of three-phase induction electric motors between 1945 and 2020. *Energies*, MDPI, Basel, v. 15, n. 6, p. 2002, 2022.
- SUETAKE, M. *Sistemas inteligentes para monitoramento e diagnósticos de falhas em motores de indução trifásicos*. Tese (Doutorado) — Universidade de São Paulo, 2012.
- SUN, J. *et al.* Wood–leaf classification of tree point cloud based on intensity and geometric information. *Remote Sensing*, MDPI, v. 13, n. 20, p. 4050, 2021.
- SUYKENS, J. A.; SIGNORETTO, M.; ARGYRIOU, A. *Regularization, optimization, kernels, and support vector machines*. Boca Raton: CRC Press, 2014.
- SWEENEY, W.; MUSAVI, M.; GUIDI, J. Probabilistic neural network as chromosome classifier. In: *Proceedings of 1993 International Conference on Neural Networks (IJCNN-93-Nagoya, Japan)*. Manhattan: IEEE, 1993. v. 1, p. 935–938 vol.1.
- T., D.; DEEPA, N. A novel intervention method for aspect-based emotion using exponential linear unit (elu) activation function in a deep neural network. In: *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)*. Manhattan: IEEE, 2021. p. 1671–1675.
- THOMAS, M.; JOY, A. T. *Elements of information theory*. New Jersey: Wiley-Interscience, 2006.
- UMANS, S. D. *Máquinas Elétricas de Fitzgerald e Kingsley-7*. Porto Alegre: AMGH Editora, 2014. v. 7.

VERGARA, J. R.; ESTÉVEZ, P. A. A review of feature selection methods based on mutual information. In: *Neural computing and applications*. New York: Springer, 2014. v. 24, n. 1, p. 175–186.

VITOR, A. L. O. *et al.* Induction motor fault diagnosis using wavelets and coordinate transformations. In: *2016 12th IEEE International Conference on Industry Applications (INDUSCON)*. Manhattan: IEEE, 2016. p. 1–8.

YACOUT, S. Fault detection and diagnosis for condition based maintenance using the logical analysis of data. In: IEEE. *The 40th International Conference on Computers & Industrial Engineering*. Manhattan, 2010. p. 1–6.

ZEMMOUCHI-GHOMARI, L.; CHERGUI, S.; OUADAH, A. Proposal of an approach of selection and impact study of cmms use on maintenance functioning, a case study. In: IEEE. *2020 1st International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)*. Manhattan, 2020. p. 1–6.

ZHAN, C.; WANG, J.; XIONG, Z. Image recognition based on optical wavelet and support vector machine. In: *2011 International Conference on Information Management, Innovation Management and Industrial Engineering*. Manhattan: IEEE, 2011. v. 3, p. 340–343.

ÇATALBAŞ, B.; ÇATALBAŞ, B.; MORGÜL, Human activity recognition with different artificial neural network based classifiers. In: *2017 25th Signal Processing and Communications Applications Conference (SIU)*. Manhattan: IEEE, 2017. p. 1–4.

APÊNDICE A – PRODUÇÕES CIENTÍFICAS

Durante o desenvolvimento da pesquisa de mestrado, foram publicados trabalhos diretamente relacionados a esta Dissertação, bem como trabalhos correlatos.

A.1 Artigos Publicados em Periódicos em Autoria ou Coautoria

BAZAN, G. H.; GOEDEL, A.; SCALASSARA, P. R.; ENDO, W.; NUNES, E. A.; TAKASE, V. T. F.; GUEDES, J. J.; GENTIL, M. G. "An Embedded System for Stator Short-Circuit Diagnosis in Three-Phase Induction Motors Using Information Theory and Artificial Neural Networks," in **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, vol. 52, no. 10, pp. 6582-6592, Oct. 2022, doi: 10.1109/TSMC.2022.3149851.

NUNES, E. A.; ANGÉLICO, B. A.; GOEDEL, A. "Diagnóstico de Falhas em Motores de Indução Trifásicos com Aplicação de Sistemas de Informação e Redes Neurais Artificiais em Sinais Submetidos à Transformação de Clarke". **XXIV Congresso Brasileiro de Automática (CBA)**. Fortaleza, CE, Brasil, 2022.

A.2 Certificado de Registro de Programa de Computador em Autoria ou Coautoria com Associação Direta ao Trabalho

GOEDEL, A.; TAKASE, V. T. F.; GUEDES, J. J.; BAZAN, G. H.; NUNES, E. A. Informação Mútua Deslocada para Sistemas Embarcados. **Instituto Nacional da Propriedade Industrial (INPI)**, Jul., 2020. Processo nº: BR512020001370-8.

A.3 Certificado de Registro de Programa de Computador em Autoria ou Coautoria com Colaboração Direta em Outras Pesquisas

GOEDTEL, A.; CASTOLDI, M. F.; TAKASE, V. T. F.; GUEDES, J. J.; NUNES, E. A.; BAZAN, G. H. Evolução Diferencial para Sistemas Embarcados. **Instituto Nacional da Propriedade Industrial (INPI)**, Jul., 2020. Processo nº: BR512020001368-6.