

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

CAROLINA ALVES BIANCHINI

**DIAGNÓSTICO DE FALHAS LOCALIZADAS DE ROLAMENTO EM MOTORES
DE INDUÇÃO TRIFÁSICOS A PARTIR DE UM MODELO MATEMÁTICO**

CORNÉLIO PROCÓPIO

2023

CAROLINA ALVES BIANCHINI

**DIAGNÓSTICO DE FALHAS LOCALIZADAS DE ROLAMENTO EM MOTORES
DE INDUÇÃO TRIFÁSICOS A PARTIR DE UM MODELO MATEMÁTICO**

**DIAGNOSIS OF LOCALIZED BEARING FAULTS IN THREE-PHASE
INDUCTION MOTORS FROM A MATHEMATICAL MODEL**

Dissertação apresentada como requisito para obtenção do título de Mestra em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de Concentração: Controle E Automação De Sistemas.

Orientador: Prof. Dr. Marcelo Favoretto
Castoldi

Coorientador: Prof. Dr. Alessandro Goedel

CORNÉLIO PROCÓPIO

2023



Esta Dissertação está licenciada sob uma Licença Creative Commons Atribuição–Não-Comercial–SemDerivações 4.0 Internacional.



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio



CAROLINA ALVES BIANCHINI

**DIAGNÓSTICO DE FALHAS LOCALIZADAS DE ROLAMENTO EM MOTORES DE INDUÇÃO TRIFÁSICOS
A PARTIR DE UM MODELO MATEMÁTICO**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Sistemas Eletrônicos Industriais.

Data de aprovação: 08 de Fevereiro de 2023

Dr. Marcelo Favoretto Castoldi, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Danilo Hernane Spatti, Doutorado - Usp-Universidade de São Paulo

Dr. Manoel Luis De Aguiar, Doutorado - Escola de Engenharia de São Carlos (Eesc) - Universidade de São Paulo (Usp)

Dr. Wesley Angelino De Souza, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 08/02/2023.

Dedico este trabalho aos meus pais,
pelo incomparável amor.

AGRADECIMENTOS

Agradeço primeiramente a Deus por sempre estar ao meu lado, dando-me força e luz para o andamento deste trabalho.

Aos meus pais, os quais não mediram esforços para fornecer as melhores condições de vida e de estudo a mim e ao meu irmão. Sou grata por tê-los presentes ao meu lado, aconselhando-me e auxiliando-me nos momentos em que é preciso. Ao meu irmão e à minha cunhada, agradeço pelo carinho e companheirismo e, mesmo estando longes, sei que posso contar com vocês.

Ao meu orientador, Prof. Dr. Marcelo Castoldi, pela sua excelente orientação e condução deste trabalho. Reconheço a sua paciência e confiança para comigo no desenvolvimento da pesquisa. Agradecimentos especiais também ao meu coorientador, Prof. Dr. Alessandro Goedel, pela colaboração e apoio prestados.

Aos professores do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), por seus ensinamentos. Agradeço, sobretudo, ao Prof. Dr. Wesley de Souza pelo conhecimento passado e pelas numerosas contribuições e ao Prof. Dr. Paulo Scalassara, pelo suporte prestado.

Aos colegas da pós-graduação e do Laboratório de Sistemas Inteligentes (LSI), pelo convívio, apoio e amizade durante o desenvolvimento da pesquisa. Sem dúvidas, tornaram o trabalho mais descomplicado e prazeroso.

Aos meus amigos e familiares, sou grata pela compreensão e companheirismo durante mais essa etapa de minha vida.

À Universidade Tecnológica Federal do Paraná (UTFPR), por proporcionar essa oportunidade e a estrutura necessária para a realização deste trabalho.

Ao suporte financeiro concedido pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), por meio de uma bolsa de estudos de Demanda Social (CAPES-DS) (processo n.º 88887.625348/2021-00).

"Não deve haver limites para o esforço humano. Somos todos diferentes. Por pior que a vida possa parecer, sempre há algo que podemos fazer em que podemos obter sucesso. Enquanto houver vida, haverá esperança".

Stephen Hawking

RESUMO

A vasta utilização dos motores de indução trifásicos (MIT) em diversos setores da indústria instiga a busca por técnicas de monitoramento e diagnóstico de defeitos nessas máquinas a fim de evitar paradas na produção e manutenções imprevistas. Dentre os componentes do MIT com mais ocorrências de falhas está o rolamento, cuja detecção de falhas pode ser efetuada por meio da análise do comportamento de algumas variáveis do motor, como vibração e/ou corrente do estator, e sua identificação, a partir de inteligência artificial. Porém, há poucos estudos sobre a modelagem e simulação dessas falhas, as quais se apresentam como um recurso viável para abranger diversos motores e condições específicas de funcionamento, como diferentes níveis de cargas e alimentações. Logo, este trabalho busca elaborar um modelo para simulações de falhas de rolamento no MIT que forneça dados de corrente de uma fase do estator para análise de suas características estatísticas no domínio do tempo e da frequência. A partir dessas informações extraídas de bancos de dados de corrente simulados e obtidos experimentalmente em bancada de teste de motores de 1 e 2 CV, amostras com 23 atributos estatísticos foram submetidas a classificações não-supervisionada (Rede auto-organizável de Kohonen) e supervisionadas (Floresta Aleatória, k -Vizinhos Mais Próximos, Perceptron Multicamadas e Máquina de Vetores de Suporte). As altas taxas de acurácia e F_1 -score obtidas nas classificações entre motores saudáveis e com falhas podem validar a utilização desse banco de dados artificial atrelado a observações experimentais de modo a tornar mais robusto o diagnóstico de falhas de rolamento executado atualmente. Além disso, os mapas topológicos gerados permitem verificar a proximidade entre amostras simuladas e experimentais quando agrupadas, visto a semelhança entre suas características. Para verificar a capacidade de generalização do modelo proposto, os algoritmos supervisionados foram também treinados e testados com dados simulados de diversas potências de motores, juntamente às amostras experimentais de motores de 1 e 2 CV, obtendo taxas acima de 94,00%.

Palavras-chave: modelagem e simulação; motor de indução trifásico; falhas de rolamento; características estatísticas; classificação de padrões.

ABSTRACT

The wide use of three-phase induction motors (TIM) in various industry sectors encourages the search for techniques of monitoring and diagnosing defects in these machines to avoid production downtime and unforeseen maintenance. Among the TIM's components with more occurrences of failures is the bearing, whose fault detection can be performed by analyzing the behavior of some motor variables, such as vibration and/or stator current, and its identification, using artificial intelligence. However, few studies on the modeling and simulation of these faults present a viable resource to cover several engines and specific operating conditions, such as different levels of loads and supplies. Therefore, this work aims to develop a model for TIM's bearing failure simulations that provides current data of a stator phase to analyze this statistical features in the time and frequency domains. From information extracted from simulated and experimental current datasets of 1 and 2 HP motors, samples with 23 statistical attributes were submitted to unsupervised (Kohonen self-organizing network) and supervised classifications (Random Forest, k -Nearest Neighbors, Multilayer Perceptron and Support Vector Machine). The high accuracy rates and F_1 -score obtained in the classifications between healthy and faulty engines can validate the use of this artificial database linked to experimental observations in order to make the diagnosis of bearing failures currently performed more robust. In addition, the generated topological maps allow verifying the proximity between simulated and experimental samples when clusterized, given the similarity between their characteristics. To check the generalization of the proposed model, the supervised algorithms were also trained and tested with simulated data from different motor powers, along with the experimental samples of 1 and 2 HP engines, obtaining rates above 94,00%.

Keywords: modeling and simulation; three-phase induction motor; bearing fault; statistical features; pattern classification.

LISTA DE ILUSTRAÇÕES

Figura 1 – Geometria do rolamento.	22
Figura 2 – Rotação do eixo do rotor na presença de defeito na pista externa. . .	23
Figura 3 – Rotação do eixo do rotor na presença de defeito na pista interna. . .	23
Figura 4 – Diagrama das principais áreas contempladas no diagnóstico de falhas do MIT.	26
Figura 5 – Esquemático da validação cruzada com 5 partições.	33
Figura 6 – Exemplo do funcionamento do <i>bootstrap</i> com um conjunto de três dados.	39
Figura 7 – Conexões entre os enrolamentos do MIT.	49
Figura 8 – Bloco de transformação das tensões trifásicas para a referência qd0. . .	50
Figura 9 – Bloco de implementação das correntes e fluxos concatenados instantâneos no eixo q.	51
Figura 10 – Bloco de implementação das correntes e fluxos concatenados instantâneos no eixo d.	52
Figura 11 – Bloco de implementação da corrente i_{0s}	52
Figura 12 – Bloco do rotor.	53
Figura 13 – Bloco de transformação das correntes na referência qd0 para o eixo de referência trifásico.	53
Figura 14 – Bloco de variação das reatâncias indutivas conforme falha.	53
Figura 15 – Modelo do motor de indução trifásico com falhas de rolamento na referência qd0.	54
Figura 16 – Bancada de teste para geração dos dados de corrente.	56
Figura 17 – Diagrama das classificações realizadas neste trabalho.	62
Figura 18 – Mapa auto-organizável de Kohonen do treinamento para motores de 1 CV na situação de duas classes.	67
Figura 19 – Mapa auto-organizável de Kohonen do teste para motores de 1 CV na situação de duas classes.	67
Figura 20 – Mapa auto-organizável de Kohonen do treinamento para motores de 2 CV na situação de duas classes.	68
Figura 21 – Mapa auto-organizável de Kohonen do teste para motores de 2 CV na situação de duas classes.	69
Figura 22 – Mapa auto-organizável de Kohonen do treinamento para motores de 1 e 2 CV na situação de duas classes.	69
Figura 23 – Mapa auto-organizável de Kohonen do teste para motores de 1 e 2 CV na situação de duas classes.	70
Figura 24 – Mapa auto-organizável de Kohonen do treinamento para motores de 1 CV na situação de multiclases.	74
Figura 25 – Mapa auto-organizável de Kohonen do teste para motores de 1 CV na situação de multiclases.	74
Figura 26 – Mapa auto-organizável de Kohonen do treinamento para motores de 2 CV na situação de multiclases.	75
Figura 27 – Mapa auto-organizável de Kohonen do teste para motores de 2 CV na situação de multiclases.	75
Figura 28 – Mapa auto-organizável de Kohonen do treinamento para motores de 1 e 2 CV na situação de multiclases.	76

Figura 29 – Mapa auto-organizável de Kohonen do teste para motores de 1 e 2 CV na situação de multiclassés.	76
Figura 30 – Gráfico das ocorrências dos atributos nas oito classificações supervisionadas após seleção de atributos.	79
Quadro 1 – Frequências no espectro do estator devido a falhas de rolamento.	25
Quadro 2 – Exemplo de matriz de confusão.	46

LISTA DE TABELAS

Tabela 1 – Cálculo dos atributos.	30
Tabela 2 – Parâmetros dos motores utilizados nas simulações.	55
Tabela 3 – Dimensões dos rolamentos dos motores utilizados nas simulações.	56
Tabela 4 – Especificações dos motores utilizados para a geração de dados a partir de simulação e bancada de teste.	57
Tabela 5 – Número de amostras após separação dos sinais.	58
Tabela 6 – Hiper-parâmetros selecionados do classificador não-supervisionado.	60
Tabela 7 – Hiper-parâmetros dos classificadores supervisionados varridos pela busca em grade e os selecionados.	61
Tabela 8 – Número de amostras balanceadas de cada condição dos motores de 1 e 2 CV para duas classes.	63
Tabela 9 – Número de amostras balanceadas de cada condição de diversos motores para duas classes.	63
Tabela 10 – Número de amostras balanceadas de cada condição dos motores de 1 e 2 CV para multiclases.	64
Tabela 11 – Número de amostras balanceadas de cada condição de diversos motores para multiclases.	64
Tabela 12 – Médias da acurácia (A_c) e do F_1 -score de cinco testes das classificações não-supervisionadas para duas classes.	66
Tabela 13 – Médias da Acurácia (A_c) e do F_1 -score de cinco testes das classificações supervisionadas para duas classes.	71
Tabela 14 – Atributos selecionados por cada algoritmo e pelos três juntos para duas classes.	71
Tabela 15 – Médias da Acurácia (A_c) e do F_1 -score de cinco testes das classificações supervisionadas com seleção de atributos para duas classes.	72
Tabela 16 – Médias da acurácia e do F_1 -score de cinco testes das classificações não-supervisionadas para multiclases.	73
Tabela 17 – Médias da Acurácia (A_c) e do F_1 -score de cinco testes das classificações supervisionadas para multiclases.	77
Tabela 18 – Atributos selecionados por cada algoritmo e pelos três juntos para multiclases.	78
Tabela 19 – Médias da Acurácia (A_c) e do F_1 -score de cinco testes das classificações supervisionadas com seleção de atributos para multiclases.	78
Tabela 20 – Classificadores supervisionados com melhores desempenhos para as análises realizadas na terceira e quarta situações com seleção de atributos.	80

LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CART	Do inglês, <i>Classification and Regression Trees</i>
CDF	Função de Distribuição Cumulativa, do inglês <i>Cumulative Distribution Function</i>
CNN	Rede Neural Convolucional, do inglês <i>Convolutional Neural Network</i>
CV	Validação cruzada, do inglês <i>Cross-Validation</i>
DT	Árvores de Decisão, do inglês <i>Decision Tree</i>
DWT	Transformada Discreta de Wavelet, do inglês <i>Discret Wavelet Transform</i>
EMD	Decomposição em Modos Empíricos, do inglês <i>Empirical Mode Decomposition</i>
ENN	Do inglês, <i>Edited Nearest Neighbors</i>
FEM	Métodos de Elementos Finitos, do inglês <i>Finite Element Method</i>
FFT	Transformada Rápida de Fourier, do inglês <i>Fast Fourier Transform</i>
GB	Do inglês, <i>Gradient Boosting</i>
ID3	Do inglês, <i>Inductive Decision Tree</i>
kNN	K-ésimo Vizinho mais Próximo, do inglês <i>k-Nearest Neighbors</i>
LASSO	Do inglês, <i>Least Absolute Shrinkage and Selection Operator</i>
MCC	Circuito Múltiplo Acoplado, do inglês <i>Multiple Coupled Circuit</i>
MCSA	Análise da assinatura de corrente do motor, do inglês <i>Motor Current Signature Analysis</i>
MIT	Motor de Indução Trifásico
MSE	Erro quadrático médio, do inglês <i>Mean Square Error</i>
MWFT	Teoria da Função Enrolamento Modificada, do inglês <i>Modified Winding Function Theory</i>
PCA	Análise de Componentes de Principais, do inglês <i>Principal Component Analysis</i>
PMC	Perceptron Multicamadas
PNN	Rede Neural Probabilística, do inglês <i>Probabilistic Neural Network</i>
RBF	Função de Base Radial, do inglês <i>Radial Basis Function</i>
RF	Floresta Aleatória, do inglês <i>Random Forest</i>
RFE	Eliminação Recursiva de Atributos, do inglês <i>Recursive Feature Elimination</i>
RNA	Rede Neural Artificial
RSS	Soma residual dos quadrados, do inglês <i>Residual Sum of Squares</i>
STFT	Transformada de Fourier de Curta Duração, do inglês <i>Short-Time Fourier Transform</i>
SVM	Máquina de Vetores de Suporte, do inglês <i>Support Vector Machine</i>
TIM	Motor de Indução Trifásico, do inglês <i>Three-phase Induction Motor</i>
UTFPR	Universidade Tecnológica Federal do Paraná
WFA	Abordagem da Função de Enrolamento, do inglês <i>Winding Function Approach</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	JUSTIFICATIVA	18
1.2	OBJETIVOS	18
1.2.1	Objetivo Geral	18
1.2.2	Objetivos Específicos	19
1.3	ORGANIZAÇÃO DO TRABALHO	19
1.4	PRODUÇÕES CIENTÍFICAS	19
2	MODELAGEM DO MOTOR DE INDUÇÃO TRIFÁSICO COM FALHAS DE ROLAMENTO	20
2.1	MODELO MATEMÁTICO DO MIT	20
2.2	MODELO MATEMÁTICO DO MIT COM FALHAS DE ROLAMENTO	22
3	ESTRATÉGIAS PARA DIAGNÓSTICO DE FALHAS E MONITORAMENTO DO MOTOR DE INDUÇÃO TRIFÁSICO	26
3.1	SENSORIAMENTO	26
3.2	EXTRAÇÃO DE CARACTERÍSTICAS	28
3.3	TRATAMENTO DAS AMOSTRAS	30
3.3.1	Normalização	31
3.3.2	Balanceamento	32
3.3.3	Validação Cruzada com k-partições	32
3.3.4	Seleção dos atributos	33
3.3.4.1	LASSO-CV	34
3.3.4.2	Eliminação Recursiva de Atributos	35
3.3.4.3	Árvore de Decisão	35
3.3.4.4	<i>Gradient Boosting</i>	37
3.4	CLASSIFICADORES DE PADRÕES	38
3.4.1	Floresta Aleatória	38
3.4.1.1	<i>Bootstrap</i>	39
3.4.1.2	<i>Bagging</i>	40
3.4.1.3	Funcionamento da Floresta Aleatória	40
3.4.2	k-ésimo Vizinhos Mais Próximos	41
3.4.3	Rede Perceptron Multicamadas	42
3.4.4	Máquina de Vetores de Suporte	43
3.4.5	Redes Auto-organizáveis de Kohonen	45
3.5	AVALIAÇÃO DOS RESULTADOS	46
4	MATERIAIS E MÉTODOS	48
4.1	GERAÇÃO E COLETA DOS DADOS	48
4.1.1	Simulação do MIT com falhas	48
4.1.2	Bancada Experimental	55
4.2	EXTRAÇÃO DE CARACTERÍSTICAS	57
4.3	TRATAMENTO DOS DADOS	58
4.4	PARAMETRIZAÇÃO DOS CLASSIFICADORES DE PADRÃO	59
4.5	TREINAMENTOS E TESTES	60
4.5.1	Duas classes	62
4.5.2	Multiclasses	63

5	RESULTADOS E DISCUSSÃO	65
5.1	CLASSIFICAÇÃO EM DUAS CLASSES	65
5.1.1	Classificador não-supervisionado	66
5.1.1.1	Mapa de Kohonen: motores de 1 CV	67
5.1.1.2	Mapa de Kohonen: motores de 2 CV	68
5.1.1.3	Mapa de Kohonen: motores de 1 e 2 CV	69
5.1.2	Classificadores supervisionados	70
5.2	CLASSIFICAÇÃO EM MULTICLASSES	72
5.2.1	Classificador não-supervisionado	72
5.2.1.1	Mapa de Kohonen: motores de 1 CV	73
5.2.1.2	Mapa de Kohonen: motores de 2 CV	74
5.2.1.3	Mapa de Kohonen: motores de 1 e 2 CV	75
5.2.2	Classificadores supervisionados	77
6	CONCLUSÕES	81
6.1	TRABALHOS FUTUROS	82
	REFERÊNCIAS	83

1 INTRODUÇÃO

O motor de indução trifásico (MIT) é amplamente utilizado em diferentes áreas da indústria devido ao seu baixo custo de aquisição e manutenção, eficiência, facilidade de controle e robustez diante de diversos ambientes e cargas mecânicas. Isso pode ser constatado pelo fato de que os motores elétricos são responsáveis por 43% a 46% do consumo de energia elétrica total produzida no mundo (ROBLES *et al.*, 2021; PRINCE; HATI, 2021).

Embora possua alta confiabilidade, o MIT está sujeito a falhas, provenientes de ambientes hostis, cargas inadequadas, variações na rede de alimentação, lubrificações incorretas, entre outras situações. Essas condições tornam necessários investimentos em técnicas de monitoramento e diagnóstico dessas máquinas para evitar paradas inesperadas, perdas de produção e aumento de custo (INCE *et al.*, 2021).

As falhas no MIT ocorrem geralmente em três componentes principais: estator, rotor e rolamentos (GANGSAR; TIWARI, 2020). Dentre as falhas no estator, encontram-se a quebra do isolamento devido a curto-circuitos entre espiras de mesma fase ou entre fases e, no rotor, barras ou anéis quebrados (FROSINI, 2020). As anomalias nos rolamentos, que possuem uma participação de 41% a 51% nas ocorrências de defeitos, podem estar presentes nas pistas do rolamento (interna e externa) e/ou nas suas esferas internas (GANGSAR; TIWARI, 2020; TERRON-SANTIAGO *et al.*, 2021).

Operando em condições normais com carga nominal e bom alinhamento, as falhas no rolamento surgem devido ao uso com pequenas fissuras nas pistas que podem evoluir para descamações e fragmentações e se propagar, gerando vibrações, ruídos e desnivelando o eixo (IMMOVILLI *et al.*, 2013). Além disso, outras condições externas podem interferir na vida útil desse componente como contaminação, corrosão, falta de lubrificação e instalação incorreta.

Perante isso, a manutenção preditiva tem recebido grande atenção dos pesquisadores uma vez que, ao se basear no monitoramento e diagnóstico das falhas, possui potencial para ser mais assertiva na recuperação do MIT, em comparação com a manutenção preventiva e corretiva.

O monitoramento das condições do motor de indução com ênfase nos rolamentos começou em 1969, com a publicação de Balderston (1969), em que pequenos desalinhamentos foram detectados em alta frequência nos sinais provenientes de ace-

lerômetros. Logo nos anos seguintes, a análise de envelope do sinal de vibração se tornou uma ferramenta muito utilizada entre os pesquisadores para a detecção de falhas de rolamento (RANDALL; ANTONI, 2011).

Atualmente, além da análise da vibração, há diversas abordagens para o reconhecimento de má operação das máquinas, como monitoramento do campo magnético, medições de temperatura e ruídos sonoros, análise química da graxa de lubrificação e análise de assinatura de corrente em motores (MCSA - do inglês, *Motor Current Signature Analysis*) (FROSINI, 2020).

Uma vez que as falhas de rolamento geram vibrações com frequências características, as análises dos espectros das vibrações e da corrente do motor constituem-se como as principais ferramentas para o diagnóstico desses defeitos, uma vez que são influenciadas por essas frequências características. Uma das técnicas clássicas para essa observação é por meio da Transformada Rápida de Fourier (FFT - do inglês, *Fast Fourier Transform*).

No entanto, ambos sensoriamentos possuem limitações. Os sensores de vibração são sensíveis a perturbações mecânicas como outros ruídos e vibrações, podendo acarretar em uma análise errônea do estado do motor (IMMOVILLI *et al.*, 2013). Além disso, para a correta instalação dos sensores, é necessário que as máquinas estejam em um espaço adequado e de fácil instalação (TOMA; PROSVIRIN; KIM, 2020). Em relação à técnica de MCSA, sua desvantagem se encontra na especificidade de seus sensores para cada tipo e potência de motor, o que pode tornar o diagnóstico menos flexível para diversos ambientes de produção.

Em vista disso e também em razão de os sinais de corrente serem ricos em informação tanto no domínio do tempo como no da frequência, este trabalho optou por trabalhar com a MCSA para obtenção de dados. Outros estudos também fizeram essa escolha como Toma, Prosvirin e Kim (2020), o qual utiliza recursos estatísticos para extrair da MCSA atributos para a entrada em três tipos de classificadores: *k*-ésimo Vizinho Mais Próximo (kNN - do inglês, *k-Nearest Neighbors*), Árvores de Decisão (DT - do inglês, *Decision Trees*) e Floresta Aleatória (RF - do inglês, *Random Forest*). Já o trabalho de Singh e Kumar (2017) utiliza Transformada de Wavelet Contínua no sinal de corrente do estator para detectar de forma eficiente as falhas de rolamento. Elbouchikhi *et al.* (2017) aborda as técnicas de decomposição em modos empíricos (EMD - do inglês, *Empirical Mode Decomposition*) e Transformada Hilbert-Huang no sinal de corrente

para extrair das funções de modo intrínseco características que detectem as falhas de rolamento. Uma comparação entre classificadores de padrões a partir de dados no domínio do tempo da corrente é feita por Palácios, Silva *et al.* (2015) para avaliar suas eficiências, sendo considerados o Classificador Naive Bayes, kNN, Máquina de Vetores de Suporte (SVM - do inglês, *Support Vector Machine*) e Perceptron Multicamadas (PMC).

Outro ponto relevante é que a maioria dos estudos focam em análises de experimentos realizados em bancada, permitindo uma averiguação mais próxima da realidade dos usos do MIT. No entanto, há algumas limitações, como a disponibilidade de motores de diferentes potências e aplicações, além de recursos para fornecer a instrumentação adequada para cada situação. Assim, a modelagem e simulação das falhas podem complementar os estudos, por meio do aumento do número de amostras e da robustez do método de detecção de falhas adotado.

Como há pouco conteúdo acerca de dados provenientes de modelos e simulações das falhas, este trabalho busca consolidar essa abordagem através de uma modelagem e simulação de simples implementação. Há quatro abordagens principais para a modelagem de motores com falhas: baseada em circuitos elétricos (MCC - do inglês, *Multiple Coupled Circuit*, WFA - do inglês, *Winding Function Approach* e Transformação nos eixos q-d), em circuitos magnéticos, em métodos de elementos finitos (FEM - do inglês, *Finite Element Method*) e em modelos híbridos, que são a combinação dos métodos de modelagem analítica (circuitos elétricos ou magnéticos) e numérica (FEM) (TERRON-SANTIAGO *et al.*, 2021).

Embora os modelos baseados em circuitos magnéticos, em métodos de elementos finitos e em modelos híbridos, como os realizados por Lannoo *et al.* (2020), Sapena-Bano *et al.* (2019) e Martinez, Belahcen e Detoni (2016), possuam maior acurácia para representar o motor, requerem maior custo computacional e tempo devido à sua alta complexidade. Já os modelos baseados em circuitos elétricos, ao assumirem algumas condições como total simetria do motor, permeabilidade linear e uniformidade do entreferro, tendem a possuir menor acurácia e tais desconsiderações podem prejudicar a correta modelagem do motor com falha. No entanto, sua fácil implementação e baixa complexidade podem ser exploradas para atender ao monitoramento online das máquinas.

Assim, há estudos baseados em circuitos elétricos como o trabalho de Rezaee-

Alam e Rezaeealam (2021), o qual compara as técnicas de WFA e FEM e obtém melhores resultados com o primeiro método. Ojaghi, Sabouri e Faiz (2018) apresenta o modelo analítico do motor de indução com falhas de rolamento em função da variação do entreferro, usando a teoria da função enrolamento modificada (MWFT - do inglês, *Modified Winding Function Theory*).

Utilizando o referencial qd0, há o trabalho de Chen e Zivanovic (2010), o qual elabora um modelo de simulação das falhas no estator e rotor e implementa no ambiente Simulink/MATLAB®. Ademais, Shen Zhang *et al.* (2020) também utiliza esse referencial e propõe a quantificação da falha de rolamento por meio do nível de desbalanceamento do entreferro, o qual é estimado por um modelo matemático da variação da indutância que possui como dado de entrada o espectro da corrente do estator.

Os trabalhos de Ojaghi, Sabouri e Faiz (2018) e Shen Zhang *et al.* (2020) baseiam-se na modelagem proposta por Blödt *et al.* (2008), cujo trabalho é de grande contribuição científica. Tal estudo apresenta a relação matemática entre as frequências características de vibração das falhas de rolamento e a corrente do estator, uma vez que há variação do comprimento do entreferro e do torque mecânico na ocorrência desse tipo de falha. Essa variação do comprimento do entreferro interfere na permeância e, conseqüentemente, na indutância e corrente do estator da máquina.

Portanto, em busca de uma modelagem e simulação de falhas de rolamento de baixa complexidade e que gerassem dados de corrente para validação, este trabalho propõe a construção no Simulink/MATLAB® de um modelo matemático baseado nas contribuições de Blödt *et al.* (2008) por meio da transformação para a referência qd0.

Mediante a inserção de oscilações na indutância do MIT, serão simulados quatro condições desse motor: saudável, com falhas de rolamento nas pistas externa e interna e nas esferas. Dados de corrente dessas simulações, bem como de ensaios em bancadas de teste, servirão de base para a detecção das falhas. Para isso, características estatísticas nos domínios do tempo e da frequência serão extraídas para serem usadas como atributos das amostras de entrada de quatro classificadores de padrões supervisionados e outro não-supervisionado, de modo a verificar a presença e a diferença entre as falhas. Assim, será possível validar o método da utilização de dados artificiais junto a experimentais para tornar mais robusto o diagnóstico de falhas de rolamento no MIT.

1.1 JUSTIFICATIVA

No Brasil, os sistemas motrizes utilizam 70% da energia elétrica demandada pelo setor industrial (ELETROBRAS, 2021; SAUER *et al.*, 2015). Logo, é notável a sua participação na produção e economia do país. Contudo, falhas inesperadas nos motores de indução provocam paradas e perdas na produção, além dos prejuízos, tornando-se necessárias técnicas de manutenção preditivas para evitar essas situações.

O monitoramento e diagnóstico de falhas de rolamento atualmente possui diversas abordagens e estudos que comprovam sua efetividade em detectar a falha antes de atingir um grau que prejudique sua operação, permitindo tomar medidas para sua recuperação de forma planejada e antecipada.

No entanto, embora possuam grande eficiência e bastantes trabalhos com sucesso nesses temas, possuem insuficiência em obter uma extensa relação de dados dos motores em diversas situações, uma vez que os laboratórios estão condicionados aos seus equipamentos disponíveis. Assim, a modelagem do MIT com falhas pode contribuir para mitigar essa deficiência, fornecendo observações de forma simplificada e rápida.

Dessa forma, este trabalho busca desenvolver o modelo matemático do MIT com falhas localizadas de rolamento que permita a geração de um banco de dados de corrente de uma fase do estator suficiente para complementar os estudos realizados em bancadas de testes, de forma a aumentar ainda mais a aplicabilidade e a eficácia destes.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Implementação e simulação do modelo matemático do motor de indução trifásico com falhas localizadas de rolamento, sujeito a condições variáveis de conjugado de carga e desequilíbrio de tensão, quando conectados diretamente à rede.

1.2.2 Objetivos Específicos

Os objetivos específicos do trabalho são apresentados a seguir:

- Estudar o estado da arte referente à modelagem matemática e simulação do motor de indução trifásico com falhas localizadas de rolamento;
- Estudar o estado da arte referente às metodologias de detecção e diagnóstico de falhas de rolamento;
- Implementar o modelo do motor de indução trifásico nos eixos qd0 no Simulink/MATLAB®;
- Vincular o modelo matemático da falha no modelo do motor;
- Simular e gerar o banco de dados da corrente do estator;
- Realizar a extração de características que identifiquem as falhas dos bancos de dados experimental e simulado;
- Testar os classificadores de padrões não-supervisionado e supervisionados.

1.3 ORGANIZAÇÃO DO TRABALHO

O presente trabalho está organizado da seguinte forma: o capítulo 2 contempla um estudo teórico da modelagem do MIT e das falhas de rolamento; o capítulo 3, a revisão do estado da arte das técnicas de diagnóstico de falhas de rolamento no MIT; já o capítulo 4 apresenta os materiais e métodos utilizados e o capítulo 5, os resultados e a discussão. Por fim, o capítulo 6 discorre sobre as conclusões e considerações a respeito da pesquisa realizada.

1.4 PRODUÇÕES CIENTÍFICAS

Foi publicado um trabalho, durante o desenvolvimento da pesquisa de Mestrado, diretamente relacionado a esta dissertação em Conferência Nacional, conforme exposto a seguir:

- BIANCHINI, C. A.; CASTOLDI, M. F.; GOEDEL, A. Diagnóstico de Falhas de Rolamento em Motores de Indução Trifásicos a partir de um Modelo Matemático. In: XXIV CONGRESSO BRASILEIRO DE AUTOMÁTICA (CBA), out. 2022, Fortaleza, CE, Brasil. **Anais [...]**. [S. l.: s. n.], 2022.

2 MODELAGEM DO MOTOR DE INDUÇÃO TRIFÁSICO COM FALHAS DE ROLAMENTO

O presente capítulo visa a apresentar a modelagem matemática do MIT com falhas de rolamento, as quais podem ser nas pistas interna e externa e nas esferas. Dessa forma, a primeira seção aborda o modelo matemático do MIT em condições saudáveis na referência qd0 estacionária.

Na seção seguinte, a abordagem matemática para falhas de rolamento proposta por Blödt *et al.* (2008) é exibida com detalhes para, posteriormente, desenvolver o equacionamento de variação da indutância no modelo exposto anteriormente. É a partir deste que será realizada a modelagem no Simulink/MATLAB[®] do MIT com falhas de rolamento.

2.1 MODELO MATEMÁTICO DO MIT

O equacionamento do MIT é transformado para a referência qd0 estacionária, de forma a facilitar a manipulação das equações. Isso se deve ao fato de que, no sistema de referência trifásico, a máquina é descrita por seis equações diferenciais de primeira ordem com indutâncias variantes no tempo e dependentes do movimento do rotor, ao passo que, na referência escolhida, essas variáveis são constantes.

Para estimar as variáveis trifásicas u_a , u_b e u_c na referência qd0 u_q , u_d e u_0 , onde u pode representar as tensões, correntes e fluxos concatenados, é necessário fazer a transformação exposta em (1) (ONG, 1998):

$$\begin{bmatrix} u_q \\ u_d \\ u_0 \end{bmatrix} = [\mathbf{T}_{qd0}(\theta_t)] \begin{bmatrix} u_a \\ u_b \\ u_c \end{bmatrix}, \quad (1)$$

em que θ_t é o ângulo de transformação entre o eixo q da referência qd0 e o eixo a do enrolamento do estator na referência trifásica e $\mathbf{T}_{qd0}(\theta_t)$ é dado por (2) (ONG, 1998):

$$\mathbf{T}_{qd0}(\theta_t) = \frac{2}{3} \begin{bmatrix} \cos(\theta_t) & \cos(\theta_t - \frac{2\pi}{3}) & \cos(\theta_t + \frac{2\pi}{3}) \\ \sin(\theta_t) & \sin(\theta_t - \frac{2\pi}{3}) & \sin(\theta_t + \frac{2\pi}{3}) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix}. \quad (2)$$

Logo, as tensões dos enrolamentos do estator, v_s , e rotor referenciado ao estator, v_r' , são representadas pelas equações em (3) (ONG, 1998):

$$\begin{aligned}
 v_{qs} &= \frac{p}{w_b} \Psi_{qs} + r_s i_{qs}, \\
 v_{ds} &= \frac{p}{w_b} \Psi_{ds} + r_s i_{ds}, \\
 v_{0s} &= \frac{p}{w_b} \Psi_{0s} + r_s i_{0s}, \\
 v'_{qr} &= \frac{p}{w_b} \Psi'_{qr} - \frac{w_r}{w_b} \Psi'_{dr} + r'_r i'_{qr}, \\
 v'_{dr} &= \frac{p}{w_b} \Psi'_{dr} + \frac{w_r}{w_b} \Psi'_{qr} + r'_r i'_{dr}, \\
 v'_{0r} &= \frac{p}{w_b} \Psi'_{0r} + r'_r i'_{0r},
 \end{aligned} \tag{3}$$

em que os subscritos q , d e 0 indicam os eixos em quadratura e direto e a sequência zero, p é o operador diferencial $\frac{d}{dt}$, r_s e r_r' são as resistências do estator e rotor referido ao estator, i_s e i_r' , as correntes do estator e rotor referido ao estator, respectivamente. Já w_b é a frequência angular de base, calculado por (4):

$$w_b = 2\pi f_s, \tag{4}$$

onde f_s é a frequência síncrona. As variáveis Ψ_s e Ψ_r' indicam os fluxos concatenados instantâneos no estator e rotor referido ao estator, calculados por (5):

$$\Psi = w_b \lambda, \tag{5}$$

em que λ é o fluxo concatenado. Os valores de Ψ_s e Ψ_r' são obtidos pela equação (6) (ONG, 1998):

$$\begin{bmatrix} \Psi_{qs} \\ \Psi_{ds} \\ \Psi_{0s} \\ \Psi'_{qr} \\ \Psi'_{dr} \\ \Psi'_{0r} \end{bmatrix} = \begin{bmatrix} x_{lsm} & 0 & 0 & x_m & 0 & 0 \\ 0 & x_{lsm} & 0 & 0 & x_m & 0 \\ 0 & 0 & x_{ls} & 0 & 0 & 0 \\ x_m & 0 & 0 & x'_{lrm} & 0 & 0 \\ 0 & x_m & 0 & 0 & x'_{lrm} & 0 \\ 0 & 0 & 0 & 0 & 0 & x'_{lr} \end{bmatrix} \begin{bmatrix} i_{qs} \\ i_{ds} \\ i_{0s} \\ i'_{qr} \\ i'_{dr} \\ i'_{0r} \end{bmatrix}, \tag{6}$$

sendo:

$$x_{lsm} = x_{ls} + x_m, \tag{7}$$

$$x'_{lrm} = x'_{lr} + x_m. \quad (8)$$

As variáveis x_{ls} e x_{lr} caracterizam as reatâncias indutivas de dispersão no estator e no rotor referido ao estator e x_m é a reatância indutiva de magnetização; essas, por sua vez, são obtidas por (9):

$$x = w_b L, \quad (9)$$

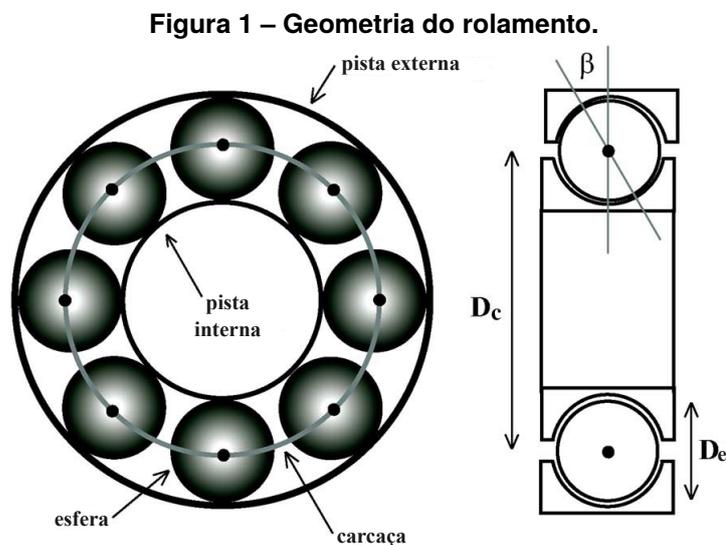
em que L é a indutância. Enquanto que o torque eletromagnético T_{em} é dado por (10) (ONG, 1998):

$$T_{em} = \frac{3}{2} \frac{P}{2w_b} (\Psi_{ds} i_{qs} - \Psi_{qs} i_{ds}), \quad (10)$$

onde P é o número de polos.

2.2 MODELO MATEMÁTICO DO MIT COM FALHAS DE ROLAMENTO

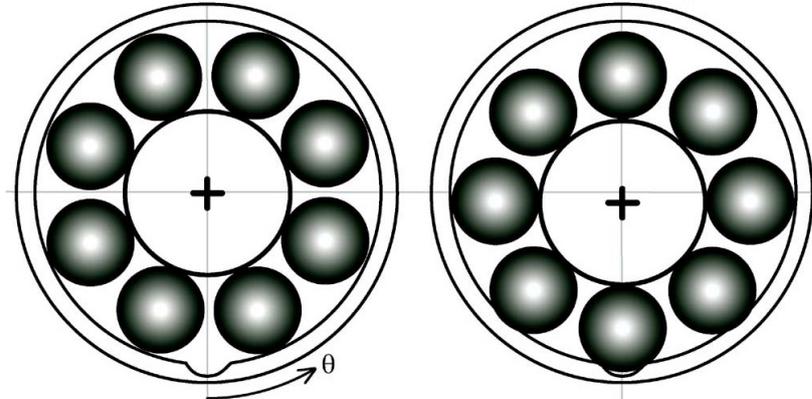
Cada tipo de falha de rolamento gera uma perturbação mecânica com frequência característica, que interfere na rotação da máquina, oscilando o comprimento do entreferro e interferindo na corrente do estator. O presente estudo leva em consideração essas frequências para o equacionamento da variação da indutância a fim de simular o motor com falha e, para isso, considera o rolamento de geometria apresentada na Figura 1.



Fonte: adaptado de Blödt *et al.* (2008).

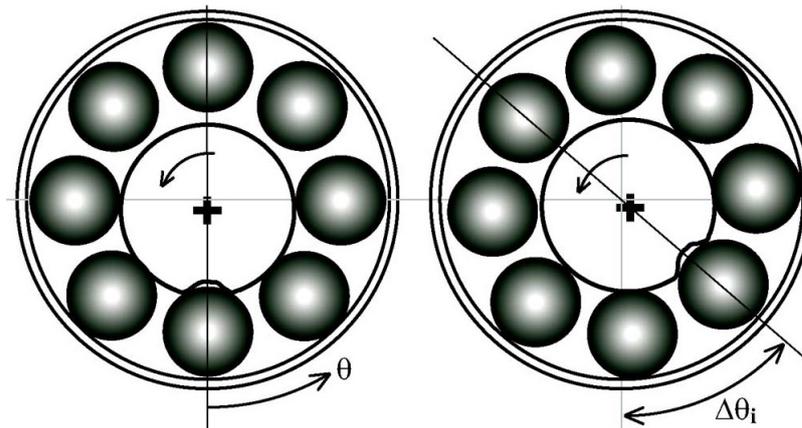
As Figuras 2 e 3 exibem como defeitos nas pistas externa e interna, respectivamente, interferem na rotação do rolamento.

Figura 2 – Rotação do eixo do rotor na presença de defeito na pista externa.



Fonte: Blödt *et al.* (2008).

Figura 3 – Rotação do eixo do rotor na presença de defeito na pista interna.



Fonte: Blödt *et al.* (2008).

Como o movimento do eixo é radial, a perturbação, ocasionada pela passagem do rolamento pela falha, é periódica com uma frequência característica f_c . Tal frequência f_c , que pode ser devido a falhas na pista externa (f_{ext}), na pista interna (f_{int}) ou nas esferas internas (f_{esf}), é calculada por (11), (12) e (13) (BLÖDT *et al.*, 2008):

Falhas na pista externa:

$$f_{ext} = \frac{N_e}{2} f_r \left(1 - \frac{D_e}{D_c} \cos \beta_{ct}\right). \quad (11)$$

Falhas na pista interna:

$$f_{int} = \frac{N_e}{2} f_r \left(1 + \frac{D_e}{D_c} \cos \beta_{ct}\right). \quad (12)$$

Falhas nas esferas:

$$f_{esf} = \frac{D_c}{D_e} f_r \left(1 - \frac{D_e^2}{D_c^2} \cos^2 \beta_{ct}\right). \quad (13)$$

em que D_c é a distância entre os centros de duas esferas, D_e , o diâmetro das esferas, N_e , o número de esferas internas, β_{ct} , o ângulo de contato entre a esfera e a carcaça e f_r , a frequência de rotação.

Analisando a perturbação em si, o aparecimento de uma fissura, ranhura ou furo em alguma parte do rolamento ocasiona um desalinhamento da rotação deste componente, o qual, por estar acoplado ao eixo do rotor, afeta o giro deste por consequência. Os efeitos que provêm dessa causalidade são as variações do comprimento do entreferro g .

Dessa forma, g será uma função do tempo t e da posição angular θ_f da falha no referencial do estator. As variações no entreferro podem ser descritas matematicamente como em (14) (BLÖDT *et al.*, 2008):

$$g_c(\theta_f, t) = g_0 \left[1 - e_r \cdot \cos(\theta_f + \psi(t)) \sum_{j=-\infty}^{j=+\infty} \delta\left(t - \frac{j}{f_c}\right) \right], \quad (14)$$

em que g_c representa o novo comprimento do entreferro, g_0 , o comprimento do entreferro na situação sem falhas; e_r é o grau de excentricidade relativa ao comprimento do entreferro e j é um número inteiro. $\psi(t)$ é definido como:

- 0, para defeito de pista externa;
- $w_r t$ para defeito de pista interna; e
- $w_{cr} t$ para defeito de esferas.

Sendo que w_r é a frequência do rotor e w_{cr} é a frequência rotacional da carcaça do rolamento, dada por (15) (BLÖDT *et al.*, 2008):

$$w_{cr} = \frac{1}{2} w_r \left(1 - \frac{D_e}{D_c} \cos \beta_{ct} \right). \quad (15)$$

Além disso, a variação do comprimento do entreferro g_c influencia a variação da permeância φ , uma vez que são inversamente proporcionais entre si de acordo com (16). A permeância, por sua vez, está relacionada à indutância da máquina.

$$\varphi_c(\theta_f, t) = \frac{\varphi_0}{\left[1 - e_r \cdot \cos(\theta_f + \psi(t)) \sum_{j=-\infty}^{j=+\infty} \delta\left(t - \frac{j}{f_c}\right) \right]}, \quad (16)$$

onde φ_c é o novo valor da permeância e φ_0 a permeância na situação normal. Outra análise que deve ser feita a partir da variação da permeância é a variação da densidade de fluxo, a qual influenciará na corrente do estator da máquina.

Ainda de acordo com Blödt *et al.* (2008), as frequências características das falhas estão relacionadas com a frequência síncrona f_s no espectro da corrente do estator conforme o exposto no Quadro 1:

Quadro 1 – Frequências no espectro do estator devido a falhas de rolamento.

Localização da falha	Frequências no espectro do estator [Hz]
Na pista externa	$f_s \pm j \cdot f_{ext}$
Na pista interna	$f_s \pm j \cdot f_{int}; f_s \pm f_r \pm j \cdot f_{int}$
Nas esferas	$f_s \pm j \cdot f_{esf}; f_s \pm f_{cr} \pm j \cdot f_{esf}$

Fonte: Blödt *et al.* (2008).

Neste trabalho, com a intenção de modelar as falhas de rolamento nas pistas externa e interna e nas esferas, a variação da indutância seguirá o mesmo raciocínio da permeância descrita neste capítulo, com picos de impulsos na frequência característica da falha a ser analisada.

A indutância de um enrolamento em um circuito magnético é proporcional ao quadrado das espiras N_{esp} e inversamente proporcional à relutância \mathfrak{R} do circuito magnético associado a esse rolamento, conforme o exposto em (17) (FITZGERALD; KINGSLEY, 2003):

$$L = \frac{N_{esp}^2}{\mathfrak{R}}. \quad (17)$$

Por sua vez, a relutância é inversamente proporcional à permeância, que é proporcional ao inverso do comprimento do entreferro g_c . Portanto, a variação de g_c influenciará a indutância da máquina. Logo, pode-se assumir o estabelecido em (18):

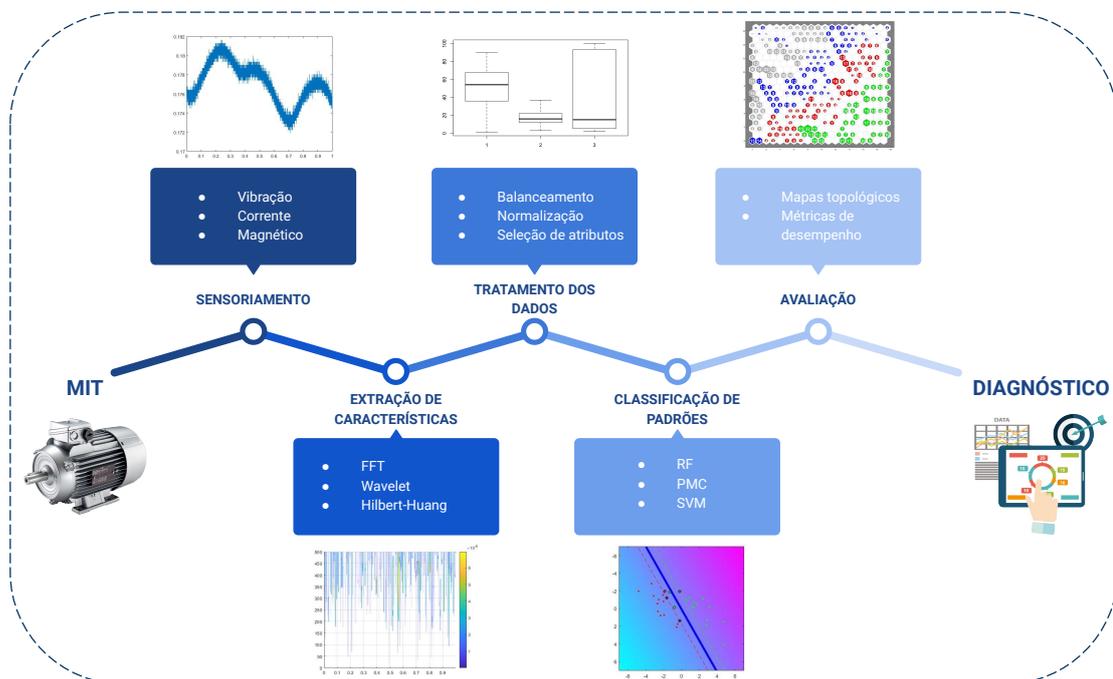
$$L_c(\theta_f, t) = \frac{L_0}{1 - e_r \cdot \cos(\theta_f + \psi(t)) \sum_{j=-\infty}^{j=+\infty} \delta(t - \frac{j}{f_c})}. \quad (18)$$

No próximo capítulo, é feita uma breve revisão do estado da arte das estratégias existentes atualmente para o diagnóstico de falhas de rolamento no MIT, a fim de que o presente estudo siga as metodologias mais adequadas para esse tipo de detecção de falhas.

3 ESTRATÉGIAS PARA DIAGNÓSTICO DE FALHAS E MONITORAMENTO DO MOTOR DE INDUÇÃO TRIFÁSICO

O diagnóstico de falhas no MIT é constituído de cinco etapas principais, as quais são o sensoriamento, a extração de características, o tratamento dos dados, a classificação de padrões e avaliação dos resultados, que contemplam diversas técnicas para a sua realização, conforme exposto na Figura 4.

Figura 4 – Diagrama das principais áreas contempladas no diagnóstico de falhas do MIT.



Fonte: autoria própria (2023).

Neste capítulo, são apresentadas algumas das metodologias empregadas em cada fase da detecção de falhas de rolamento de forma a respaldar as estratégias tomadas neste trabalho.

3.1 SENSORIAMENTO

O monitoramento das condições do MIT tornou-se um artifício eficiente para a detecção precoce das falhas e, para ser realizado, são necessários o sensoriamento e a inspeção de grandezas da máquina que identifiquem padrões fora da operação normal.

Após anos de investigação e estudo, encontraram-se diversas abordagens para

a detecção de defeitos nos rolamentos do MIT, verificando grandezas como temperatura, ruído acústico, fluxo magnético, velocidade, vibração e corrente.

Santos *et al.* (2021) obtém resultados satisfatórios ao extrair informações de sinais acústicos de motores com e sem falhas de rolamento, após submetê-las aos classificadores de padrões PMC e SVM; no entanto, esses sinais têm a desvantagem de serem bastantes sensíveis a ruídos externos, o que pode ocasionar erros na sua leitura, conforme explicita Marmouch, Aroui e Koubaa (2021).

Outra forma de avaliar a presença de falha é proposta por Choudhary, Mian e Fatima (2021), cujo trabalho se baseia na análise de imagens térmicas coletadas em seis condições de operação do rolamento. Para realizar o diagnóstico, os dados são submetidos a uma rede neural artificial (RNA) e a uma rede neural convolucional (CNN - do inglês, *Convolutional Neural Network*), justificando que a metodologia resulta em classificação com grande acurácia e eficiência. No entanto, não são discutidos o custo computacional e o custo com os equipamentos envolvidos.

Frosini, Harlisca e Szabó (2015) trabalha com o espectro do fluxo disperso para identificação de variações em algumas harmônicas, as quais são amplificadas na presença de defeitos no rolamento do MIT. Para isso, emprega sensores customizados flexíveis, de baixo custo e aplicáveis a uma grande faixa de potências, acoplados de forma não invasiva em três regiões da máquina. Todavia, esses sensores ainda não estão consolidados no mercado, apesar de serem estudados há aproximadamente 20 anos, uma vez que os sensores abrangidos pela literatura enfrentam dificuldades quanto à melhor localização e ao alcance de diversos motores (FROSINI; HARLISCA; SZABÓ, 2015).

A identificação de falhas por meio da vibração (HELMI; FOROUZANTABAR, 2019; ALI *et al.*, 2019; YUAN *et al.*, 2020) ou sinais de corrente (CAVERO *et al.*, 2017; BESSOUS *et al.*, 2018; TOMA; PROSVIRIN; KIM, 2020; AVIÑA-CORRAL *et al.*, 2021; MARMOUCH; AROUI; KOUBAA, 2021) tem sido empregada de forma mais frequente em relação aos outros métodos em virtude dos custos dos sensores, flexibilidade de instalação, abrangência das máquinas a serem investigadas e provimento de resultados confiáveis.

Embora a técnica MCSA seja geralmente utilizada para diagnosticar defeitos de origem elétrica no MIT, esta também é adequada para defeitos de origem mecânica, como as falhas nos rolamentos (GANGSAR; TIWARI, 2020). Ademais, o intenso uso de

conversores eletrônicos atrelados ao MIT, como inversores de frequência, conduz ao uso de sinais eletromagnéticos quando possível, uma vez que, ao já possuir transdutores nos sistemas dos acionamentos eletrônicos em questão, evita a inserção de sensores adicionais (FROSINI, 2020).

Apesar de possuir desvantagens, como especificidade dos sensores de corrente para cada tipo e potência de motor, diversos trabalhos optaram pela abordagem MCSA. O estudo em Marmouch, Aroui e Koubaa (2021) traz resultados satisfatórios ao utilizar características extraídas do espectro de frequência da assinatura de corrente do estator. Após aplicar o método de seleção de características e redução de dimensão, a Análise de Componentes de Principais (PCA - do inglês, *Principal Component Analysis*), as amostras provenientes de motores normais, com barras quebradas no rotor e com falhas de rolamento, são submetidas aos classificadores de padrões Função de Base Radial (RBF - do inglês, *Radial Basis Function*) e Rede Neural Probabilística (PNN - do inglês, *Probabilistic Neural Network*).

Por sua vez, Aviña-Corral *et al.* (2021) realiza o diagnóstico de três falhas de rolamento - na pista externa, nas esferas e por corrosão, por meio de testes de qualidade de ajuste das distribuições probabilísticas, como a função de distribuição cumulativa (CDF - do inglês, *Cumulative Distribution Function*), das amostras de corrente. Utilizando o teste Kolmogorov-Smirnov, teste Kuiper e teste Qui-Quadrado de Pearson, obtém 97,10% de acurácia nos resultados.

Em vista dos pontos elencados, este trabalho considera a MCSA como técnica para sensoriamento dos motores com falha de rolamento, uma vez que já é estabelecida na literatura e pelo fato de a modelagem matemática a ser estudada proporcionar a análise dessa grandeza da máquina.

Na próxima seção, são apresentadas as principais técnicas de extração de características dos sinais de corrente, priorizando aquelas utilizadas neste estudo.

3.2 EXTRAÇÃO DE CARACTERÍSTICAS

Os dados de corrente são ricos em informações que podem ser exploradas para identificação de comportamentos da máquina sob diversas condições. Uma vez que as frequências características das perturbações geradas pelas falhas de rolamento afetam a corrente do estator (BLÖDT *et al.*, 2008), a FFT, por meio da análise do espectro

de frequências da corrente, permite a detecção das falhas de rolamento em muitos trabalhos, sendo uma técnica muito difundida. Marmouch, Aroui e Koubaa (2021) usa a FFT para extrair determinadas assinaturas de frequência de falhas de rolamento e de rotor e assim aplicar técnicas de redução de dimensionalidade. Atributos estatísticos no domínio da frequência de sinais de corrente são extraídos do espectro gerado pela FFT em Husna, Indriawati e Widjiantoro (2021) para classificação de falhas, juntamente com características estatísticas no domínio do tempo.

No entanto, devido às limitações de resolução e estacionaridade da FFT, esta técnica pode não ser tão abrangente a diversas situações de variações de carga e velocidade (GANGSAR; TIWARI, 2020). Assim, métodos que trabalham no domínio do tempo-frequência, como Transformadas de Wavelet, de Fourier de curta duração (STFT - do inglês, *Short-Time Fourier Transform*) e de Hilbert-Huang ganharam espaço e interesse dos pesquisadores da área.

O estudo realizado por Ali *et al.* (2019) propõe o diagnóstico de múltiplas falhas, incluindo a de rolamentos, por meio dos sinais de vibração e corrente, através da extração de suas características por meio de busca de correspondência e Transformada Discreta de Wavelet (DWT - do inglês, *Discret Wavelet Transform*). Bessous *et al.* (2018) também utiliza a técnica de DWT em sinais de corrente para identificação de falhas nas pistas externa e interna de rolamentos, obtendo taxas altas de acurácia. Já Cavero *et al.* (2017) investiga qual a ferramenta mais adequada dentre as que trabalham no domínio tempo-frequência para detecção de falhas no MIT, comparando a FFT, a STFT, Transformada de Wigner-Ville, Transformada de Hilbert-Huang, entre outras; no entanto, chega a conclusão de que não há uma técnica única e eficiente para diagnóstico de múltiplas falhas dentre as estudadas.

Neste trabalho, com o intuito de realizar apenas a transformação com a técnica mais difundida, é realizada a extração de características estatísticas no domínio do tempo e da frequência de forma separada, as quais são apresentadas na Tabela 1. Os atributos no domínio do tempo são: média (A_1), desvio padrão (A_2), quadrado das raízes (A_3), raiz quadrada média (A_4), valor de pico (A_5), fator de assimetria (A_6), kurtosis (A_7), fator de crista (A_8), fator de compensação (A_9), fator de forma (A_{10}) e fator de impulso (A_{11}). No domínio da frequência, são: potência espectral média (A_{12}), variância da potência espectral (A_{13}), fator de assimetria e kurtosis da potência espectral (A_{14} e A_{15}), frequência central (A_{16}), desvio padrão da frequência (A_{17}), raiz quadrada média

da frequência (A_{18}), frequência média que cruza a média do sinal no domínio do tempo (A_{19}), fator de estabilização (A_{20}), coeficiente de variabilidade (A_{21}), fator de assimetria e kurtosis da frequência (A_{22} e A_{23}). Na Tabela 1, $x(n)$ é o sinal de corrente no tempo, sendo $n = 1, 2, \dots, N$ o número de pontos, $s(k)$ é o espectro de frequências, $k = 1, 2, \dots, K$ sendo o número de pontos e f_k é a frequência k do espectro.

Tabela 1 – Cálculo dos atributos.

Atributos no domínio do tempo	Atributos no domínio da frequência
$A_1 = \frac{\sum_{n=1}^N x(n)}{N}$	$A_{12} = \frac{\sum_{k=1}^K s(k)}{K}$
$A_2 = \sqrt{\frac{\sum_{n=1}^N (x(n) - A_1)^2}{N-1}}$	$A_{13} = \frac{\sum_{k=1}^K (s(k) - A_{12})^2}{K-1}$
$A_3 = \left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N} \right)^2$	$A_{14} = \frac{\sum_{k=1}^K (s(k) - A_{12})^3}{K(\sqrt{A_{13}})^3}$
$A_4 = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$	$A_{15} = \frac{\sum_{k=1}^K (s(k) - A_{12})^4}{K A_{13}^2}$
$A_5 = \max x(n) $	$A_{16} = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$
$A_6 = \frac{\sum_{n=1}^N (x(n) - A_1)^3}{(N-1)A_2^3}$	$A_{17} = \sqrt{\frac{\sum_{k=1}^K (f_k - A_{16})^2 s(k)}{K}}$
$A_7 = \frac{\sum_{n=1}^N (x(n) - A_1)^4}{(N-1)A_2^4}$	$A_{18} = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}}$
$A_8 = \frac{A_5}{A_4}$	$A_{19} = \sqrt{\frac{\sum_{k=1}^K f_k^3 s(k)}{\sum_{k=1}^K f_k^2 s(k)}}$
$A_9 = \frac{A_5}{A_3}$	$A_{20} = \frac{\sum_{k=1}^K f_k^2 s(k)}{\sqrt{\sum_{k=1}^K s(k) \sum_{k=1}^K f_k^4 s(k)}}$
$A_{10} = \frac{A_4}{\frac{1}{N} \sum_{n=1}^N x(n) }$	$A_{21} = \frac{A_{17}}{A_{16}}$
$A_{11} = \frac{A_5}{\frac{1}{N} \sum_{n=1}^N x(n) }$	$A_{22} = \frac{\sum_{k=1}^K (f_k - A_{16})^3 s(k)}{K A_{17}^3}$
	$A_{23} = \frac{\sum_{k=1}^K (f_k - A_{16})^4 s(k)}{K A_{17}^4}$

Fonte: adaptado de Haroun, Seghir e Touati (2018).

A etapa de extração de características do sinal fornece uma faixa de atributos que representam o sinal de forma reduzida em relação ao sinal original. Isso viabiliza um processo de aprendizado dos algoritmos de menor complexidade e tempo.

3.3 TRATAMENTO DAS AMOSTRAS

O desempenho de um algoritmo de aprendizado pode ser aprimorado caso os seus dados sejam previamente processados, evitando ruídos, amostras com valores inconsistentes ou inexistentes, atributos irrelevantes e classes desbalanceadas. Assim, há técnicas de pré-processamento que melhoram a qualidade dos dados, de forma a contribuir na implementação de modelos mais confiáveis e com menor custo computacional.

Esses procedimentos podem envolver a limpeza, amostragem, balanceamento,

transformação dos dados e redução de dimensionalidade. A seguir, serão descritos as estratégias de tratamento de dados utilizados neste estudo.

3.3.1 Normalização

Quando os limites inferiores e superiores dos atributos de um conjunto de dados são muito diferentes entre si, é conveniente fazer uma transformação para uma mesma escala, pois uma determinada característica pode predominar na hora do aprendizado, prejudicando a contribuição das outras. Essa transformação é a normalização, a qual pode modificar a amplitude dos valores por meio de reescala ou padronização (FACELI *et al.*, 2011).

A normalização por reescala tem por objetivo enquadrar os dados em um mesmo intervalo, como $[0,1]$, em que zero será o novo valor mínimo (z_{min}) e um, o novo valor máximo (z_{max}), podendo ser calculada por (19):

$$x_n = z_{min} + \frac{x - x_{min}}{x_{max} - x_{min}}(z_{max} - z_{min}), \quad (19)$$

em que x_n é a amostra normalizada, x_{max} e x_{min} são os valores máximos e mínimos do banco de dados original.

Já a normalização por padronização não estabelece a mesma escala para todos os atributos, mas sim uma nova distribuição em que todos terão média zero e desvio padrão um. Também conhecida como *Z-score*, é dada por (20):

$$x_n = \frac{x - \bar{x}}{\sigma}, \quad (20)$$

em que \bar{x} é a média das amostras de determinado atributo e σ é o desvio padrão.

O primeiro tipo de normalização mencionado resulta em características que estarão exatamente na mesma escala, porém não é muito indicada para situações onde há *outliers*. Assim, normalmente, é empregada a técnica *Z-score*, a qual lida bem com esses casos.

3.3.2 Balanceamento

Conjuntos de dados com diferentes quantidades de amostras para cada classe é recorrente de acontecer. No entanto, essa distribuição pode resultar em modelos preditivos tendenciosos à classe que possui maior quantidade de elementos. Espera-se que classificadores consigam generalizar diante de elementos de qualquer categoria com a mesma acurácia. Contudo, na situação de classes desbalanceadas, haverá mais dados com um determinado rótulo do que com outro no treinamento, resultando em taxas de erro de classificação maiores para aquele que possui menos amostras (KOTSIANTIS; PINTELAS, 2003).

Caso possível, gerar novas amostras para a classe que possui menos elementos é o ideal para o balanceamento, mas, na maioria das vezes, isso não é possível. Então, recorre-se ao balanceamento artificial dos dados que pode ocorrer pela redefinição do tamanho do conjunto de dados, utilização de diferentes custos ou penalizações para as diversas classes ou induzir um modelo para cada categoria (FACELI *et al.*, 2011). Duas técnicas bastante difundidas envolvem a reamostragem dos dados, sendo elas *undersampling* e *oversampling*. A primeira realiza o balanceamento através da eliminação de elementos e a segunda, simula ou incrementa amostras adicionais ao conjunto (KULKARNI; CHONG; BATARSEH, 2020).

Também chamado de *down-sizing*, há diversos métodos na literatura para realizar *undersampling*, como *Random Undersampling*, Tomek Links e *Edited Nearest Neighbors* (ENN). O *Random Undersampling* é a ferramenta não-heurística para *undersampling* e se baseia na eliminação de amostras aleatórias da classe com maioria (KULKARNI; CHONG; BATARSEH, 2020).

3.3.3 Validação Cruzada com k-partições

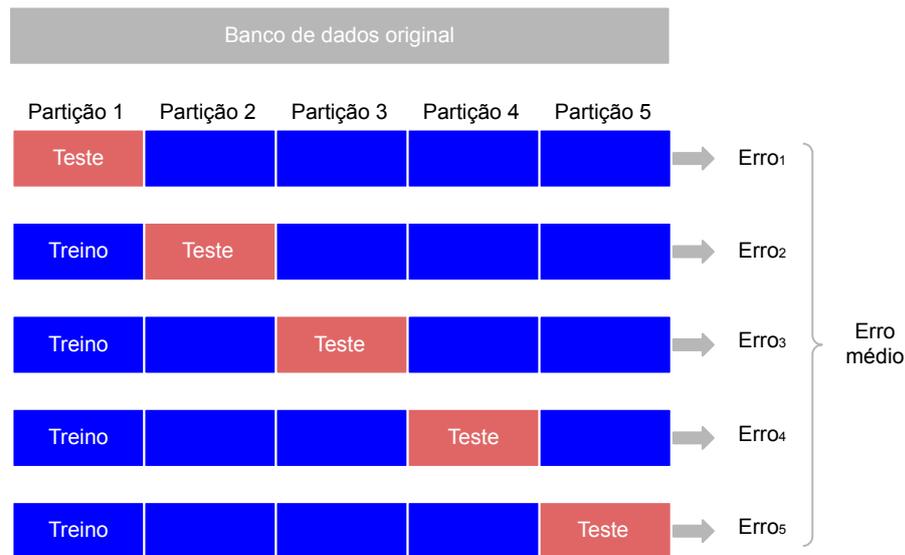
O processo de aprendizado consiste em identificar os parâmetros que consigam representar o problema com maior acurácia possível, criando o modelo preditivo.

No entanto, treinar e testar o algoritmo com o mesmo conjunto de dados pode levar à situação de *overfitting*, em que a rede memoriza as respostas frente aos dados de entrada, o que ocasiona a não generalização da rede (SILVA *et al.*, 2017). Assim, terá baixas taxas de erro quadrático médio no período de treinamento e altas taxas desse

erro em testes com amostras diferentes daquelas que foram utilizadas para treinar.

Um método para contornar esse problema é a validação cruzada (CV - do inglês, *cross-validation*) com k-partições (do inglês, *k-fold cross-validation*), que consiste em dividir o conjunto total de amostras em k partes, em que k-1 partições serão usadas como um subconjunto para treinamento e o restante será utilizado para teste, como exemplificado na Figura 5.

Figura 5 – Esquemático da validação cruzada com 5 partições.



Fonte: autoria própria (2023).

O processo de aprendizado se repete k vezes até que todas as partições tenham sido usadas como subconjunto de teste e o erro de teste geral do modelo é a média dos erros nos k testes realizados (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

3.3.4 Seleção dos atributos

A seleção de atributos consiste em um conjunto de técnicas que seleciona os atributos mais relevantes de um conjunto de dados. A redução dessas variáveis contribui para a eficiência do algoritmo de aprendizado de máquina, uma vez que ocupa menos espaço, diminui a complexidade da análise e contribui para melhor generalização do problema. Além disso, atributos de baixa relevância podem confundir o aprendizado, acarretando uma baixa performance. Há diversas técnicas para se realizar a escolha dos atributos que traga maior performance ao algoritmo. Elas podem ser do tipo embutida, baseada em filtro ou em *wrapper*.

O procedimento do tipo embutido é aquele que o próprio algoritmo de aprendizado de máquina já realiza em seu código para seleção de subgrupos de atributos, como as árvores de decisão (FACELI *et al.*, 2011). As técnicas baseadas em filtro realizam a seleção numa etapa anterior ao aprendizado, observando relações entre as variáveis e as saídas de forma individual. Já os métodos do tipo *wrapper* utilizam diversos algoritmos de aprendizado de máquina que retornam a relevância dos atributos para encontrar a combinação ótima desses, adicionando ou eliminando quando necessário (KUHN; JOHNSON, 2013).

Embora o custo computacional e o tempo de implementação da seleção *wrapper* seja maior comparada às outras, ela foi utilizada nesse trabalho com o intuito de encontrar com efetividade os atributos que melhor representassem o conjunto de dados e, conseqüentemente, contribuir para a performance dos classificadores. Os algoritmos utilizados para essa proposta foram o *Least Absolute Shrinkage and Selection Operator* com validação cruzada (LASSO-CV), a Eliminação Recursiva de Atributos (RFE - do inglês, *Recursive Feature Elimination*) com Floresta Aleatória e *Gradient Boosting* (GB), os quais serão descritos a seguir.

3.3.4.1 LASSO-CV

Com o intuito de criar um modelo que represente situações reais, a regressão linear se apresenta como a estimação da saída \hat{y} a partir de uma combinação linear entre determinados parâmetros B com a entrada $x^T = (x_1, x_2, \dots, x_M)$, que seja mais próximo do valor esperado y , conforme (21) (HASTIE; TIBSHIRANI; FRIEDMAN, 2009):

$$\hat{y}(x) = B_0 + \sum_{j=1}^M x_j B_j. \quad (21)$$

Para que a diferença entre o \hat{y} e o y seja a menor possível, busca-se a solução ótima que minimize a soma residual dos quadrados (RSS - do inglês, *Residual Sum of Squares*) para N amostras, previsto em (22):

$$RSS(B) = \sum_{i=1}^N (y_i - \hat{y}_i)^2. \quad (22)$$

Assim, são estimados os parâmetros. No entanto, objetivando-se “encolher” os parâmetros encontrados, uma vez que possivelmente resultará em menos erros de predi-

ção, adiciona-se penalizações à função custo, conhecidos como os métodos Regressão *Ridge* e Regressão *Least Absolute Shrinkage and Selection Operator* (LASSO).

Diferenciando-se da primeira por meio da adoção de norma um para adição da penalização, a Regressão LASSO caracteriza-se por selecionar os atributos que melhor representem a entrada, como o exposto em (23), uma vez que a sua restrição gera alguns parâmetros iguais a zero:

$$B^{lasso} = \min_B \frac{1}{2} \sum_{i=1}^N (y_i - B_0 - \sum_{j=1}^M x_{ij} B_j)^2 + \tau \sum_{j=1}^M |B_j|, \quad (23)$$

onde τ é um parâmetro que controla o nível de encolhimento da regressão. Para encontrar seu valor ótimo, a validação cruzada (CV - do inglês, *cross-validation*) é realizada.

3.3.4.2 Eliminação Recursiva de Atributos

A Eliminação Recursiva de Atributos (RFE – do inglês, *Recursive Feature Elimination*) é um algoritmo bastante utilizado para seleção de atributos. Guyon, Weston e Barnhill (2002) propõem essa técnica para evitar o ajuste dos modelos preditivos a cada busca. É possível configurar dois hiperparâmetros: o número desejado de atributos e o algoritmo para listar a importância dos atributos. Esse último pode ser algum baseado nos critérios de Árvores de Decisão, como Floresta Aleatória e *Gradient Boosting*, os quais serão descritos nas próximas seções.

Inicialmente, o modelo é criado utilizando todos os atributos e uma medida da importância de cada uma é computada da mais importante para a menos importante. Em seguida, diversos modelos preditivos são novamente treinados, porém com a eliminação dos atributos com menor importância, calculando a sua performance, até se atingir o número desejado de variáveis (KUHN; JOHNSON, 2013).

3.3.4.3 Árvore de Decisão

A árvore de decisão (DT - do inglês, *Decision Trees*) é um método de aprendizado de máquina para tomadas de decisão em problemas de classificação ou regressão por meio da estratégia dividir para conquistar (FACELI *et al.*, 2011). Com uma estrutura

ramificada semelhante a uma árvore, utiliza a divisão em subgrupos para encontrar uma solução simples a uma questão complexa. Entre os algoritmos que se baseiam nas árvores de decisão, encontram-se *Inductive Decision Tree* - ID3 (QUINLAN, 1979), *Classification and Regression Trees* - CART (BREIMAN *et al.*, 1984) e C4.5 (QUINLAN, 1993).

Embora sua simplicidade garanta uma fácil visualização e compreensão para o ser humano, esse método não-paramétrico é sensível a mudanças no conjunto de treinamento, levando a erros de interpretação. Além disso, o seu ajuste excessivo pode acarretar o *overfitting*, sendo evitado mediante a adoção de critérios de parada na criação do modelo de treinamento.

Uma árvore de decisão é constituída por nós internos, que representam um atributo, ramos, os quais indicam uma regra de decisão, e as folhas, com o resultado da classificação (classe). O primeiro nó estabelecido da árvore é o nó raiz. Existem diversos métodos que definem a divisão para classificação, objetivando encontrar o atributo que melhor discrimine as classes. Entre eles, há as regras baseadas no Ganho de Informação, usado no C4.5, e no índice Gini, utilizado no CART.

O Ganho de Informação (*GI*) se fundamenta no conceito de entropia (*S*), responsável por medir a aleatoriedade de uma variável aleatória. Nas árvores de decisão, a aleatoriedade representa a dificuldade de um atributo (a variável aleatória) de predizer a classe (FACELI *et al.*, 2011). Logo, a característica com menor entropia será a escolhida para dividir os dados. Desse modo, o Ganho de Informação mede a redução na entropia nos subgrupos *h* obtidos por cada um dos atributos. A entropia e o Ganho de Informação são dados por (24) e (25) (HASTIE; TIBSHIRANI; FRIEDMAN, 2009):

$$S = - \sum_{i=1}^R p_i \log_2 p_i, \quad (24)$$

$$GI = S_0 - \sum_{i=1}^h \frac{N_i}{N} S_i, \quad (25)$$

em que *R* representa o número de classes do conjunto de dados, *p_i*, a probabilidade da classe *i*, *N*, o número total de dados e *N_i*, o número de dados contidos no subgrupo obtido após a divisão.

Outra maneira de identificar o atributo para divisão do nó é pelo índice Gini. A função Gini indica o grau de impureza de um nó. A impureza é uma função sobre a

proporção das classes em um determinado nó. O valor mínimo de impureza significa que há somente dados de uma mesma classe. Assim, o índice Gini I_g de cada classe é calculado por (HASTIE; TIBSHIRANI; FRIEDMAN, 2009; FACELI *et al.*, 2011):

$$I_g(t) = 1 - \sum_{i=1}^h p_i^2. \quad (26)$$

O atributo que apresentar a maior redução da impureza é o selecionado.

3.3.4.4 Gradient Boosting

O *Gradient Boosting* (GB) é um algoritmo de aprendizado de máquina pertencente aos métodos de comitê de classificadores (*ensemble methods*), com aplicações tanto para problemas de regressão quanto de classificação. Utiliza uma coleção de modelos preditivos considerados fracos (com uma taxa de erro alta), como as árvores de decisão, para encontrar um modelo geral com maior acurácia (JAMES *et al.*, 2013).

A sua diferença em relação a outras técnicas se encontra no ajuste das árvores de decisão de forma sequencial, ou seja, a entrada de uma árvore depende da saída da anterior. Logo, seu treinamento é gradual e mais lento, porém garantindo maior acurácia.

Neste método, a base de dados para treinamento da árvore a é composta pelos resíduos obtidos nas folhas da árvore anterior. Com o intuito de alcançar o resíduo mínimo r_{na} de cada amostra n , este é calculado pela minimização da função custo L , que é o erro quadrático médio (MSE - do inglês, *Mean Square Error*), para situações de regressão, e máxima verossimilhança, para classificação, entre as saídas observada y e prevista \hat{y} , como descrito em (27) (HASTIE; TIBSHIRANI; FRIEDMAN, 2009):

$$r_{na} = - \left[\frac{\partial L(y_n, \hat{y}_n)}{\partial \hat{y}_n} \right]_{\hat{y}=\hat{y}_{a-1}}. \quad (27)$$

Após ajustar a árvore de acordo com esses resíduos, a saída de cada folha γ_{ja} , será dada por (28):

$$\gamma_{ja} = \min_{\gamma} \sum_{x_n \in R_{ja}} L(y_n, \hat{y}_{a-1}(x_n) + \gamma). \quad (28)$$

Assim, uma nova predição será feita a partir dessa última árvore encontrada,

com J_a folhas, por meio de:

$$\hat{y}_a(x) = \hat{y}_{a-1}(x) + \sum_{j=1}^{J_a} \gamma_{ja} I(x \in R_{ja}). \quad (29)$$

3.4 CLASSIFICADORES DE PADRÕES

Com o avanço do aprendizado de máquina, diversas técnicas para identificar o tipo de falha ou condições dos motores se tornaram disponíveis para potencializar o monitoramento e diagnóstico de falhas de rolamento no MIT.

Entre os classificadores mais utilizados na literatura, encontram-se o SVM (ALI *et al.*, 2019; GUEDES, 2019), kNN (ALI *et al.*, 2019; TOMA; PROSVIRIN; KIM, 2020), RF (TOMA; PROSVIRIN; KIM, 2020) e PMC (GODOY, 2016; PALÁCIOS, 2016; GUEDES, 2019; BAZAN, 2020). Embora não empregados frequentemente para classificação, os mapas auto-organizáveis de Kohonen realizam a clusterização dos dados de forma não supervisionada, por meio da identificação de padrões entre as observações, como verificado nos trabalhos de Jialing Zhang *et al.* (2020) e Santos *et al.* (2021).

Em vista desses pontos, este estudo utiliza o RF, o kNN, a PMC, o SVM e a rede de Kohonen para validar a proposta de modelagem das falhas de rolamento. Assim, uma análise mais aprofundada acerca desses classificadores é dada a seguir.

3.4.1 Floresta Aleatória

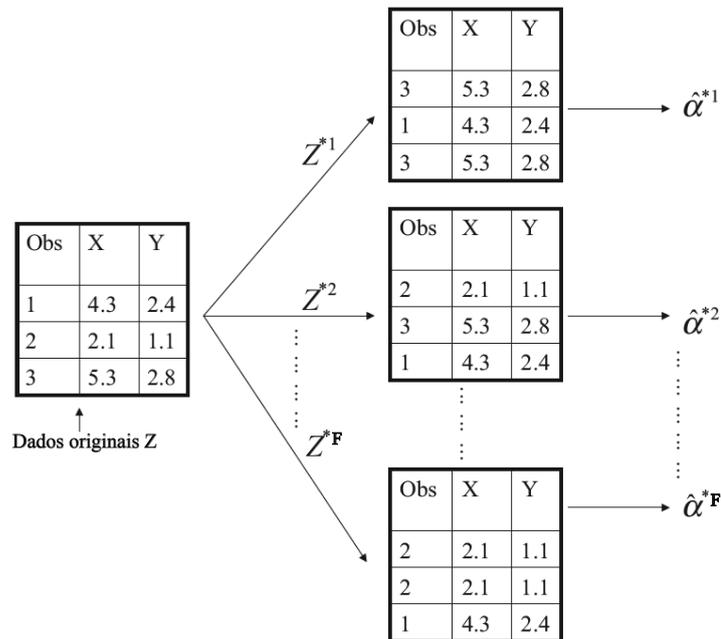
Assim como o *Gradient Boosting*, a Floresta Aleatória (RF - do inglês, *Random Forest*) é um algoritmo de predição do tipo *ensemble methods*. Logo, a RF se baseia na associação de diversas DTs treinadas com subgrupos aleatórios do conjunto total de dados de treinamento de forma a encontrar uma solução com maior acurácia quando comparada às saídas individuais das árvores.

O seu funcionamento é embasado em técnicas de reamostragem dos dados (*bootstrap*) e redução da variância de um algoritmo de aprendizado (*bagging*), além das DTs, os quais serão descritos a seguir.

3.4.1.1 Bootstrap

O *bootstrap* é uma ferramenta estatística utilizada para determinar o desempenho de um algoritmo de aprendizado, quantificando a sua incerteza. Por meio de reamostragem, essa técnica consegue estimar o erro padrão ou a acurácia de um modelo preditor. Uma vez que a reprodução do conjunto de treinamento com outras amostras reais é um procedimento complexo de se realizar, o bootstrap cria F subgrupos da base de dados amostrando-o e replicando algumas instâncias de forma a garantir o mesmo número de amostras do conjunto original. A Figura 6 ilustra o mecanismo do *bootstrap*.

Figura 6 – Exemplo do funcionamento do *bootstrap* com um conjunto de três dados.



Fonte: adaptado de James *et al.* (2013).

Por meio da análise individual de determinado aspecto estatístico de cada modelo com seu subgrupo Z^* , é possível estimar tal aspecto para o grupo original Z . Sendo $Q(Z)$ a saída para determinada entrada, calcula-se a sua variância σ^2 por (30) (HASTIE; TIBSHIRANI; FRIEDMAN, 2009):

$$\sigma^2[Q(\mathbf{Z})] = \frac{1}{F-1} \sum_{i=1}^F (Q(\mathbf{Z}^{*i}) - \overline{Q^*})^2, \quad (30)$$

onde:

$$\overline{Q^*} = \frac{\sum_i Q(\mathbf{Z}^{*i})}{F}. \quad (31)$$

3.4.1.2 *Bagging*

O *bootstrap*, aliado à técnica de *bagging*, pode aprimorar um modelo preditivo, visto que calcular a média das saídas de um conjunto de observações reduz sua variância (JAMES *et al.*, 2013). O método *bagging*, também chamado de *bootstrap aggregation*, consiste em utilizar diversos subgrupos da população a fim de treinar modelos de aprendizado individuais e obter a saída geral f_{bag} por meio da média dos resultados individuais f^{*i} .

Assim, por meio da reamostragem obtida por *bootstrap*, o modelo preditivo com maior acurácia é calculado por (32) (JAMES *et al.*, 2013):

$$f_{bag}(x) = \frac{1}{F} \sum_{i=1}^F f^{*i}(x). \quad (32)$$

Para situações de classificação, a média das saídas é substituída pela maioria dos votos, ou seja, o resultado será o rótulo com mais ocorrências individuais.

3.4.1.3 Funcionamento da Floresta Aleatória

O aperfeiçoamento do método *bagging*, realizado descorrelacionando as árvores de decisão, é chamado de Floresta Aleatória. Para isso, na ramificação do nó de cada árvore, uma amostra aleatória de M' atributos é selecionada para ser candidata a variável do nó em questão.

Realizando *bagging*, todas as variáveis m de uma instância são levadas em consideração e, caso haja um atributo com grande relevância e os demais, com relevância moderada, haverá uma tendência em todas as árvores de utilizar o mesmo atributo na divisão dos nós, o que resultará em árvores com estruturas semelhantes ou correlacionadas. Adotando amostras M' de variáveis, nem sempre aquela de maior relevância estará presente, permitindo que as outras sejam usadas para critério de divisão, criando árvores descorrelacionadas entre si.

A variância da média de um conjunto F de variáveis aleatórias i.i.d. (independentes e identicamente distribuídas), com variância σ^2 cada uma, é dada por (33) (HASTIE; TIBSHIRANI; FRIEDMAN, 2009):

$$\overline{\sigma}^2 = \frac{1}{F}\sigma^2. \quad (33)$$

No entanto, quando são somente i.d. (identicamente distribuídas), com uma correlação positiva par-a-par ρ , a variância da média é a indicada em (34):

$$\overline{\sigma}^2 = \rho\sigma^2 + \frac{1-\rho}{F}\sigma^2. \quad (34)$$

Embora o valor de F ser suficientemente grande para desconsiderar o segundo termo, a variância ainda depende do fator de correlação no primeiro termo, limitando o benefício de se realizar a média.

Assim, a RF é capaz de aprimorar o *bagging* por meio da seleção M' dos atributos. Geralmente, esse parâmetro é a raiz quadrada de M para situações de classificação e um terço de M para problemas de regressão. Quando $M' = M$, a RF é o próprio *bagging* (JAMES *et al.*, 2013).

O modelo preditivo da Floresta Aleatória, para regressões, é dado por (35) (HASTIE; TIBSHIRANI; FRIEDMAN, 2009):

$$f_{rf}^F(x) = \frac{1}{F} \sum_{i=1}^F T_i(x), \quad (35)$$

sendo $T_i(x)$, a saída de cada árvore presente no algoritmo. Para classificação, é considerado $R_i(x)$ como a classe predita para a i -ésima árvore e a saída da RF é retornada como a maioria de votos de $\{R_i(x)\}_1^F$.

3.4.2 k-ésimo Vizinhos Mais Próximos

O algoritmo k-ésimo Vizinhos Mais Próximos (kNN - do inglês, *k-Nearest Neighbors*) é um método de aprendizado de máquina não-paramétrico e supervisionado que se baseia nas distâncias para solucionar problemas de classificação e regressão. Respalda-se na concepção de que dados semelhantes entre si estão relacionados ao mesmo grupo (FACELI *et al.*, 2011).

Sendo um conjunto de dados com m atributos, cada amostra representa um ponto no espaço M -dimensional. Para obter a saída de um determinado objeto de teste, o kNN calcula a distância entre este e cada dado de treinamento. O objeto de

treinamento que resulte no menor valor da distância, ou seja, o vizinho mais próximo, indicará a saída do teste em questão. Caso k (número de vizinhos) seja maior que um, o rótulo ou valor de saída será a moda das classes, para problemas de classificação, ou a estratégia que minimize a função custo, como a média, para situações de regressão (FACELI *et al.*, 2011).

Há diversas formas de calcular a distância no espaço M -dimensional sendo a Euclidiana a mais empregada. Ferrero (2009) apresenta uma forma genérica do cálculo dessa distância (36):

$$dist(E_i, E_j) = \left(\sum_{l=1}^M |x_{il} - x_{jl}|^d \right)^{\frac{1}{d}}, \quad (36)$$

em que E_i e E_j são dois pontos no espaço entre os quais se deseja calcular a distância e d está relacionado ao tipo da distância que se quer calcular.

Uma vez que essa técnica é baseada em memória dos dados de treinamento e não há modelo a ser ajustado, é considerada do tipo *lazy* (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Apesar das vantagens de ser simples e aplicável em problemas complexos, seu custo computacional pode ser relativamente alto caso o conjunto de dados seja muito grande e realizar más interpretações se for alta a dimensionalidade dos dados.

3.4.3 Rede Perceptron Multicamadas

A Rede Perceptron Multicamadas (PMC) é um dos tipos de rede neural artificial utilizada para aproximação de funções, reconhecimento de padrões, previsão de séries temporais, entre outros, e é fundamentada na arquitetura *feedforward* de camadas múltiplas (SILVA *et al.*, 2017). Trabalhos como o de Jawadekar *et al.* (2014) e Navasari, Asfani e Negara (2018) utilizam a PMC para validar o método proposto de diagnóstico de falhas de rolamento.

A PMC baseia-se em duas etapas: na primeira fase, chamada fase *forward*, os dados de entrada são propagados até os neurônios de saída, produzindo sinais de acordo com os pesos e limiares definidos. Assim, a saída \hat{y} de cada neurônio j pode ser calculada por (37), em que $x = \{x_1, x_2, \dots, x_M\}$ é o vetor de N amostras de entrada dos neurônios de determinada camada, M é a dimensão das amostras, w_j é o peso

associado ao neurônio j , b é o limiar e $g(\cdot)$ é a função de ativação do neurônio (SILVA *et al.*, 2017):

$$\hat{y}_j(n) = g \left(\sum_{i=1}^M x_i(n) \cdot w_{ji} + b_j \right). \quad (37)$$

Em seguida, na fase *backward*, um sinal de erro E (resultante da diferença entre a saída desejada y e a gerada \hat{y} é propagado de forma reversa, da saída à entrada, para ajuste dos pesos e limiares de cada neurônio j , conforme (38) (SILVA *et al.*, 2017):

$$E(n) = \frac{1}{2} \sum_{j=1}^W (y_j(n) - \hat{y}_j(n))^2. \quad (38)$$

Esse processo é repetido até que algum critério de parada, como número de épocas de treinamento ou erro mínimo, seja atingido (HAYKIN, 2009).

O uso de PMC para classificação de falhas de rolamento em MIT já foi realizado em alguns trabalhos recentes, mostrando ser eficiente nessa aplicação. Palácios, Godoy *et al.* (2017) compara três classificadores de padrão, dentre eles a PMC, para classificação de múltiplas falhas no MIT, cuja extração de características é baseada nos sinais de tensão e corrente no domínio do tempo, com acurácia acima de 89%. Bazan *et al.* (2020) também explora a PMC como classificador de padrão para diagnóstico de falhas de rolamento no MIT, porém com outra metodologia de extração de características, com informação mútua de duas fases da corrente. Já Li, Mo e Yan (2021) apresenta outra técnica de classificação, baseada em gráfico de visibilidade horizontal, e compara com o classificador convencional que é a PMC.

3.4.4 Máquina de Vetores de Suporte

Assim como a PMC, a Máquina de Vetores de Suporte (SVM - do inglês, *Support Vector Machine*) também objetiva a configuração de hiperplanos para solucionar problemas de classificação. No entanto, difere-se pela otimização das fronteiras de separação, obtendo maior acurácia e capacidade de generalização.

Para um conjunto de N amostras com M atributos distribuídos no espaço M -dimensional, um hiperplano possuirá $M - 1$ dimensões e o hiperplano ótimo será aquele que se encontra mais distante dos dados mais próximos a ele no espaço. Esses elementos mais próximos ao hiperplano que definem a margem ótima são denominados

vetores de suporte (JAMES *et al.*, 2013).

Quando o hiperplano consegue separar todo o conjunto de dados em duas regiões, esses são ditos linearmente separáveis. Todavia, são raras as aplicações onde as amostras são desse tipo. Assim, encontrar um hiperplano separador será uma tarefa muito difícil, então aceita-se que haja algumas violações às fronteiras definidas, por meio da introdução de folga ξ_i , o qual é regularizado por uma constante C que estabelece um peso à minimização dos erros. Logo, a busca pela margem ótima torna-se um problema de otimização a seguir (39) (FACELI *et al.*, 2011):

$$\min_{\mathbf{w} \in \mathbb{R}^M, \xi_i \in \mathbb{R}^+} \|\mathbf{w}\|^2 + C \sum_i^N \xi_i, \quad (39)$$

sujeito a:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, \xi_i \geq 0, \forall i = 1, \dots, n, \quad (40)$$

em que \mathbf{w} representa o vetor de parâmetros do hiperplano. Já y_i indica a saída desejada, \mathbf{x}_i , a amostra e b , o viés da configuração do hiperplano.

Quando ξ_i apresenta valor zero, significa que a amostra encontra-se na região de acordo com seu rótulo; entre zero e um, a instância está fora da margem prevista; e, acima de um, o dado localiza-se na região incorreta. Por tratar-se de um problema de otimização quadrático, recorre-se à introdução de uma função lagrangiana (41):

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1). \quad (41)$$

Em que a sua minimização implica na maximização de α_i e minimização de \mathbf{w} e b , resultando em (42):

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j), \quad (42)$$

$$\text{com as restrições: } \begin{cases} 0 \leq \alpha_i \leq C, \forall i = 1, \dots, n, \\ \sum_{i=1}^n \alpha_i y_i = 0. \end{cases} \quad (43)$$

Essa equação é a representação dual enquanto a equação (39) é a primal. Ambas se diferem pela dimensionalidade em que trabalham, sendo a primeira relacionada ao número de amostras e a segunda, ao número de atributos.

Os hiperplanos calculados por (39) e (42) satisfazem problemas linearmente separáveis ou que possuam alguns ruídos e *outliers*. Para problemas não lineares, é necessário mapear o conjunto de treinamento em um espaço com maior dimensão onde um hiperplano seja capaz de separar as amostras. Assim, ocorre a transformação $\Phi : X \rightarrow \mathfrak{F}$ e (42) torna-se (44):

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\Phi(x_i) \cdot \Phi(x_j)). \quad (44)$$

Como a computação de Φ pode ser custosa, emprega-se as funções kernel, que recebe os pontos x_i e x_j no espaço de entradas e calcula o produto escalar entre eles no espaço transformado, sem conhecer o mapeamento. Os mais utilizados são os polinomiais, os de função base radial (RBF - do inglês, *Radial Basis Function*) e os sigmoidais (FACELI *et al.*, 2011).

3.4.5 Redes Auto-organizáveis de Kohonen

Utilizadas para classificar as falhas de rolamento extraídas dos sinais de vibração dos rolamentos por Jialing Zhang *et al.* (2020), as redes auto-organizáveis de Kohonen é outro tipo de rede neural artificial muito utilizada para classificação de padrões e clusterização. Diferentemente da PMC, a rede de Kohonen se auto-organiza por meio de métodos de treinamento competitivos, os quais têm capacidade de detectar similaridades entre os dados de entrada, agrupando-os em classes (*clusters*) (SILVA *et al.*, 2017). Esta rede obteve atenção da comunidade científica na mesma época que a PMC com a formulação proposta por Kohonen (1982).

Uma vez que não há dados de saída desejados para realizar o ajuste dos pesos, os neurônios competem entre si para ser ativado para determinada amostra, sendo o neurônio escolhido chamado de neurônio vencedor (HAYKIN, 2009). Uma forma de avaliar o neurônio vencedor é por meio da proximidade do neurônio com a amostra de entrada, sendo esta calculada pela distância euclidiana entre os vetores do peso e da amostra. Aquele que apresentar a menor distância será o vencedor e será ajustado de acordo com uma taxa pré-definida. Como se trata de um mapa topológico, em que os neurônios estão distribuídos em um espaço bidimensional, é conveniente que os neurônios vizinhos ao neurônio vencedor também recebam um ajuste proporcional à

sua relevância. Pode-se resumir esses ajustes da seguinte forma (SILVA *et al.*, 2017):

$$\begin{cases} \mathbf{w}^{(v)} \leftarrow \mathbf{w}^{(v)} + \eta \cdot (\mathbf{x}^{(n)} - \mathbf{w}^{(v)}); \\ \mathbf{w}^{(\Omega)} \leftarrow \mathbf{w}^{(\Omega)} + \frac{\eta}{2} \cdot (\mathbf{x}^{(n)} - \mathbf{w}^{(\Omega)}). \end{cases} \quad (45)$$

que $\mathbf{w}^{(v)}$ representa o neurônio vencedor, $\mathbf{w}^{(\Omega)}$, o neurônio vizinho, η , a taxa de aprendizado e $\mathbf{x}^{(n)}$, a n-ésima amostra de entrada.

3.5 AVALIAÇÃO DOS RESULTADOS

As medidas de desempenho permitem avaliar a performance de determinado algoritmo de aprendizado. Para os métodos de classificação, a matriz de confusão fornece informações para diversas análises, inclusive o cálculo de métricas como acurácia, revocação, precisão e medida-F (FACELI *et al.*, 2011; KUHN; JOHNSON, 2013).

Considerando uma situação de duas classes, a matriz de confusão indica quantas amostras de teste foram classificadas correta e incorretamente. Para isso, indica quais são os verdadeiros positivos (VP), falsos positivos (FP), falsos negativos (FN) e verdadeiros negativos (VN). O Quadro 2 apresenta um exemplo de matriz de confusão.

Quadro 2 – Exemplo de matriz de confusão.

		Classe prevista	
		+	-
Classe observada	+	VP	FN
	-	FP	VN

Fonte: adaptado de Faceli *et al.* (2011).

A acurácia (A_c) é obtida pela soma dos valores na diagonal principal da matriz de confusão dividida por todos os elementos contidos na matriz (n), dada por (46):

$$A_c = \frac{VP + VN}{n}. \quad (46)$$

A revocação, também chamada de sensibilidade, é obtida por (47) e significa a taxa de acerto obtida na classe positiva.

$$rev = \frac{VP}{VP + FN}. \quad (47)$$

A precisão, por sua vez, é a proporção de verdadeiros positivos dentre todos previstos como positivos. Seu cálculo é dado por (48):

$$prec = \frac{VP}{VP + FP}. \quad (48)$$

As métricas revocação e precisão são geralmente combinadas para fornecer a análise chamada medida-F, que é a média harmônica ponderada dessas duas métricas. Esta é dada por (49):

$$F = \frac{(w + 1) \times rev \times prec}{rev + w \times prec}, \quad (49)$$

em que w é o grau de importância dado à precisão e revocação. Quando igual a um, a medida é conhecida F_1 -score.

Para generalizar para mais classes, basta considerar cada classe como positiva em relação às demais e medidas de desempenho serão geradas para cada classe.

Uma vez que a acurácia mede somente a porcentagem de previsões corretas, ela pode não ser adequada para situações onde o banco de dados é desbalanceado, uma vez que não faz distinção entre os tipos de previsões erradas. Assim, a F_1 -score se apresenta como uma saída para essas situações, já que é a combinação das métricas revocação e precisão, as quais levam em consideração os tipos de erros (falsos positivos e falsos negativos) para avaliação do desempenho do classificador.

4 MATERIAIS E MÉTODOS

Neste capítulo, são apresentados os materiais e a metodologia empregados para a realização do estudo. O trabalho é dividido em cinco etapas principais: geração e coleta dos dados, extração de características, tratamento dos dados, parametrização dos classificadores de padrões e treinamentos/testes. Para isso, o ambiente Simulink/MATLAB[®] é utilizado como ferramenta para implementação do modelo do MIT com falhas, processamento e classificação das amostras. Nos dois últimos estágios, também é utilizada a plataforma Jupyter Notebook (JUPYTER, 2023) para implementação dos algoritmos de classificação dos dados.

4.1 GERAÇÃO E COLETA DOS DADOS

De forma a atender o objetivo deste trabalho, que é o diagnóstico de falhas a partir da modelagem matemática do MIT com falhas de rolamento, são gerados dados de corrente de uma fase do estator por meio de simulação no Simulink/MATLAB[®].

A modelagem da máquina possui *loops* algébricos, ou seja, quando a entrada de um bloco depende da realimentação da saída, há o surgimento de uma dependência circular entre entrada e saída a cada passo de tempo na hora da resolução do sistema. Para contornar esta questão, é utilizado o ambiente Simulink/MATLAB[®], o qual emprega solucionadores não-lineares, que realizam iterações a cada passo de tempo para buscar a solução do *loop*. Como somente blocos de operação matemática são usados para implementação do modelo, este não possui alta complexidade.

Outro conjunto de dados de corrente obtidos em bancada experimental é somado a estes sinais simulados, onde o agrupamento total é submetido posteriormente à extração de características, tratamento das amostras e classificadores de padrões.

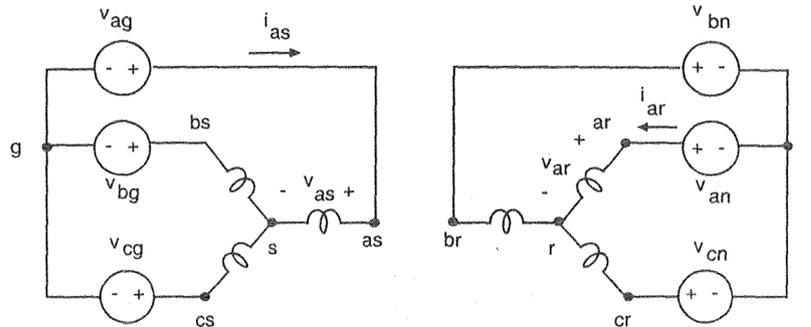
A seguir, a simulação implementada e a bancada experimental, provedores dos bancos de dados, são descritas detalhadamente.

4.1.1 Simulação do MIT com falhas

Considerando as conexões entre os enrolamentos do estator e do rotor de um MIT simétrico conforme Figura 7, com alimentação trifásica de tensões v_{ag} , v_{bg} e v_{cg} ,

simulando conexão direta à rede, as tensões trifásicas v_{as} , v_{bs} e v_{cs} do estator são dadas por (50) (ONG, 1998):

Figura 7 – Conexões entre os enrolamentos do MIT.



Fonte: Ong (1998).

$$\begin{aligned} v_{as} &= v_{ag} - v_{sg}, \\ v_{bs} &= v_{bg} - v_{sg}, \\ v_{cs} &= v_{cg} - v_{sg}, \end{aligned} \quad (50)$$

em que v_{sg} é a tensão entre o neutro do estator s e o neutro da fonte g , calculado por (51) (ONG, 1998):

$$v_{sg} = R_{sg}(i_{as} + i_{bs} + i_{cs}) + L_{sg} \frac{d}{dt}(i_{as} + i_{bs} + i_{cs}), \quad (51)$$

onde R_{sg} é a resistência e L_{sg} a indutância da conexão entre s e g . As correntes trifásicas do estator são identificadas por i_{as} , i_{bs} e i_{cs} .

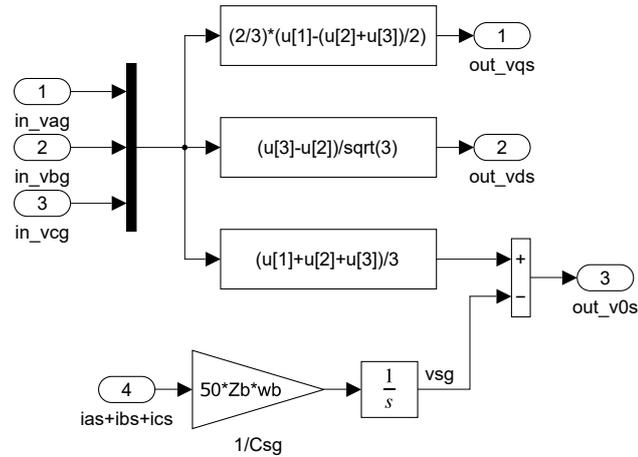
Realizando a transformação exibida em (2), obtém-se o exposto em (52):

$$\begin{aligned} v_{qs} &= \frac{2}{3}v_{ag} - \frac{1}{3}v_{bg} - \frac{1}{3}v_{cg}, \\ v_{ds} &= \frac{1}{\sqrt{3}}(v_{cg} - v_{bg}), \\ v_{0s} &= \frac{1}{3}(v_{ag} + v_{bg} + v_{cg}) - v_{sg}. \end{aligned} \quad (52)$$

No ambiente Simulink/MATLAB[®], essas equações são implementadas conforme a Figura 8. De forma a tornar os sinais de alimentação trifásica mais próximos do real, 15 harmônicas são adicionadas às senóides v_{ag} , v_{bg} e v_{cg} . Além disso, o neutro do estator está flutuando na simulação e, para obter a tensão entre os pontos neutros s e g , é conectado um pequeno capacitor fictício representado por C_{sg} .

Em seguida, para obter as correntes do estator na nova referência, (6) é rearranjada conforme (53) e (54):

Figura 8 – Bloco de transformação das tensões trifásicas para a referência qd0.



Fonte: autoria própria (2023).

$$i_{qs} = \frac{\Psi_{qs} - \Psi_{qm}}{x_{ls}}, \quad (53)$$

$$i_{ds} = \frac{\Psi_{ds} - \Psi_{dm}}{x_{ls}},$$

$$i'_{qr} = \frac{\Psi'_{qr} - \Psi_{qm}}{x'_{lr}}, \quad (54)$$

$$i'_{dr} = \frac{\Psi'_{dr} - \Psi_{dm}}{x'_{lr}},$$

em que Ψ_{qm} e Ψ_{dm} são os fluxos concatenados instantâneos de magnetização na referência qd0 estacionária, dados por (55):

$$\Psi_{qm} = x_m (i_{qs} + i'_{qr}), \quad (55)$$

$$\Psi_{dm} = x_m (i_{ds} + i'_{dr}).$$

Reordenando as equações (53) e (54), obtém-se (56):

$$\Psi_{qm} = x_M \left(\frac{\Psi_{qs}}{x_{ls}} + \frac{\Psi'_{qr}}{x'_{lr}} \right), \quad (56)$$

$$\Psi_{dm} = x_M \left(\frac{\Psi_{ds}}{x_{ls}} + \frac{\Psi'_{dr}}{x'_{lr}} \right),$$

onde:

$$\frac{1}{x_M} = \frac{1}{x_m} + \frac{1}{x_{ls}} + \frac{1}{x'_{lr}}. \quad (57)$$

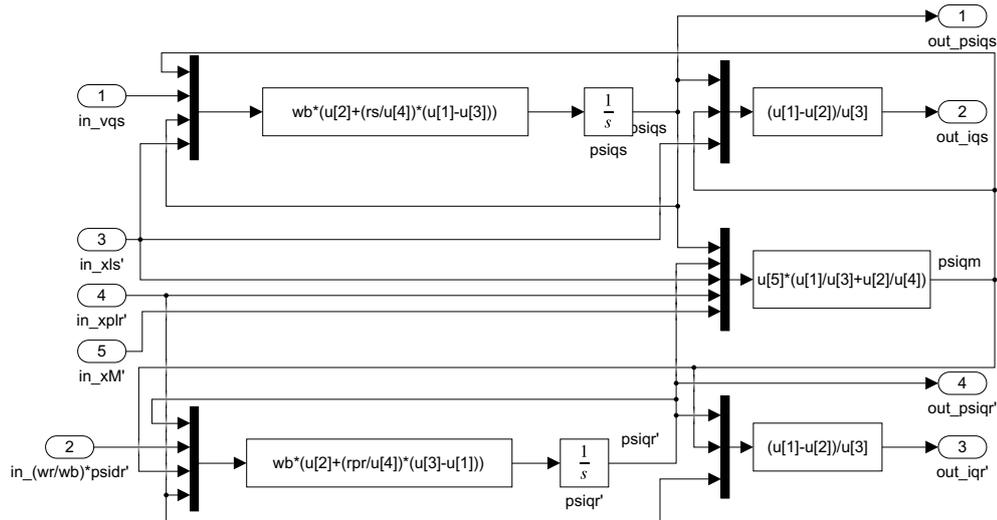
Assim, pode-se redispôr as variáveis em (3), conforme (58) e (59):

$$\begin{aligned}\Psi_{qs} &= w_b \int \left\{ v_{qs} + \frac{r_s}{x_{ls}} (\Psi_{qm} - \Psi_{qs}) \right\} dt, \\ \Psi_{ds} &= w_b \int \left\{ v_{ds} + \frac{r_s}{x_{ls}} (\Psi_{dm} - \Psi_{ds}) \right\} dt, \\ i_{0s} &= \frac{w_b}{x_{ls}} \int (v_{0s} - i_{0s} r_s) dt,\end{aligned}\quad (58)$$

$$\begin{aligned}\Psi'_{qr} &= w_b \int \left\{ v'_{qr} + \frac{w_r}{w_b} \Psi'_{dr} + \frac{r'_r}{x'_{lr}} (\Psi_{qm} - \Psi'_{qr}) \right\} dt, \\ \Psi'_{dr} &= w_b \int \left\{ v'_{dr} - \frac{w_r}{w_b} \Psi'_{qr} + \frac{r'_r}{x'_{lr}} (\Psi_{dm} - \Psi'_{dr}) \right\} dt, \\ i'_{0r} &= \frac{w_b}{x'_{lr}} \int (v'_{0r} - i'_{0r} r'_r) dt.\end{aligned}\quad (59)$$

Rearranjadas as equações, é possível compor os blocos das Figuras 9 e 10, responsáveis por calcular, na nova referência, as correntes i_{qs} , i_{ds} , i_{qr}' e i_{dr}' e os fluxos concatenados instantâneos Ψ_{qs} , Ψ_{ds} , Ψ_{qr}' , Ψ_{dr}' , Ψ_{qm} e Ψ_{dm} .

Figura 9 – Bloco de implementação das correntes e fluxos concatenados instantâneos no eixo q.



Fonte: autoria própria (2023).

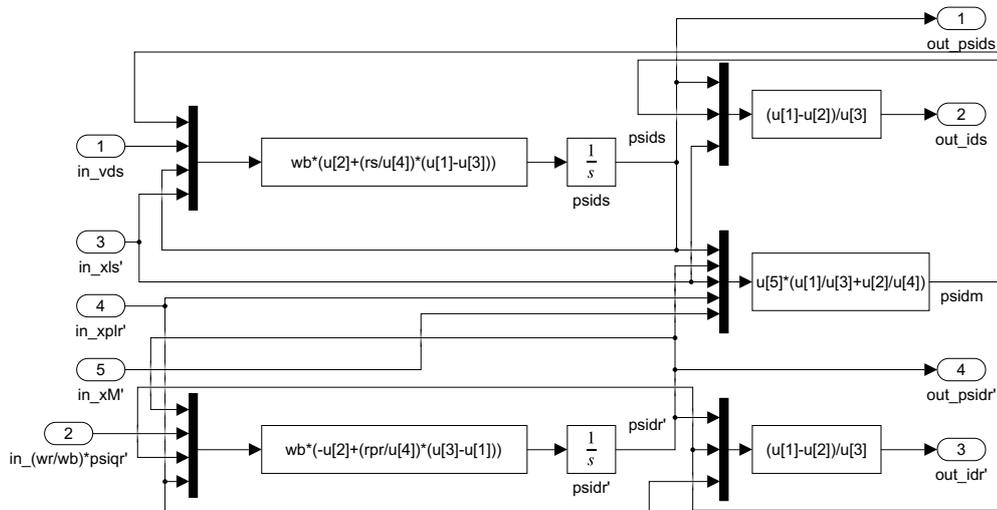
Para encontrar a corrente i_{0s} , o bloco da Figura 11 é elaborado.

O bloco responsável pela rotação do rotor (Figura 12) se baseia em (10) e (60):

$$\frac{2Jw_b}{P} \frac{d(w_r/w_b)}{dt} = T_{em} + T_{mec} - T_{damp}, \quad (60)$$

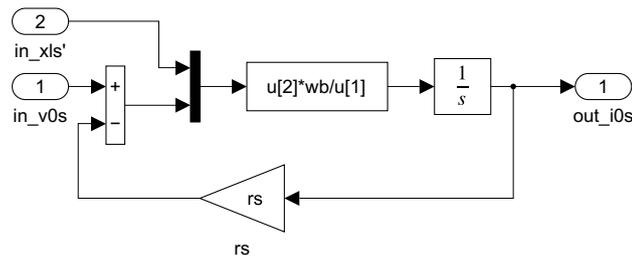
em que J é o coeficiente de inércia da carga, T_{mec} é o torque de carga e T_{damp} é o torque de amortecimento, dado por (61), com coeficiente de amortecimento D_ω . Desse bloco, é possível obter a velocidade do rotor em rad/s.

Figura 10 – Bloco de implementação das correntes e fluxos concatenados instantâneos no eixo d.



Fonte: autoria própria (2023).

Figura 11 – Bloco de implementação da corrente i_{0s} .



Fonte: autoria própria (2023).

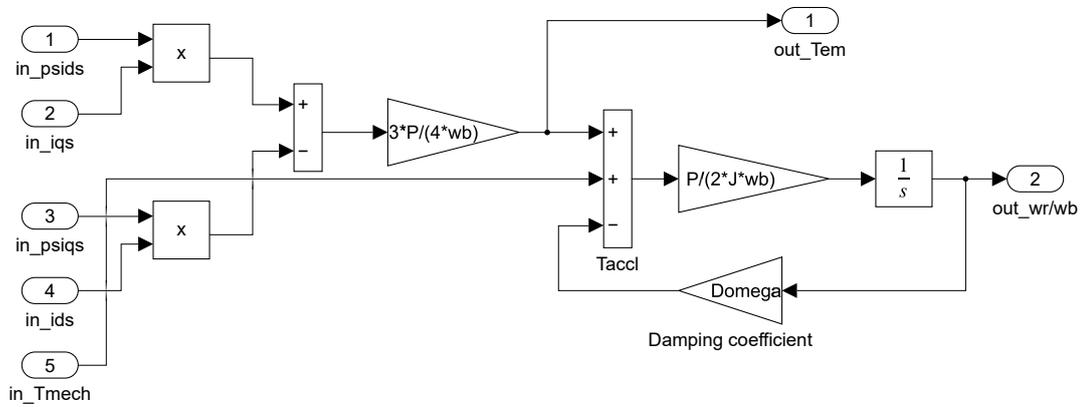
$$T_{damp} = D \omega \frac{w_r}{w_b}. \quad (61)$$

Já o bloco da Figura 13 é implementado para obter novamente as correntes trifásicas do motor após realizar as mudanças das indutâncias de dispersão do rotor, estator e de magnetização na referência qd0 e assim poder analisar seu efeito.

Essa implementação no Simulink/MATLAB[®] é encontrada em Ong (1998). A diferença está na inserção do bloco da Figura 14 na modelagem do motor de indução para simular a variação das reatâncias indutivas x_{ls} , x_{lr}' e x_m para cada tipo de falha de rolamento, nas pistas externa e interna e nas esferas.

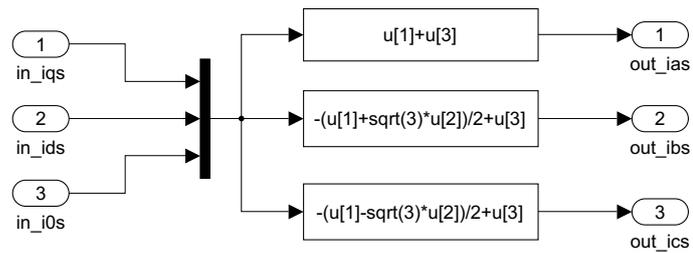
Neste bloco, T_{ext} , T_{int} e T_{esf} são os períodos das falhas de rolamento na pista externa, na pista interna e nas esferas, respectivamente. Com o intuito de implementar (18), é inserido um gerador de pulsos com o seu período sendo o inverso da frequência

Figura 12 – Bloco do rotor.



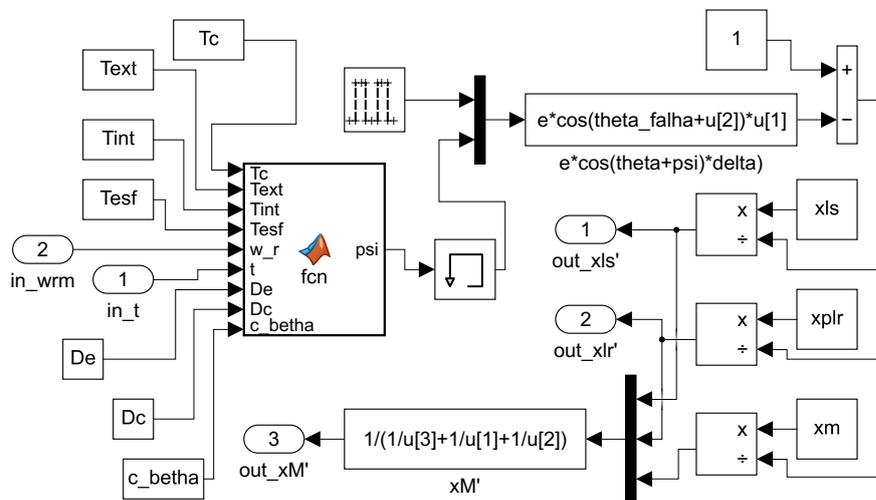
Fonte: autoria própria (2023).

Figura 13 – Bloco de transformação das correntes na referência qd0 para o eixo de referência trifásico.



Fonte: autoria própria (2023).

Figura 14 – Bloco de variação das reatâncias indutivas conforme falha.

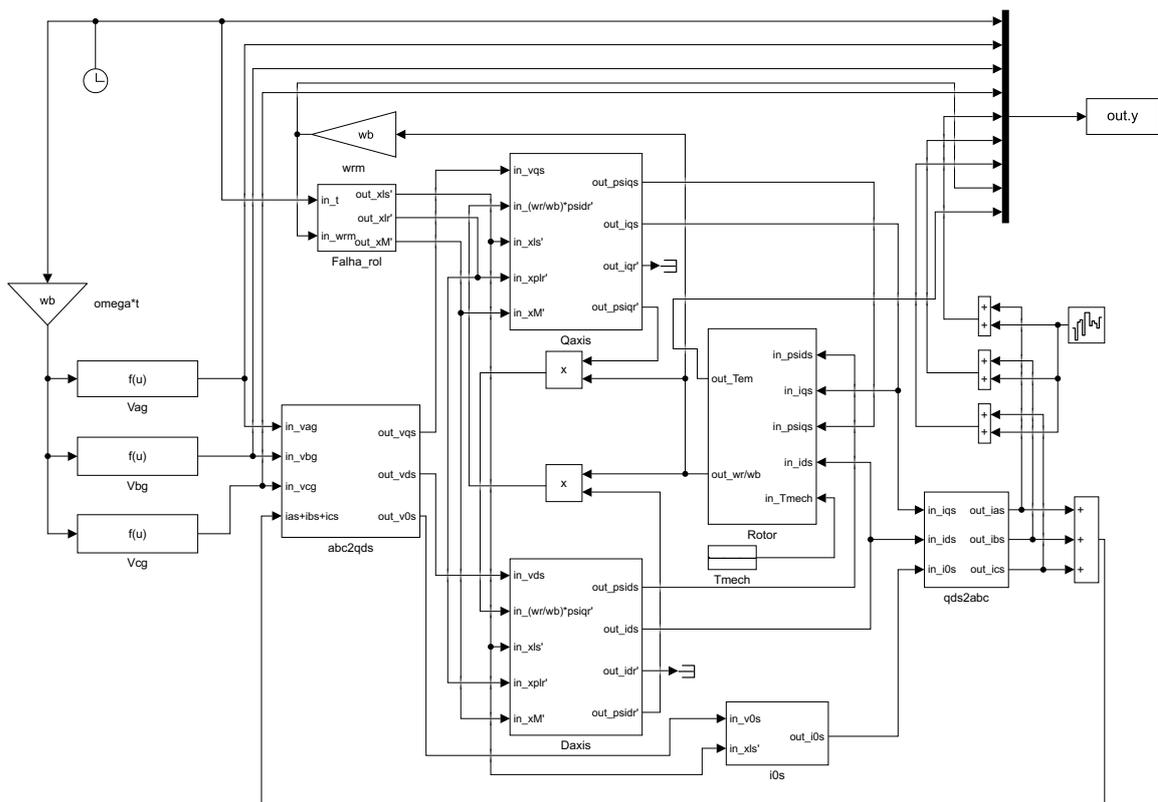


Fonte: autoria própria (2023).

característica da falha a ser escolhida pelo usuário. O sinal proveniente deste recebe um ganho referente ao grau de excentricidade e_r multiplicado pelo cosseno de $(\theta_f + \psi(t))$, em que ψ é diferente para os três casos de falha, conforme descrito na seção 2. O nível de excentricidade em relação ao entreferro é configurado para $e_r = 0,30$, visto que, para realizar sua simulação, Ojaghi, Sabouri e Faiz (2018) utiliza esse valor para e_r e testes entre 0,00 e 0,40 são explicitados por Guldemir (2003). Em seguida, o resultado é subtraído de uma unidade para ser acoplado nos valores da reatância. Assim, são introduzidas variações nas reatâncias que irão atuar nas equações da máquina na referência qd0.

Logo, o modelo do MIT com falhas de rolamento é implementado conforme a Figura 15. Para finalizar o modelo, um ruído branco é adicionado ao sinal de corrente da saída para simular o ruído adquirido ao utilizar instrumentos de medição.

Figura 15 – Modelo do motor de indução trifásico com falhas de rolamento na referência qd0.



Fonte: autoria própria (2023).

Com o modelo do MIT com falhas localizadas de rolamento pronto, são realizadas diversas simulações. São considerados o motor sem carga, com 25%, 50%, 75% e 100% de carga nominal no eixo para seis situações de desequilíbrio nas ten-

sões trifásicas do estator. A primeira situação considera as três fases balanceadas; a segunda, um desbalanço de +2% nas fases A e C e desbalanço de -2% na fase B; a terceira situação, um desbalanço de +4% nas fases A e C e desbalanço de -4% na fase B; a quarta, um desbalanço de +6% nas fases A e C e desbalanço de -6% na fase B; a quinta situação, um desbalanço de +8% nas fases A e C e desbalanço de -8% na fase B; e a sexta, um desbalanço de +10% nas fases A e C e desbalanço de -10% na fase B. Portanto, considerando motor saudável, com falha de pistas interna, externa e esferas (quatro estados do MIT), cinco níveis de carga e seis situações de alimentação, são totalizadas 120 situações para cada motor. Essas simulações são feitas com uma taxa de amostragem de 25 kHz, com passo fixo, e executadas por 5 segundos durante o regime permanente da máquina.

Os parâmetros dos motores utilizados para simulação, como as resistências r_s e r_r' , as reatâncias x_{ls} , x_{lr}' , a inércia J , o coeficiente de amortecimento D_ω e o tipo de rolamento dianteiro estão apresentados na Tabela 2. Todos os motores são trifásico, 60 Hz e possuem quatro polos.

Tabela 2 – Parâmetros dos motores utilizados nas simulações.

Motor (CV)	V_{linha} (V)	FP	r_s (Ω)	r_r' (Ω)	x_{ls} (Ω)	x_{lr}' (Ω)	x_m (Ω)	J (kgm^2)	D_ω	Rolamento
1	380,00	0,81	9,36	4,13	7,11	11,00	236,02	0,00	0,00	zz-6204
2	380,00	0,78	4,21	1,98	5,85	7,03	128,39	0,00	0,00	zz-6205
5	460,00	0,77	1,12	1,08	2,25	2,25	76,79	0,02	0,01	zz-6206
10	460,00	0,84	0,68	0,45	1,56	1,56	56,02	0,05	0,01	zz-6308
20	460,00	0,81	0,28	0,16	0,83	0,83	28,70	0,10	0,02	zz-6309
50	460,00	0,84	0,10	0,06	0,33	0,33	11,47	0,40	0,02	zz-6312
100	460,00	0,84	0,04	0,02	0,15	0,15	6,27	1,30	0,06	zz-6314
150	460,00	0,84	0,03	0,02	0,11	0,11	4,13	2,00	0,02	zz-6316
200	460,00	0,86	0,02	0,01	0,07	0,07	3,55	2,60	0,05	zz-6319

Fonte: Simulink (2022).

As especificações dos rolamentos analisados estão dispostos na Tabela 3.

4.1.2 Bancada Experimental

Os dados obtidos experimentalmente para efeito de comparação com os simulados são gerados a partir de uma bancada de teste exibida na Figura 16, originalmente proposta por Goedel (2007) e posteriormente desenvolvida e utilizada nos trabalhos de Broniera (2014), Godoy (2016), Palácios (2016), Gongora (2019), Guedes (2019) e

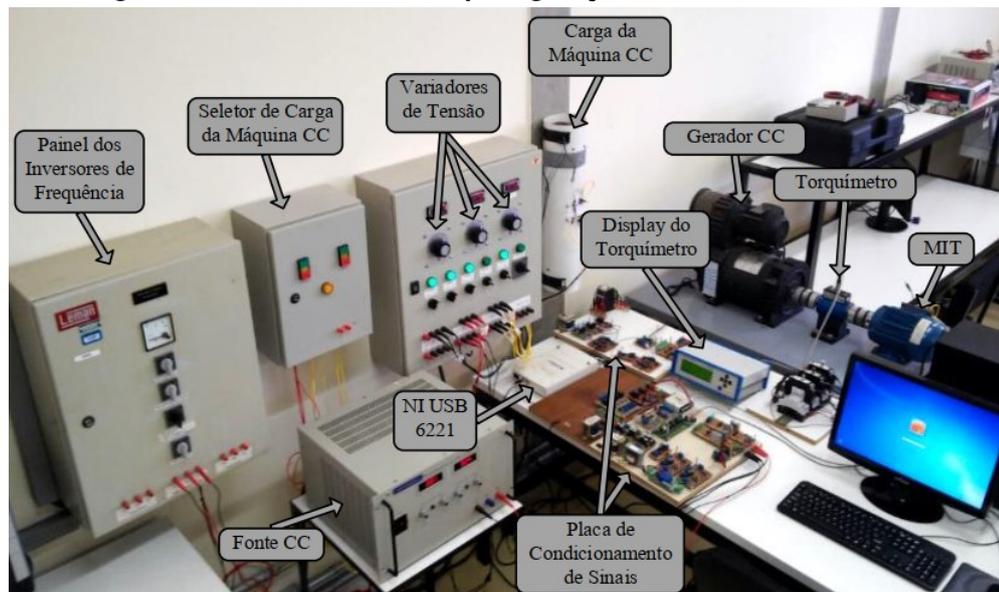
Tabela 3 – Dimensões dos rolamentos dos motores utilizados nas simulações.

Rolamento	D_c (m)	D_e (m)	N_e
zz-6204	0,03	0,01	9
zz-6205	0,04	0,02	9
zz-6206	0,05	0,02	11
zz-6308	0,07	0,02	12
zz-6309	0,08	0,02	12
zz-6312	0,10	0,03	13
zz-6314	0,12	0,04	14
zz-6316	0,13	0,04	14
zz-6319	0,16	0,04	15

Fonte: SKF (2022).

Bazan (2020). Essa bancada consegue monitorar grandezas provenientes de um MIT, como tensão, corrente, vibração, torque e velocidade, além de possibilitar a geração de diversas situações com variações na alimentação e na carga, e a inserção de defeitos controlados no MIT.

Figura 16 – Bancada de teste para geração dos dados de corrente.



Fonte: Bazan (2020).

A partir de um condicionamento de sinais por meio de sensores *Hall*, as tensões de fase e correntes de linha são moduladas para serem repassadas às entradas analógicas da placa de aquisição dos dados modelo USB 6221, da *National Instruments*. Essa, por sua vez, permite a comunicação via cabo USB com o computador para recebimento, armazenamento e tratamento dos dados por meio do *software* MATLAB®. Uma descrição mais detalhada é disponível em Gongora (2013).

Os dados de corrente e tensão são amostrados com uma taxa de 25 kHz, com

um intervalo de cinco segundos, com o motor em regime permanente e conectados diretamente à rede, utilizando motores de 1 CV e 2 CV. Os rolamentos dianteiros do motor de 1 CV e 2 CV são o zz-6204 e zz-6205, respectivamente, os mesmos descritos na Tabela 3.

São geradas amostras com as mesmas situações de carga e desequilíbrio de tensão descritas na subseção 4.1.1, porém as falhas de pista interna são feitas somente no motor de 1 CV e as falhas de esferas, somente no motor de 2 CV. As demais condições de saudável e falha na pista externa são verificadas em ambas as máquinas.

Logo, para a geração de dados, utilizam-se as máquinas cujas especificações são resumidas na Tabela 4.

Tabela 4 – Especificações dos motores utilizados para a geração de dados a partir de simulação e bancada de teste.

Especificações do motor	Simulação/ Bancada de teste	Bancada de teste
Fabricante	WEG	WEG
Modelo	W22	W22
	Alto rendimento	Alto rendimento
Potência [kW]	0,75	1,5
Tensão de Alimentação (Δ/Y) [V]	220/380	220/380
Corrente de Alimentação (Δ/Y) [A]	3,02/1,75	5,98/3,46
Número de fases	3	3
Frequência [Hz]	60	60
Número de polos	4	4
Velocidade Nominal [rpm]	1730	1750
Conjugado Nominal [N.m]	4,1	8,2

Fonte: WEG (2022).

4.2 EXTRAÇÃO DE CARACTERÍSTICAS

Antes de realizar a etapa de extração de características, há um condicionamento dos sinais, visando prover maior banco de dados de qualidade. Assim, primeiramente, tanto os sinais simulados quanto experimentais são filtrados por um filtro digital passa-baixa ideal não-causal com frequência de corte de 2 kHz. A escolha da frequência de corte é realizada de modo que, mesmo após a filtragem, as frequências características de falhas e suas primeiras harmônicas não sejam afetadas.

Em posse de 120 sinais simulados e 90 experimentais de cada motor de cinco segundo cada, estes são separados de meio em meio segundo. Logo, o número de

amostras disponíveis torna-se a exibida na Tabela 5, em que é apresentada a quantidade de dados por condição da máquina, saudável (SAU), com falhas de pista externa (FPE), de pista interna (FPI) e nas esferas (FE).

Tabela 5 – Número de amostras após separação dos sinais.

Origem	Motor (CV)	Número de amostras				
		SAU	FPE	FPI	FE	Total
Simulada	1, 2, 5, 10, 20, 50, 100, 150, 200	300	300	300	300	1200
Experimental	1	300	300	300	0	900
	2	300	300	0	300	900

Fonte: autoria própria (2023).

Após os sinais estarem condicionados, prossegue-se com a extração de características. A análise de determinadas instâncias dos sinais no domínio do tempo e da frequência permite reconhecer determinados padrões e comportamentos. Assim, as características listadas na Tabela 1 são extraídas dos sinais de corrente no regime permanente simulados e experimentais. Os atributos A_1 a A_{11} são extraídos no domínio do tempo e os atributos A_{12} a A_{23} , no domínio da frequência. Para extrair as características no domínio da frequência, é necessário obter o espectro de frequências dos dados de corrente. Logo, a FFT, sendo a ferramenta mais difundida, é utilizada para este fim.

Após esse procedimento, as 1200 amostras de corrente simulada e 900 de corrente experimental de cada motor podem ser representadas por 23 características que as definem e não mais os 12.500 pontos da magnitude da corrente no tempo, o que diminui o número de entradas nos classificadores e o seu custo computacional, facilitando o processo de aprendizado. Porém, antes de submeter as novas amostras aos classificadores, os novos conjuntos de dados são tratados com balanceamento e normalização, conforme descrito na próxima seção 4.3.

4.3 TRATAMENTO DOS DADOS

Visando validar o modelo do MIT com falhas localizadas de rolamento por meio da análise de classificadores quando submetidos dados simulados e experimentais mesclados, torna-se necessário o balanceamento das amostras, uma vez que não há dados experimentais de determinadas condições dos motores de 1 e 2 CV. Também se objetiva fazer uma categorização entre saudáveis e falhas inicialmente, o que implica

em uma base de dados com mais situações de falha do que saudável, caso não seja realizada a etapa de balanceamento.

A técnica para realizar esse ajuste na quantidade de elementos de cada condição da máquina, neste trabalho, é a *undersampling*. Manualmente, alguns dados de determinadas condições são eliminados do conjunto, de forma a equilibrar o número de amostras entre as classes. Esse procedimento é feito para cada classificação, isto é, levando em consideração o motor a ser investigado bem como se é para categorização em duas classes ou quatro classes. As novas definições das bases de dados são detalhadas na seção 4.5.

Para que as faixas de valores das 23 características não fiquem tão distantes entre si, a normalização *Z-score*, dada por (20), é realizada. Além disso, uma seleção de atributos mais relevantes é feita para submeter aos classificadores supervisionados. O conjunto com características reduzidas não é analisado pelo classificador não-supervisionado porque o objetivo deste é proporcionar, principalmente, a visualização do agrupamento das amostras. Logo, a seleção de atributos é realizada por meio do LASSO-CV e RFE com dois algoritmos de seleção, sendo eles o GB e RF. O RFE é configurado para retornar dez atributos mais relevantes. Pela combinação dos votos dos três algoritmos, as variáveis que mais se destacam são escolhidas.

Para divisão em subconjuntos de treinamento e teste, a técnica de validação cruzada é utilizada, em que cinco partições são feitas ($k = 5$), ou seja, 80% do dados são destinados ao treinamento e 20%, ao teste. A classificação é realizada cinco vezes onde os subconjuntos de treinamento e teste são reformulados de forma que cada amostra seja participante da etapa de teste uma vez.

4.4 PARAMETRIZAÇÃO DOS CLASSIFICADORES DE PADRÃO

Neste trabalho, são adotados, para classificar os bancos de dados, um classificador não-supervisionado e quatro classificadores supervisionados a fim de verificar o diagnóstico com conjunto de dados simulados e experimentais com base em diversas metodologias. O objetivo de utilizar a rede auto-organizável de Kohonen é a possibilidade de visualizar o agrupamento dos dados sem que sejam disponibilizados seus rótulos. Os supervisionados RF, kNN, PMC e SVM, além de serem os mais difundidos na literatura, permitem analisar o desempenho da classificação dos dados e assim a

identificação das falhas quando são submetidas amostras artificiais.

Antes de realizar o treinamento dos algoritmos de aprendizado de máquina com o banco de dados, alguns hiper-parâmetros devem ser configurados e estes permanecem fixos durante o aprendizado. Para se estabelecer uma comparação justa entre as situações analisadas (diferentes conjuntos de motores), são utilizados os mesmos hiper-parâmetros em todas os casos de classificação. Os hiper-parâmetros da rede de Kohonen estão especificados na Tabela 6.

Tabela 6 – Hiper-parâmetros selecionados do classificador não-supervisionado.

Classificador	Hiper-parâmetro	Hiper-parâmetro selecionado
Rede de Kohonen	Topologia	20x20
	Número de épocas	200
	Taxa de aprendizado inicial	0,02
	Métrica de proximidade	Distância Euclidiana
	Raio de vizinhança inicial	3

Fonte: autoria própria (2023).

Para os quatro classificadores supervisionados, a busca em grade é realizada, a qual consiste na procura pela combinação de hiper-parâmetros, dentro de um intervalo de valores, que retorne a melhor acurácia ou erro de validação. A busca é feita para o conjunto 1+2 CV e, em seguida, os hiper-parâmetros encontrados são adotados para todas as análises. Esses estão dispostos na Tabela 7. É válido ressaltar que é estabelecido, para a rede PMC, número máximo de 100 épocas de treinamento e somente uma camada escondida.

4.5 TREINAMENTOS E TESTES

A identificação das falhas é dividida em duas partes: classificação para duas classes e para multiclases, combinando o conjunto de dados de origens simulada e experimental. Para ambas as etapas, são realizados primeiramente o treinamento e o teste do classificador não-supervisionado; em seguida, o treinamento e o teste dos classificadores supervisionados. Em todas as análises, as métricas de acurácia e F_1 -score são utilizadas para mensurar a qualidade dos resultados obtidos com a categorização.

Uma vez que o classificador não-supervisionado utilizado neste trabalho também gera mapas auto-organizáveis, é possível visualizar o agrupamento dos dados

Tabela 7 – Hiper-parâmetros dos classificadores supervisionados varridos pela busca em grade e os selecionados.

Classificador	Hiper-parâmetro	Busca em grade	Hiper-parâmetro selecionado
RF	Número máximo de atributos M'	\sqrt{M} , $\log_2 M$	\sqrt{M}
	Número de estimadores	100, 200, 300, 400, 500, 600	100
	Critério	Gini, Entropia	Gini
kNN	Número de vizinhos k	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	1
	Métrica Minkowski d	1, 2	1
PMC	Função de ativação	Logística, Tangente hiperbólica, ReLU	ReLU
	Taxa de decaimento dos pesos	0,1, 0,001, 0,0001, 0,00001	0,1
	Neurônios na camada escondida	5-100 (de 5 em 5)	80
SVM	C	0,1, 1, 10, 100	0,1
	Coefficiente de Kernel	100, 10, 1, 0,1, 0,001, 0,0001	100
	Kernel	Linear, polinomial, RBF	Polinomial

Fonte: autoria própria (2023).

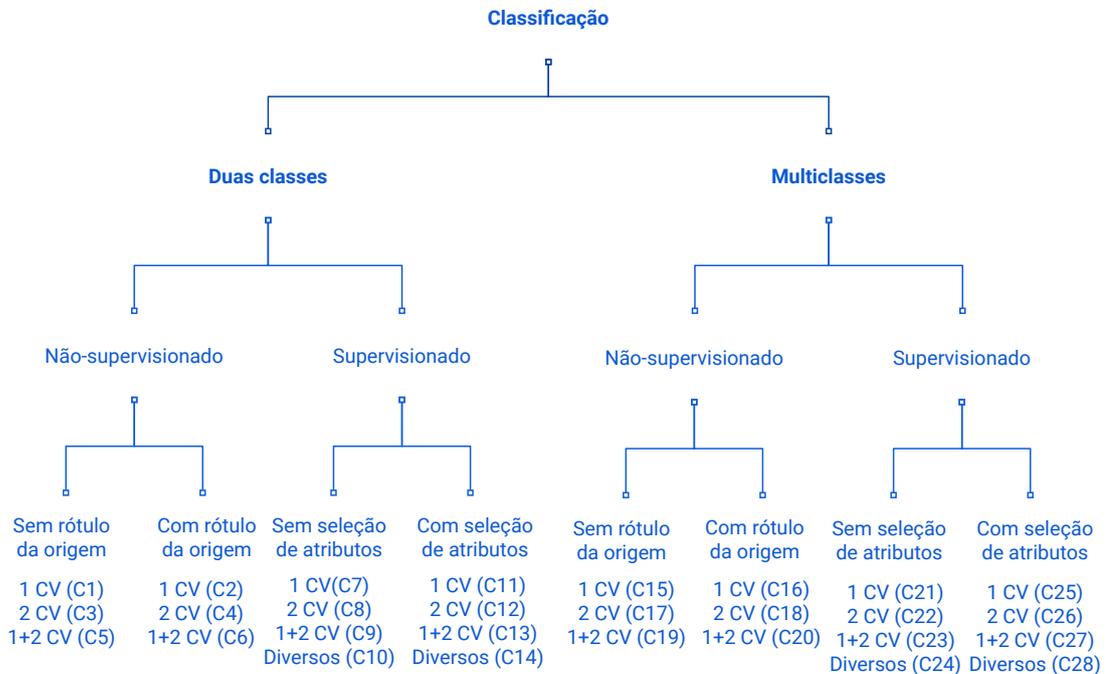
por meio dos neurônios ativados no mapa. Logo, esses mapas são analisados e, para verificar a proximidade do modelo desenvolvido com o motor real, classificações com esse algoritmo rotulando a origem dos dados também são realizadas. Dessa forma, a quantidade de elementos simulados deve ser igual ao experimental; isso restringe a análise do classificador não-supervisionado aos motores de 1 e 2 CV investigados de forma individual e conjunta.

Como o intuito dos classificadores supervisionados é verificar a interferência de amostras simuladas na classificação de dados experimentais, a classificação considerando a origem não é feita. Desse modo, como a restrição de se ter o mesmo número de amostras simuladas e experimentais já não é mais imposta a estes algoritmos, um quarto conjunto é apresentado a estes, sendo composto de amostras simuladas de 1, 2, 5, 10, 20, 50, 100, 150 e 200 CV e amostras experimentais de 1 e 2 CV, respeitando o balanceamento de números iguais entre as classes. Além disso, a categorização com classificadores supervisionados após seleção dos atributos mais relevantes é verificada a fim de diminuir o custo computacional e averiguar se ainda é atingido um bom desempenho.

A Figura 17 resume as 28 análises feitas, sendo metade para categorização em

duas classes e a outra metade, em multiclass. Como o balanceamento é diferente para cada motor e categorização, são descritas as quantidades de amostras utilizadas em cada situação e classificador nas próximas subseções.

Figura 17 – Diagrama das classificações realizadas neste trabalho.



Fonte: autoria própria (2023).

4.5.1 Duas classes

A classificação em duas classes envolve dois rótulos: saudável e com falha. Assim, para o caso de 1 CV, é necessário eliminar os dados simulados na condição de FE, já que não há amostras experimentais dessa falha para esse motor, e diminuir os elementos com FPE e FPI para que juntos tenham a mesma quantidade que a condição saudável. O mesmo raciocínio é feito para o motor de 2 CV, porém removendo completamente as amostras com FPI e reduzindo os dados com FPE e FE. Já para a situação 1+2 CV, todas as condições são disponíveis, logo equilibra-se entre os tipos de falha para atingir a mesma parcela de elementos saudáveis. Essa é a distribuição dos dados em cada conjunto analisado pelos classificadores não-supervisionado e supervisionados para classificação em duas classes e fica como o estabelecido na Tabela 8.

Segundo a Tabela 8, 1200 amostras no total são analisadas em cada uma das

Tabela 8 – Número de amostras balanceadas de cada condição dos motores de 1 e 2 CV para duas classes.

Motor (CV)	Origem	Condição				Total
		SAU	FPE	FPI	FE	
1	SIM	300	150	150	0	1200
	EXP	300	150	150	0	
2	SIM	300	150	0	150	1200
	EXP	300	150	0	150	
1+2	SIM	300	100	100	100	1200
	EXP	300	100	100	100	

Fonte: autoria própria (2023).

três situações listadas por todos os classificadores para categorização em duas classes. Sendo $k = 5$ da validação cruzada, cada subconjunto de treinamento tem 960 dados e cada subconjunto de teste, 240 dados.

Como os dados simulados de motores de 1, 2, 5, 10, 20, 50, 100, 150 e 200 CV são usados em conjunto com experimentais de 1 e 2 CV numa quarta situação nos classificadores supervisionados, estes seguem o arranjo disposto na Tabela 9. É válido ressaltar que esta situação não foi analisada pelo Kohonen em virtude da não disponibilidade de amostras experimentais de motores de 5, 10, 20, 50, 100, 150 e 200 CV. Sendo 3300 o total de amostras nesta análise, cada um dos cinco subconjuntos de treinamento da validação cruzada possuem 2640 elementos e de teste, 660 elementos.

Tabela 9 – Número de amostras balanceadas de cada condição de diversos motores para duas classes.

Motor (CV)	Origem	Condição				Total
		SAU	FPE	FPI	FE	
1+2+5+10+20+ 50+100+150+200	SIM	1350	450	450	450	3300
1+2	EXP	300	100	100	100	

Fonte: autoria própria (2023).

4.5.2 Multiclasses

A categorização em multiclasses (SAU, FPE, FPI e FE) permite o uso de maior quantidade de dados em relação à classificação anterior. Isso se deve porque não é mais necessário juntar os dados de falhas em um único conjunto para se obter a mesma parcela que as amostras saudáveis. Assim, para o motor de 1 CV, basta eliminar os elementos simulados de FE; e para o motor de 2 CV, os elementos simulados de FPI. Para o caso 1+2 CV, cada condição por motor contribui com 150 amostras

simuladas; não são utilizadas todas pela limitação que há para os dados experimentais nas condições FE e FPI dos motores de 1 e 2 CV, respectivamente, que fornecem todas as 300 amostras disponíveis para suprir a condição ausente do outro motor. A Tabela 10 apresenta a distribuição das amostras por condição e por motor utilizadas nas classificações multiclasses não-supervisionada e supervisionada.

Tabela 10 – Número de amostras balanceadas de cada condição dos motores de 1 e 2 CV para multiclasses.

Motor (CV)	Origem	Condição				Total
		SAU	FPE	FPI	FE	
1	SIM	300	300	300	0	1800
	EXP	300	300	300	0	
2	SIM	300	300	0	300	1800
	EXP	300	300	0	300	
1+2	SIM	300	300	300	300	2400
	EXP	300	300	300	300	

Fonte: autoria própria (2023).

Para as situações de motores individuais, 1440 amostras são destinadas ao treinamento e 360, ao teste. Na terceira análise, cuja base de dados é de 2400 elementos, os classificadores são treinados cinco vezes com 1920 amostras e testados com 480 amostras.

Assim como ocorrido para duas classes, uma quarta situação é analisada por algoritmos supervisionados. O conjunto observado apresenta a distribuição das amostras da Tabela 11, onde 6600 dados foram utilizados. Destes, 5280 elementos são destinados ao subconjunto de treinamento e 1320, ao subconjunto de teste, cada uma das cinco vezes que o classificador é treinado, conforme validação cruzada.

Tabela 11 – Número de amostras balanceadas de cada condição de diversos motores para multiclasses.

Motor (CV)	Origem	Condição				Total
		SAU	FPE	FPI	FE	
1+2+5+10+20+ 50+100+150+200	SIM	1350	1350	1350	1350	6600
1+2	EXP	300	300	300	300	

Fonte: autoria própria (2023).

5 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados obtidos nas classificações realizadas entre as condições do MIT, utilizando amostras de origens experimental e simulada, conforme explicitado no capítulo anterior. Analisando a acurácia (A_c) e o F_1 -score, é possível inferir sobre a validação do modelo proposto.

Esses resultados estão setorizados de acordo com a classificação (duas classes ou multiclass), em que cada uma evidencia os resultados obtidos em diversas amostras de motores simulados e experimentais usando classificadores não-supervisionado e supervisionados.

5.1 CLASSIFICAÇÃO EM DUAS CLASSES

Um dos propósitos da implementação do modelo do MIT com falhas localizadas de rolamento é proporcionar um diagnóstico mais eficiente sobre a condição da máquina, ou seja, se está operando de forma saudável ou com falhas de rolamento. Uma vez que a manutenção para todas as localidades incluem a substituição completa da peça, é fundamental identificar se há a presença da falha no rolamento, independentemente da sua localização.

Dessa forma, as subseções a seguir apresentam os resultados obtidos nas classificações de amostras simuladas e experimentais categorizando entre saudáveis e com falhas. A clusterização permite verificar se há uma tendência nos dados que representam um determinado estado se agruparem, seja de origem simulada ou experimental. Logo, além de utilizar o método não-supervisionado para classificação, é possível avaliar visualmente o agrupamento dos elementos.

Em seguida, os resultados obtidos com quatro classificadores de método supervisionado são evidenciados para poder validar a proposta deste trabalho, que é a complementação da base de dados com amostras oriundas da simulação do modelo do motor com falha. Além disso, as informações extraídas do banco de dados analisado mais relevantes para a classificação também são apresentadas para aprimoramento do diagnóstico de falhas.

5.1.1 Classificador não-supervisionado

O mapa auto-organizável de Kohonen, embora muito utilizado para fins de clusterização, pode ter uma etapa final supervisionada que possibilite a classificação de uma nova amostra de teste. Assim, as médias da acurácia e do F_1 -score de cinco testes, após segmentação da base de dados por validação cruzada, são expostas na Tabela 12 para motores de 1, 2 e 1 e 2 CV em conjunto.

Tabela 12 – Médias da acurácia (A_c) e do F_1 -score de cinco testes das classificações não-supervisionadas para duas classes.

Índice	Motor (CV)		A_c (%)	F_1 (%)
C1	1	S/ dif.	99,33	99,32
C2		C/ dif.	98,92	98,93
C3	2	S/ dif.	100,00	100,00
C4		C/ dif.	99,33	99,33
C5	1+2	S/ dif.	99,08	99,07
C6		C/ dif.	98,50	98,53

Fonte: autoria própria (2023).

Os termos "C/ dif." e "S/ dif." apontam se houve rotulação para a origem do dado ou não, respectivamente, ou seja, se era de procedência experimental ou simulada. Esse procedimento foi adotado com o objetivo de visualizar se há uma tendência em as amostras artificiais de uma determinada condição do motor se agruparem próximas as de origem experimental de mesma condição, visto que o Kohonen permite tal análise. Assim, os resultados obtidos na classificação após essas clusterizações "C/ dif." também foram tabeladas, sendo valores bem próximos aos que não são indicados a origem do dado ("S/ dif.").

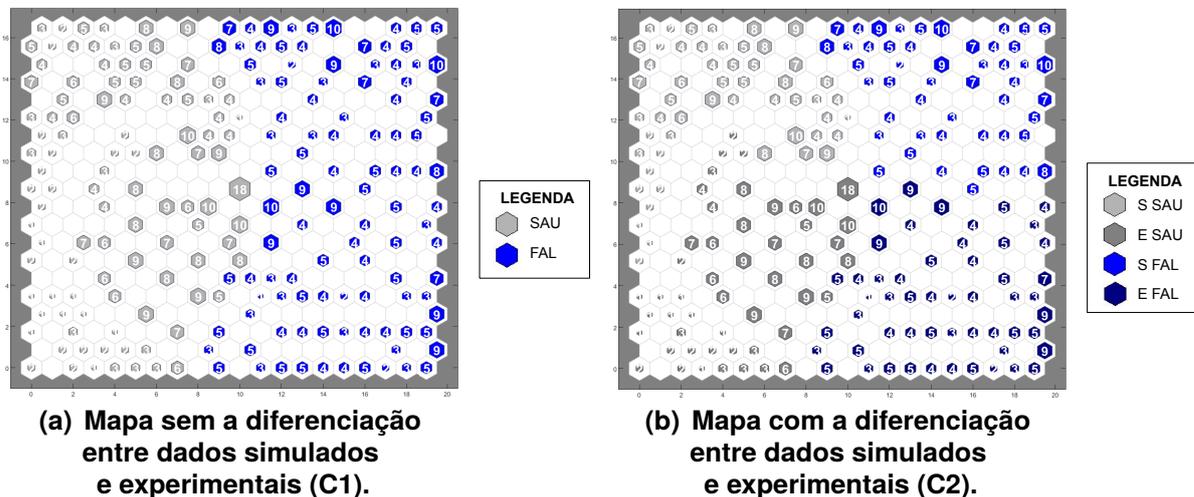
Nota-se, pela Tabela 12, que a menor acurácia, entre todos os testes (independente do tipo do motor), foi 98,50% e o menor F_1 -score, 98,53%, na classificação C6, o que se pode inferir que a utilização de dados simulados com experimentais para classificação por meio de Kohonen traz altas taxas de acerto.

Os seis casos exibidos na Tabela 12 têm seus mapas auto-organizáveis apresentados a seguir, tanto para a etapa de treinamento quanto de teste. É válido ressaltar que os mapas são provenientes da classificação com a partição dos dados que possui maior índice de acurácia e de F_1 -score, para visualizar o melhor caso obtido em cada situação.

5.1.1.1 Mapa de Kohonen: motores de 1 CV

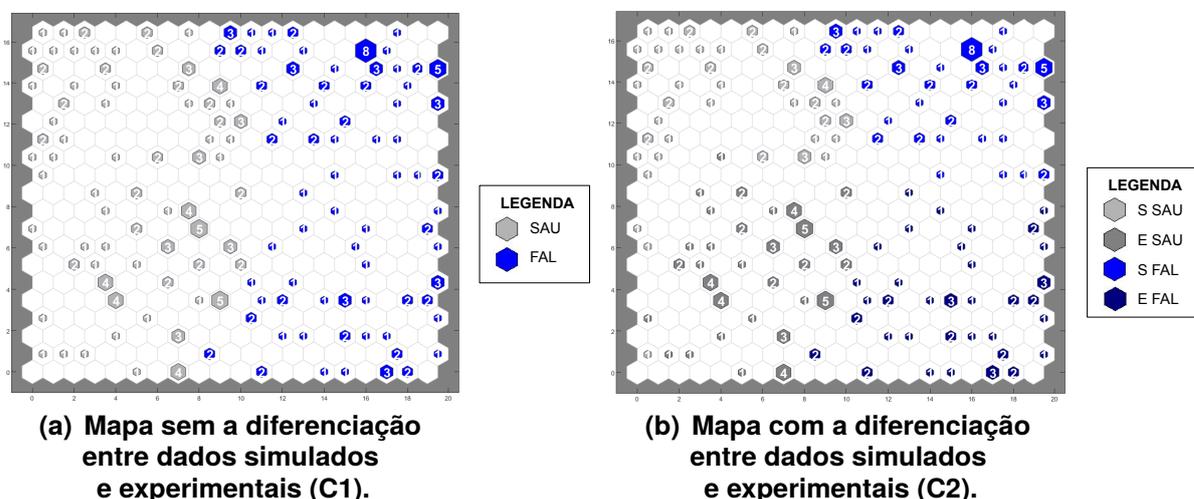
Para a situação do motor de 1 CV, são utilizadas 600 amostras simuladas e 600 experimentais, em que 960 são destinadas ao treinamento e 240 ao teste em cinco classificações em duas classes, conforme composição da Tabela 8. Com base nessa divisão dos dados, as Figuras 18 e 19 exibem os mapas auto-organizáveis de Kohonen obtidos a partir do treinamento e teste, respectivamente. As figuras situadas à esquerda não identificam a origem dos dados ao passo que, à direita, essa procedência é especificada.

Figura 18 – Mapa auto-organizável de Kohonen do treinamento para motores de 1 CV na situação de duas classes.



Fonte: autoria própria (2023).

Figura 19 – Mapa auto-organizável de Kohonen do teste para motores de 1 CV na situação de duas classes.



Fonte: autoria própria (2023).

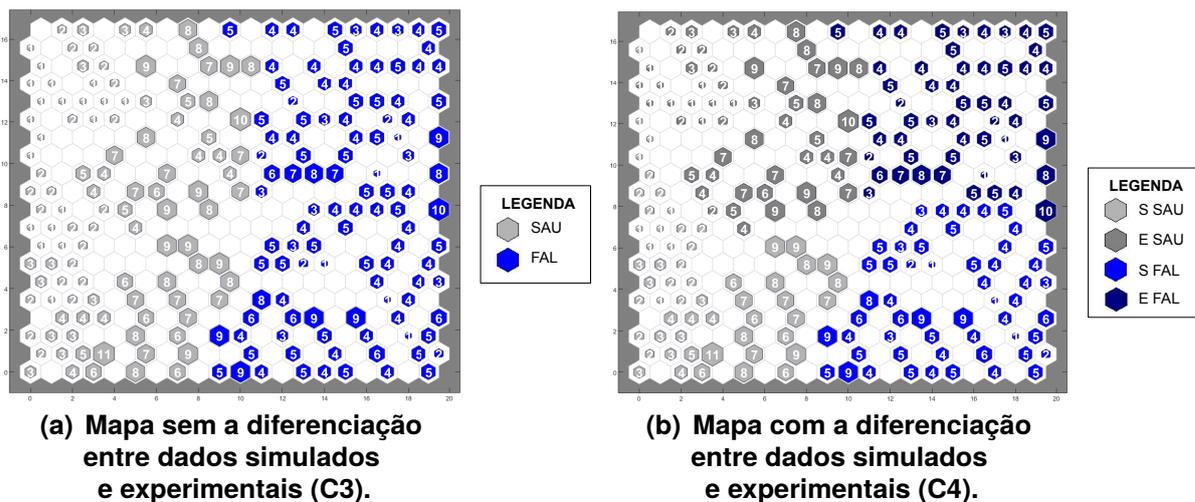
Embora haja diferenças entre os dados simulados (S SAU e S FAL) e experimentais (E SAU e E FAL), estes tendem a se agrupar dependendo da condição do motor, como observado pelo surgimento de duas regiões distintas para as figuras à esquerda (Subfiguras 18(a) e 19(a)). As células de cor cinza são os neurônios ativados por dados saudáveis (SAU) e as de cor azul, neurônios excitados por amostras com falhas (FAL).

5.1.1.2 Mapa de Kohonen: motores de 2 CV

Conforme Tabela 8, 1200 amostras, tanto de origem simulada quanto experimental, são treinadas e testadas para a situação do motor de 2 CV, em que 960 elementos são utilizados na primeira operação e 240, na segunda. As Figuras 20 e 21 exibem a distribuição desses dados no mapa de Kohonen.

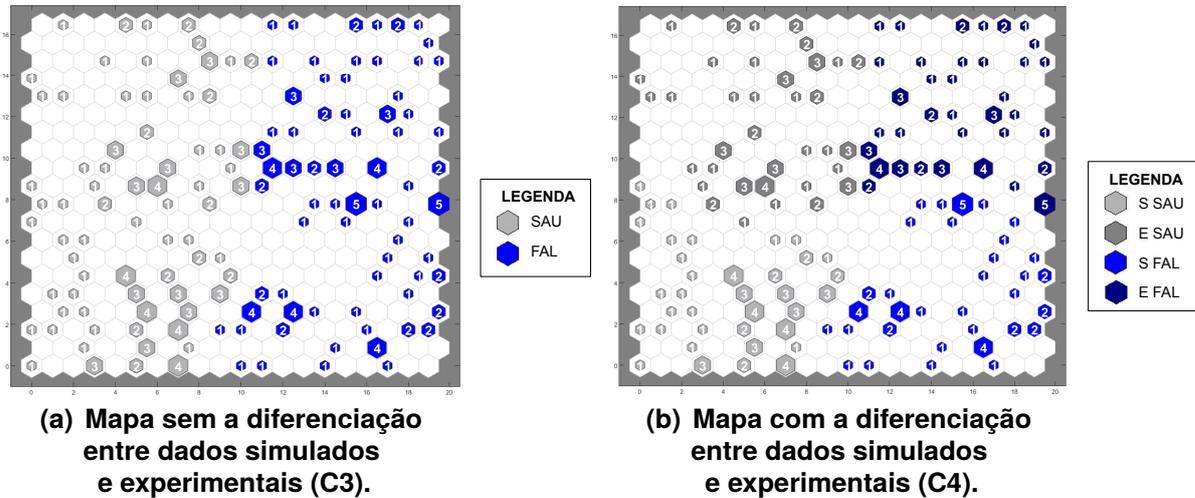
Assim como observado para o motor de 1 CV, há a formação de duas regiões distintas (saudável e com falhas) nas Subfiguras 20(a) e 21(a). Ademais, os dados experimentais saudáveis (E SAU) se agrupam com os simulados saudáveis (S SAU) enquanto os experimentais com falhas (E FAL) e simulados com falhas (S FAL) se associam (Subfiguras 20(b) e 21(b)).

Figura 20 – Mapa auto-organizável de Kohonen do treinamento para motores de 2 CV na situação de duas classes.



Fonte: autoria própria (2023).

Figura 21 – Mapa auto-organizável de Kohonen do teste para motores de 2 CV na situação de duas classes.

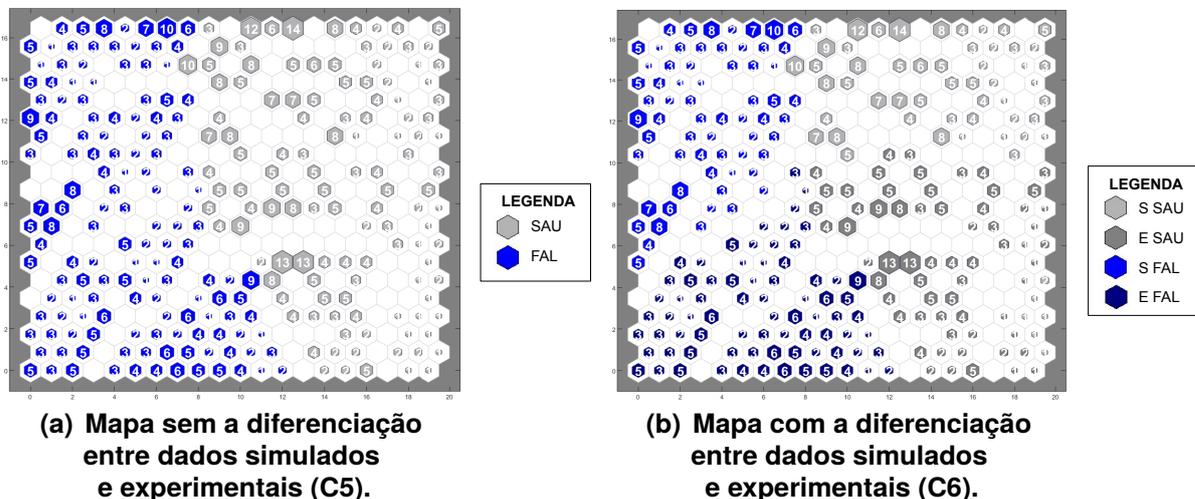


Fonte: autoria própria (2023).

5.1.1.3 Mapa de Kohonen: motores de 1 e 2 CV

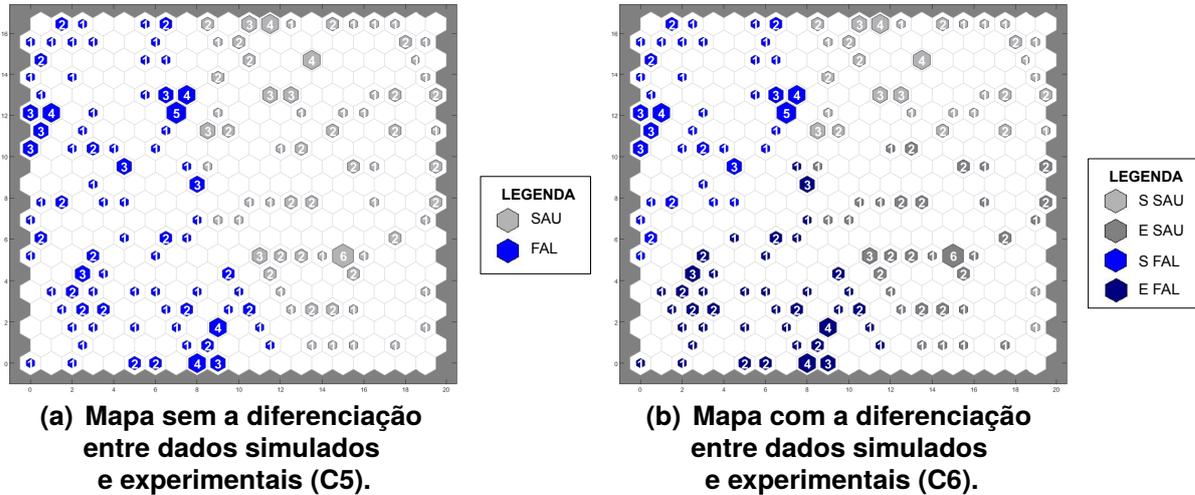
Mesclando os conjuntos de 1 CV e 2 CV, 1200 amostras são distribuídas nos mapas de Kohonen, sendo 960 no treinamento (Figura 22) e 240 no teste (Figura 23), seguindo a distribuição da Tabela 8. De acordo com os mapas individuais para 1 CV e 2 CV, há a composição de dois setores característicos nos mapas das Subfiguras 22(a) e 23(a), evidenciando que, ainda que existam diferenças entre sinais simulados e experimentais, há um comportamento em comum que indica a presença ou não das falhas, o que valida a proposta da modelagem presente neste trabalho.

Figura 22 – Mapa auto-organizável de Kohonen do treinamento para motores de 1 e 2 CV na situação de duas classes.



Fonte: autoria própria (2023).

Figura 23 – Mapa auto-organizável de Kohonen do teste para motores de 1 e 2 CV na situação de duas classes.



Fonte: autoria própria (2023).

5.1.2 Classificadores supervisionados

Os classificadores com aprendizado supervisionado caracterizam-se por, na etapa de treinamento, conhecer a saída desejada para que seus parâmetros sejam ajustados à situação. A Tabela 13 apresenta os resultados obtidos nos testes com quatro classificadores supervisionados, sendo eles a Floresta Aleatória, o k-ésimo Vizinhos Mais Próximos, a Rede Perceptron Multicamadas e a Máquina de Vetores de Suporte, para categorização entre saudável e com falhas de amostras simuladas e experimentais.

Conforme realizado para a classificação não-supervisionada, são analisados os dados dos motores de 1 e 2 CV de forma individual e conjunta. Uma vez que o objetivo da classificação supervisionada não inclui a análise da origem das amostras como na classificação não-supervisionada, adicionam-se também grupos de amostras simuladas de 5, 10, 20, 50, 100, 150 e 200 CV, de forma a tornar o aprendizado mais robusto. Para isso, 300 dados de cada motor são investigados, totalizando 3300 elementos. A divisão entre treinamento e teste, assim como a quantidade presente de cada condição da máquina, são exibidas nas Tabelas 8 e 9.

A partir do exposto na Tabela 13, verifica-se que há resultados com altas taxas de acurácia e F_1 -score, sendo iguais a 100% para dois dos quatro classificadores (RF e kNN) e próximas de 100% para os outros dois, PMC e SVM. É possível inferir que a

Tabela 13 – Médias da Acurácia (A_c) e do F_1 -score de cinco testes das classificações supervisionadas para duas classes.

Índice	Motor (CV)	RF		kNN		PMC		SVM	
		A_c (%)	F_1 (%)						
C7	1	100,00	100,00	100,00	100,00	99,58	99,58	100,00	100,00
C8	2	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
C9	1+2	100,00	100,00	100,00	100,00	99,33	99,33	100,00	100,00
C10	1+2+5+10 20+50+100 150+200	100,00	100,00	100,00	100,00	99,42	99,42	99,85	99,85

Fonte: autoria própria (2023).

adição dos dados simulados não prejudica o aprendizado dos algoritmos, o que pode validar a inserção destes ao conjunto das amostras experimentais.

A segunda análise das classificações supervisionadas para duas classes inclui a seleção de atributos mais relevantes realizada antes da classificação em si. De acordo com o explicitado no capítulo anterior, três algoritmos de aprendizado retornam três modelos com menos variáveis que representam o modelo original. Os atributos selecionados por cada algoritmo e pelos votos dos três em conjunto são apresentados na Tabela 14.

Tabela 14 – Atributos selecionados por cada algoritmo e pelos três juntos para duas classes.

Índice	Motor (CV)	LASSO-CV	GB	RF	Selecionados pelos três
C11	1	1, 3, 4, 5, 6, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 22	1, 2, 4, 7, 10, 12, 13, 14, 15, 23	2, 3, 4, 7, 10, 14, 15, 17, 21, 23	4, 10, 14, 15
C12	2	1, 3, 4, 5, 6, 7, 8, 9, 10, 11, 17 13, 14, 15, 16, 18, 19, 21, 22, 23	6, 7, 8, 9 10, 12, 13, 15, 17, 22	7, 8, 9, 10, 11, 13, 14, 15, 22, 23	7, 8, 9, 10, 13, 15, 22
C13	1+2	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 21, 22, 23	1, 2, 6, 9, 10, 11, 14, 15, 19, 22	2, 3, 4, 9, 10, 14, 15, 17, 21, 22	2, 9, 10, 14, 15, 22
C14	1+2+5+10 20+50+100 150+200	1, 2, 3, 4, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 23	1, 2, 8, 9, 10, 14, 15, 17, 19, 23	1, 3, 6, 9, 10, 13, 14, 15, 20, 22	1, 9, 10, 14, 15

Fonte: autoria própria (2023).

Após a seleção de atributos pelos votos dos três algoritmos, as classificações são novamente refeitas, cujos resultados encontram-se na Tabela 15. Observa-se que, dentre os quatro classificadores, a menor acurácia e o menor F_1 -score são de

96,08%, utilizando PMC no caso C11. Os classificadores RF, kNN e SVM obtêm bom desempenho, entre 98,85% e 100,00%. A rede PMC é o algoritmo que encontra maior dificuldade para classificar, porém, ainda assim, atinge resultados acima de 96,00%.

Tabela 15 – Médias da Acurácia (A_c) e do F_1 -score de cinco testes das classificações supervisionadas com seleção de atributos para duas classes.

Índice	Motor (CV)	RF		kNN		PMC		SVM	
		A_c (%)	F_1 (%)						
C11	1	99,83	99,83	99,92	99,92	96,08	96,08	99,92	99,92
C12	2	100,00	100,00	100,00	100,00	99,00	99,00	100,00	100,00
C13	1+2	100,00	100,00	99,83	99,83	97,42	97,42	100,00	100,00
C14	1+2+5+10 20+50+100 150+200	99,97	99,97	99,36	99,36	98,79	98,79	98,85	98,85

Fonte: autoria própria (2023).

Os resultados obtidos com e sem seleção de atributos evidenciam que podem ser incorporadas amostras simuladas ao conjunto de dados experimentais, sem interferir no aprendizado do algoritmo de classificação. Além disso, o caso com diversos motores simulados e apenas 1 e 2 CV experimentais pode apontar uma robustez alcançada pelos algoritmos, uma vez que a potência do motor não interfere na categorização entre saudável e com falhas.

5.2 CLASSIFICAÇÃO EM MULTICLASSES

A categorização entre os tipos de falhas de rolamento (sua localização), além de verificar se o motor está saudável ou não, permite investigar as possíveis causas do determinado dano caso haja um certo padrão na ocorrência de um de seus tipos.

Assim, a partir de amostras de sinais de corrente simulados e experimentais de alguns motores, são analisados a seguir classificadores com aprendizados não-supervisionado e supervisionados para a situação de multiclases, como realizado para duas classes.

5.2.1 Classificador não-supervisionado

Utilizando o mapa auto-organizável de Kohonen com uma etapa final supervisionada, é possível verificar a sua performance para classificação em multiclases, cujos índices de acurácia e F_1 -score são armazenados e estão exibidos na Tabela 16. Com

os menores índices sendo 99,46% e 99,45% para acurácia e F_1 -score, na classificação C20, respectivamente, pode-se inferir que o classificador obtém bom desempenho para identificar se há falha no motor e, se sim, sua localização.

Tabela 16 – Médias da acurácia e do F_1 -score de cinco testes das classificações não-supervisionadas para multiclassés.

Índice	Motor (CV)		A_c (%)	F_1 (%)
C15	1	S/ dif.	99,89	99,89
C16		C/ dif.	99,67	99,67
C17	2	S/ dif.	99,83	99,84
C18		C/ dif.	99,50	99,52
C19	1+2	S/ dif.	99,67	99,67
C20		C/ dif.	99,46	99,45

Fonte: autoria própria (2023).

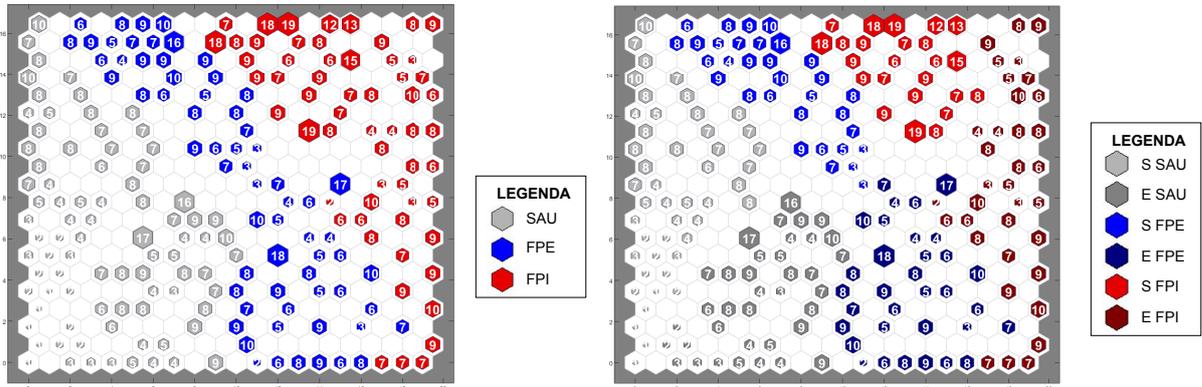
A fim de visualizar a clusterização dos dados, os mapas de Kohonen para cada uma das seis situações da Tabela 16 são exibidos nas próximas subseções.

5.2.1.1 Mapa de Kohonen: motores de 1 CV

As Figuras 24 e 25 são os mapas gerados após treinamento e teste, respectivamente, das 1800 amostras de um motor de 1 CV, sendo 1440 dados destinados à primeira etapa e 360 à segunda. A composição desse conjunto é exibido na Tabela 10. As subfiguras da esquerda identificam os neurônios ativados pelas amostras de determinada condição do motor, podendo ser saudável (SAU), falha de pista externa (FPE), de pista interna (FPI) e nas esferas (FE). As subfiguras da direita também fazem o mesmo papel, porém apontando a origem do dado, se foi simulado (S) ou experimental (E).

Embora não haja disponível amostras do tipo E FE para agregar à análise, nota-se, nas Subfiguras 24(a) e 25(a), a concentração dos neurônios ativados por dados com a mesma condição, independentemente se é simulado ou experimental, formando regiões para SAU, FPE e FPI. Já as Subfiguras 24(b) e 25(b) apontam que as amostras simuladas e experimentais de mesma condição tendem a se agrupar.

Figura 24 – Mapa auto-organizável de Kohonen do treinamento para motores de 1 CV na situação de multiclasses.

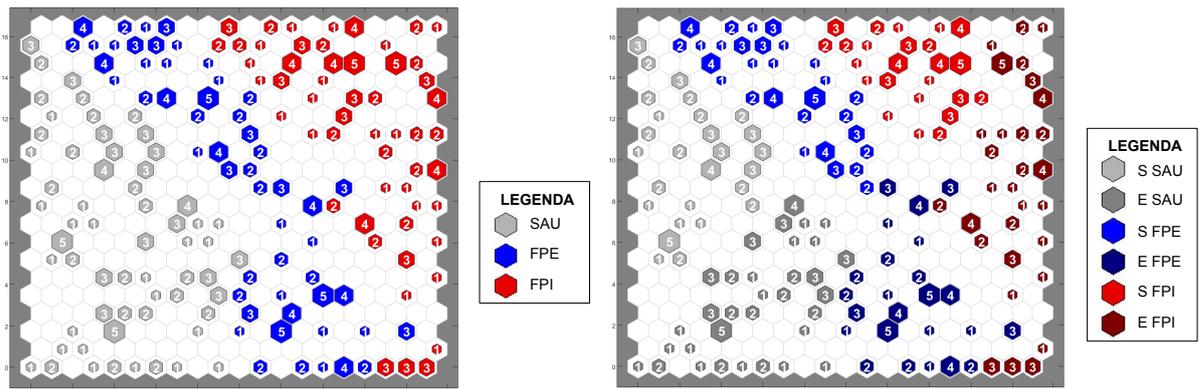


(a) Mapa sem a diferenciação entre dados simulados e experimentais (C15).

(b) Mapa com a diferenciação entre dados simulados e experimentais (C16).

Fonte: autoria própria (2023).

Figura 25 – Mapa auto-organizável de Kohonen do teste para motores de 1 CV na situação de multiclasses.



(a) Mapa sem a diferenciação entre dados simulados e experimentais (C15).

(b) Mapa com a diferenciação entre dados simulados e experimentais (C16).

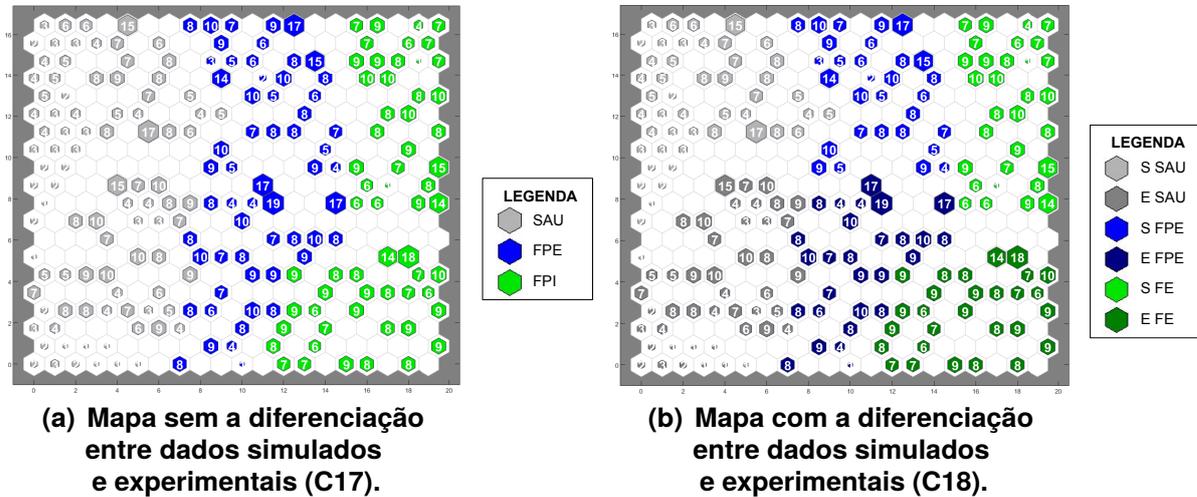
Fonte: autoria própria (2023).

5.2.1.2 Mapa de Kohonen: motores de 2 CV

Os 1800 dados do motor de 2 CV seguem a configuração da Tabela 10, em que 1440 foram treinados e 360 testados, seguindo validação cruzada. Após serem submetidos ao treinamento e ao teste de Kohonen, ativam os neurônios conforme mapas topológicos das Figuras 26 e 27. É válido ressaltar que não há amostras experimentais na condição FPI para o motor de 2 CV, logo esta falha não é analisada nesta situação. Como observado para o motor de 1 CV, os neurônios excitados por elementos da mesma condição do motor agrupam-se nos mesmos locais, formando regiões para cada

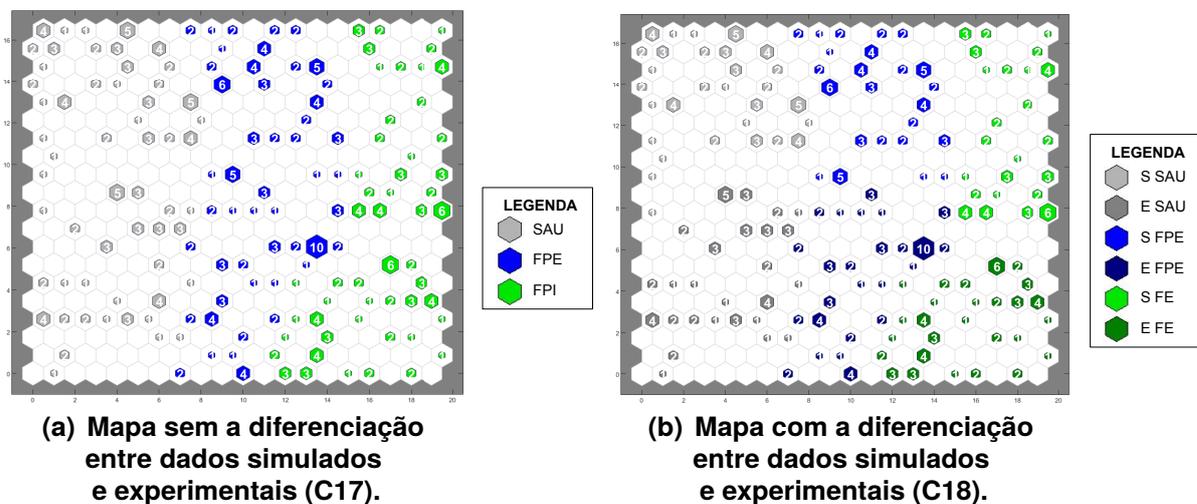
uma.

Figura 26 – Mapa auto-organizável de Kohonen do treinamento para motores de 2 CV na situação de multiclasses.



Fonte: autoria própria (2023).

Figura 27 – Mapa auto-organizável de Kohonen do teste para motores de 2 CV na situação de multiclasses.

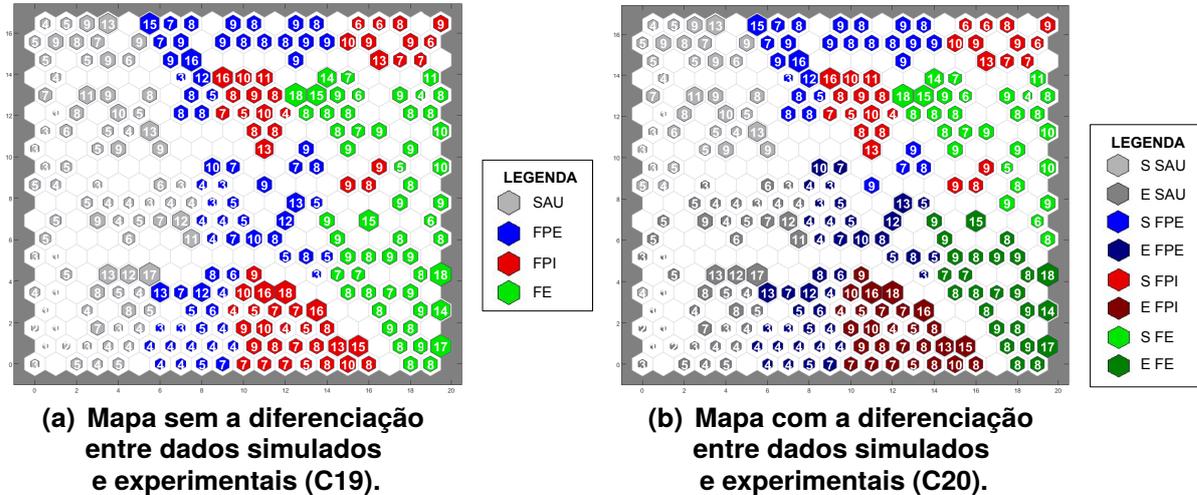


Fonte: autoria própria (2023).

5.2.1.3 Mapa de Kohonen: motores de 1 e 2 CV

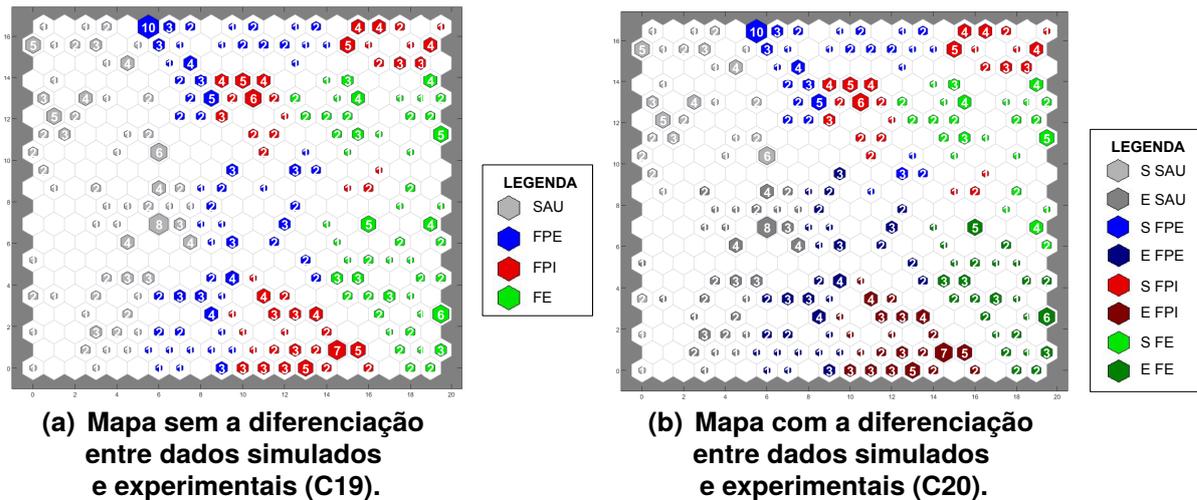
Combinando os conjuntos de 1 e 2 CV, a configuração da base de 2400 dados fica estabelecido como na Tabela 10, em que 1920 elementos são destinados ao treinamento e 480, ao teste. O treinamento e teste de Kohonen com esse conjunto geram os mapas topológicos das Figuras 28 e 29.

Figura 28 – Mapa auto-organizável de Kohonen do treinamento para motores de 1 e 2 CV na situação de multiclasses.



Fonte: autoria própria (2023).

Figura 29 – Mapa auto-organizável de Kohonen do teste para motores de 1 e 2 CV na situação de multiclasses.



Fonte: autoria própria (2023).

Embora as taxas para a situação 1+2 CV sejam superiores a 99,00% (Tabela 16), observa-se que, ao mesclar as bases de dados dos motores de diferentes potências, o algoritmo não clusteriza em região bem delimitada uma condição da máquina. As Subfiguras 28(a) e 29(a) evidenciam o surgimento de um único grupo para dados saudáveis, FPE e FE, mas quatro regiões para amostras FPI. Ao analisar a origem dos elementos nas Subfiguras 28(b) e 29(b), nota-se que os dados experimentais FPI estão em uma região bem delimitada, porém distantes dos dados simulados que representam a mesma condição. Analisando estes últimos, verifica-se que as falhas simuladas FPI estão em regiões que não possuem limites bem definidos. Já as outras condições se

agrupam em áreas com limites definidos, sendo que os dados de origem experimental ficam próximos ao de origem simulada.

5.2.2 Classificadores supervisionados

Do mesmo modo que na categorização em duas classes, quatro classificadores supervisionados são treinados e testados com amostras simuladas e experimentais combinadas de motores em quatro situações, porém dividindo em quatro classes: SAU, FPE, FPI e FE. A primeira e segunda situações envolvem a classificação de um banco de dados de motores de 1 e 2 CV de forma individual; o terceiro caso, a combinação dos conjuntos de amostras de 1 e 2 CV; e na quarta análise, dados de motores simulados de 1, 2, 5, 10, 20, 50, 100, 150 e 200 CV juntamente com o banco experimental de 1 e 2 CV foram utilizados. A quantidade de elementos envolvidos nas etapas de cada caso está estabelecida nas Tabelas 10 e 11 e a acurácia e o F_1 -score obtidos estão dispostos na Tabela 17.

Tabela 17 – Médias da Acurácia (A_c) e do F_1 -score de cinco testes das classificações supervisionadas para multiclases.

Índice	Motor (CV)	RF		kNN		PMC		SVM	
		A_c (%)	F_1 (%)						
C21	1	99,94	99,94	100,00	100,00	99,78	99,78	100,00	100,00
C22	2	100,00	100,00	66,67	55,56	99,72	99,72	99,94	99,94
C23	1+2	100,00	100,00	100,00	100,00	99,75	99,75	100,00	100,00
C24	1+2+5+10 20+50+100 150+200	100,00	100,00	100,00	100,00	98,89	98,89	99,89	99,89

Fonte: autoria própria (2023).

Os classificadores RF e SVM têm bom desempenho uma vez que, para as quatro situações analisadas, os índices atingidos são iguais ou superiores a 99,89%. A PMC também obtém taxas de acurácia e F_1 -score próximas a 100%, em que seu menor resultado é 98,89% para o caso C24 com diversos motores. O kNN apresenta 100% de acurácia e F_1 -score em três situações, no entanto essas taxas caem drasticamente para o caso do motor de 2 CV (C22).

A próxima análise contempla a seleção de atributos antes de classificar os dados. Conforme realizado para duas classes, três algoritmos de seleção são treinados para verificar a relevância dos atributos. As variáveis selecionadas por cada um estão na Tabela 18, bem como aquelas escolhidas pelos votos dos três algoritmos em conjunto.

Tabela 18 – Atributos selecionados por cada algoritmo e pelos três juntos para multiclases.

Índice	Motor (CV)	LASSO-CV	GB	RF	Selecionados pelos três
C25	1	1, 3, 5, 6, 7, 8, 9, 10, 12, 13, 14, 16, 17, 18, 19, 20, 23	4, 6, 7, 10, 11, 12, 15, 17, 20, 23	3, 4, 7, 8, 9, 10, 11, 12, 13, 15	7, 10, 12
C26	2	2, 3, 5, 6, 8, 9, 10, 12, 13, 14, 16, 19, 20, 22, 23	3, 6, 7, 9, 10, 13, 14, 15, 19, 22	3, 4, 7, 8, 9, 10, 11, 13, 15, 22	3, 9, 10, 13, 22
C27	1+2	2, 3, 4, 5, 6, 8, 9, 10, 11, 12, 13, 14, 15, 17, 18, 19, 21, 22, 23	2, 4, 7, 9, 10, 12, 15, 17, 21, 23	2, 4, 7, 9, 10, 12, 13, 17, 21, 23	2, 4, 9, 10, 12, 17, 21, 23
C28	1+2+5+10 20+50+100 150+200	1-23	1, 4, 7, 9, 10, 14, 15, 16, 22, 23	2, 6, 9, 10, 12, 13, 14, 15, 16, 22	9, 10, 14, 15, 16, 22

Fonte: autoria própria (2023).

Com os atributos selecionados, prossegue-se com as etapas de treinamento e teste com validação cruzada dos quatro classificadores supervisionados, cujos resultados alcançados estão dispostos na Tabela 19.

Tabela 19 – Médias da Acurácia (A_c) e do F_1 -score de cinco testes das classificações supervisionadas com seleção de atributos para multiclases.

Índice	Motor (CV)	RF		kNN		PMC		SVM	
		A_c (%)	F_1 (%)						
C25	1	99,89	99,89	99,78	99,78	91,50	91,46	99,78	99,78
C26	2	100,00	100,00	99,89	99,89	99,61	99,61	99,78	99,78
C27	1+2	100,00	100,00	100,00	100,00	97,71	97,70	99,88	99,87
C28	1+2+5+10 20+50+100 150+200	99,95	99,95	98,80	98,80	94,50	94,50	97,09	97,09

Fonte: autoria própria (2023).

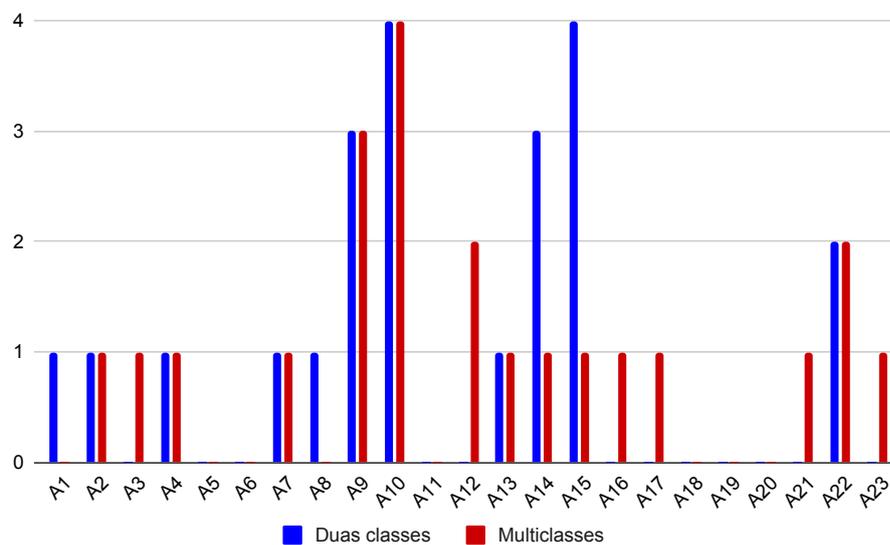
Com a seleção de atributos, reduzindo o custo computacional dos algoritmos, há uma pequena redução das taxas de acurácia e F_1 -score para os quatro classificadores, excetuando-se o caso do motor de 2 CV (C26) com o kNN, cujos resultados aumentam diante da outra classificação e ficam com um valor de 99,89%. Os acertos para o RF e SVM reduzem, porém a menor taxa atingida é acima de 97,09% (C28). A rede PMC é a mais afetada com a redução das entradas, com resultados entre 91,46% e 99,61%.

Analisando as classificações da Tabela 17, pode ser constatado que os dados simulados não prejudicam a categorização entre as quatro condições dos motores investigados, com exceção para o caso do motor de 2 CV com kNN. Por outro lado, a

seleção de atributos (Tabela 19) proporciona melhorias no resultado deste último caso. Pode-se dizer que a etapa de seleção de características apresenta bons resultados, próximos a 100%, para os classificadores RF, kNN e SVM.

Ademais, uma investigação é feita a respeito dos atributos selecionados para as oito análises da classificação supervisionada (duas classes e multiclases). O gráfico da Figura 30 apresenta o número de vezes que cada atributo é escolhido como relevante após o algoritmo de seleção ter sido treinado.

Figura 30 – Gráfico das ocorrências dos atributos nas oito classificações supervisionadas após seleção de atributos.



Fonte: autoria própria (2023).

Verifica-se que as instâncias A_5 , A_6 , A_{11} , A_{18} , A_{19} e A_{20} não são eleitas nenhuma vez; e os atributos A_1 , A_3 , A_8 , A_{16} , A_{17} , A_{21} e A_{23} , somente uma vez (ou para duas classes ou para multiclases). Realizando mais uma etapa de seleção, fazendo como critério a ocorrência de pelo menos duas vezes para as duas classificações (duas classes e multiclases), chega-se às variáveis A_9 (fator de compensação), A_{10} (fator de forma) e A_{22} (fator de assimetria da frequência), sendo as duas primeiras no domínio do tempo e a última, no domínio da frequência.

Nota-se que o fator de forma foi selecionado em todos os oito casos de classificação supervisionada, tanto para categorização em duas classes como para multiclases. O fator de compensação não foi escolhido em nenhuma situação com o motor de 1 CV; já o fator de assimetria da frequência foi selecionado para os casos C12 e C13 (duas classes) e para C26 e C28 (multiclases).

Outra análise que pode ser realizada é que houve um atributo que foi selecionado em dois casos (C25 e C27) na situação com multiclases porém em nenhum caso na situação com duas classes, que é a potência espectral média (A_{12}). De forma análoga, as características A_{14} e A_{15} (fator de assimetria e kurtosis da potência espectral) foram relevantes para a classificação em duas classes em quase todos os casos (C11 a C14), porém somente para um caso (C28) na classificação em multiclases.

Com o intuito de chegar no classificador supervisionado mais adequado às análises de duas classes e multiclases, faz-se um resumo daqueles com maiores índices para a base de dados da terceira e quarta análise com seleção de atributos (C13, C14, C27 e C28), objetivando-se uma observação mais generalista e sem tendências. A Tabela 20 apresenta essa síntese.

Tabela 20 – Classificadores supervisionados com melhores desempenhos para as análises realizadas na terceira e quarta situações com seleção de atributos.

Índice	Análise	Classificador	A_c (%)	F_1 (%)
C13		RF/SVM	100,00	100,00
C14	Duas classes	1+2+5+10	RF	99,97
		20+50+100		
C27		150+200	RF/kNN	100,00
		1+2		
C28	Multiclases	1+2+5+10	RF	99,95
		20+50+100		
		150+200		

Fonte: autoria própria (2023).

Nota-se que, para a terceira situação, em que os motores de 1 e 2 CV simulados e experimentais são analisados em conjunto, mais de um classificador atinge 100,00% de acurácia e F_1 -score para duas classes e multiclases. Adicionando a essa base de dados amostras simuladas de 5, 10, 20, 50, 100, 150 e 200 CV, com o objetivo de tornar o sistema mais robusto e generalista, o classificador RF apresenta os melhores resultados, acima de 99,95%, para os dois tipos de classificação. Assim, pode-se inferir que as simulações podem ser incrementadas à base de dados sem prejudicar a categorização entre as condições do MIT.

6 CONCLUSÕES

A modelagem das falhas localizadas de rolamento levando em consideração a variação das reatâncias indutivas do MIT permite a geração de um banco de dados de corrente de uma fase do estator que reproduz as diversas situações obtidas experimentalmente em uma bancada de testes.

Após submeter características estatísticas extraídas dos domínios do tempo e da frequência de cada amostra de corrente, proveniente tanto da simulação quanto dos experimentos, aos classificadores de padrões RF, kNN, PMC, SVM e à rede de Kohonen, estes apresentam resultados promissores. Os algoritmos são capazes de discernir amostras de motores saudáveis e de motores com falhas de rolamento e em agrupá-las em regiões diferentes para as duas condições do motor, quando analisada a classificação em duas classes, e para quatro condições, ao realizar a categorização em multiclases, com taxas de acurácia e F_1 -score acima de 98,00% (excetuando-se a classificação em multiclases do motor de 2 CV com o kNN).

Embora as medidas de desempenho tenham uma pequena redução ao se aplicar a seleção de atributos, pode-se dizer que os desempenhos continuam satisfatórios para os classificadores, uma vez que se reduz o custo computacional e a acurácia é superior a 96,00% (excetuando-se os resultados com a PMC na categorização em multiclases, em que a menor taxa foi aproximadamente 92,00%). Os atributos mais relevantes são dois no domínio do tempo e um no da frequência, sendo eles fator de compensação (A_9), fator de forma (A_{10}) e fator de assimetria da frequência (A_{22}).

Ademais, a adição de amostras simuladas de outros motores (5, 10, 20, 50, 100, 150 e 200 CV) não interfere drasticamente no aprendizado dos classificadores, visto que as taxas tiveram uma pequena redução em seus valores. Contudo, essa inserção de dados diferentes pode tornar os classificadores mais robustos e também mais generalistas, uma vez que foram treinados a partir de amostras de motores de diversas potências.

Portanto, uma vez que a proposta deste trabalho é implementar o modelo do MIT com falhas localizadas de rolamento que forneça dados de corrente simulados para complementar um banco de dados experimental, pode-se dizer que o modelo é validado diante das altas taxas obtidas com as classificações. Os agrupamentos dos dados artificiais e experimentais que representam as mesmas condições da máquina

nos mapas de Kohonen podem indicar que o modelo proposto está próximo da realidade e os resultados obtidos com os classificadores supervisionados, principalmente com o RF apontam que as amostras simuladas não interferem no aprendizado dos algoritmos para o diagnóstico de falhas.

6.1 TRABALHOS FUTUROS

Visto que o modelo proposto no presente trabalho é validado, sua contribuição é relevante para o diagnóstico de falhas de rolamento no MIT e, assim, futuras investigações podem ser feitas para aprimorar o conteúdo dessa pesquisa. Sugerem-se então os seguintes futuros trabalhos:

- Explorar outras metodologias de extração de características, como no domínio tempo-frequência (DWT, STFT, Transformada de Wigner-Ville e Transformada de Hilbert-Huang);
- Investigar outras técnicas de seleção de atributos (baseadas em filtro ou do tipo embutido);
- Averiguar o desempenho das categorizações com outros algoritmos de classificação (Naive Bayes gaussiano, AdaBoost, *Linear discriminant analysis*, *Histogram-based Gradient Boosting*, entre outros);
- Avaliar outras metodologias de modelagem de motores de indução com falhas;
- Expandir o modelo para outras falhas do MIT;
- Embarcar em *hardware* o classificador oriundo dos treinamentos e testes realizados com os bancos de dados simulado e experimental para monitoramento online do MIT.

REFERÊNCIAS

- ALI, M. Z. *et al.* Machine Learning-Based Fault Diagnosis for Single and Multi-Faults in Induction Motors Using Measured Stator Currents and Vibration Signals. **IEEE Transactions on Industry Applications**, v. 55, n. 3, p. 2378–2391, 2019.
- AVIÑA-CORRAL, V. *et al.* Bearing Fault Detection in Adjustable Speed Drive-Powered Induction Machine by Using Motor Current Signature Analysis and Goodness-of-Fit Tests. **IEEE Transactions on Industrial Informatics**, v. 17, n. 12, p. 8265–8274, 2021.
- BALDERSTON, H. L. The detection of incipient failure in bearings. **Material Evaluation**, v. 27, p. 121–128, 1969.
- BAZAN, G. H. **Identificação inteligente de falhas em máquinas elétricas utilizando informação mútua**. 2020. 156 f. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/25597>. Acesso em: 10 ago. 2022.
- BAZAN, G. H. *et al.* Information Theoretical Measurements From Induction Motors Under Several Load and Voltage Conditions for Bearing Faults Classification. **IEEE Transactions on Industrial Informatics**, v. 16, n. 6, p. 3640–3650, 2020.
- BESSOUS, N. *et al.* Diagnosis of bearing defects in induction motors using discrete wavelet transform. **International Journal of System Assurance Engineering and Management**, v. 9, n. 2, p. 335–343, 2018.
- BLÖDT, M. *et al.* Models for Bearing Damage Detection in Induction Motors Using Stator Current Monitoring. **IEEE Transactions on Industrial Electronics**, v. 55, n. 4, p. 1813–1822, 2008.
- BREIMAN, L. *et al.* **Classification and Regression Trees**. 1. ed. Nova York, NY, EUA: Taylor & Francis, 1984.
- BRONIERA, P. J. **Diagnóstico de curto-circuito no enrolamento de estator em máquinas de indução trifásicas utilizando redes neurais artificiais**. 2014. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR.
- CAVERO, V. F. *et al.* A Comparison of Techniques for Fault Detection in Inverter-Fed Induction Motors in Transient Regime. **IEEE Access**, v. 5, p. 8048–8063, 2017.
- CHEN, S.; ZIVANOVIC, R. Modelling and simulation of stator and rotor fault conditions in induction machines for testing fault diagnostic techniques. **European Transactions on Electrical Power**, p. 611–629, 2010.

CHOUDHARY, A.; MIAN, T.; FATIMA, S. Convolutional neural network based bearing fault diagnosis of rotating machine using thermal images. **Measurement**, v. 176, p. 109196, 2021.

ELBOUCHIKHI, E. *et al.* An Efficient Hilbert–Huang Transform-Based Bearing Faults Detection in Induction Machines. **IEEE Transactions on Energy Conversion**, v. 32, n. 2, p. 401–413, 2017.

ELETROBRAS. **Resultados PROCEL 2021: ano-base 2020**. [S. l.], 2021. Disponível em: <http://www.procelinfo.com.br/resultadosprocel2021/>. Acesso em: 3 nov. 2021.

FACELI, K. *et al.* **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**. 2. ed. Rio de Janeiro, RJ, Brasil: LTC, 2011.

FERRERO, C. A. **Algoritmo kNN para previsão de dados temporais: funções de previsão e critérios de seleção de vizinhos próximos aplicados a variáveis ambientais em limnologia**. 2009. 103 f. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação - ICMC-USP, São Carlos, SP.

FITZGERALD, A. E.; KINGSLEY, C. **Electric Machinery**. 6. ed. Nova York, NY, EUA: McGraw-Hill, 2003.

FROSINI, L. Novel Diagnostic Techniques for Rotating Electrical Machines - A Review. **Energies**, v. 13, n. 19, p. 5066, 2020.

FROSINI, L.; HARLISCA, C.; SZABÓ, L. Induction Machine Bearing Fault Detection by Means of Statistical Processing of the Stray Flux Measurement. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1846–1854, 2015.

GANGSAR, P.; TIWARI, R. Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. **Mechanical Systems and Signal Processing**, v. 144, p. 106908, 2020.

GODOY, W. F. **Multiclassificador Inteligente de Falhas no Domínio do Tempo em Motores de Indução Trifásicos Alimentados por Inversores de Frequência**. 2016. 162 f. Tese (Doutorado em Ciências) – Programa de Engenharia Elétrica da Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, SP. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18153/tde-03062016-111024/pt-br.php>. Acesso em: 4 dez. 2022.

GOEDEL, A. **Estimador neural de velocidade para motores de indução trifásicos**. 2007. 159 f. Tese (Doutorado em Engenharia Elétrica) – Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, SP. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18153/tde-18122007-204855/pt-br.php>. Acesso em: 20 jun. 2021.

GONGORA, W. S. **Identificação de Falhas Elétricas em Motores de Indução Trifásicos por Injeção de Sinal de Referência**. 2019. 100 f. Tese (Doutorado em Ciências) – Programa de Engenharia Elétrica da Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, SP. Disponível em: <https://teses.usp.br/teses/disponiveis/18/18153/tde-10092019-104925/pt-br.php>. Acesso em: 5 dez. 2022.

GONGORA, W. S. **Uma abordagem neural no diagnóstico de falhas em rolamentos de motores de indução trifásicos**. 2013. 97 f. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/782>. Acesso em: 14 mar. 2022.

GUEDES, J. J. **Identificação de Falhas em Motores de Indução Trifásicos Utilizando Algoritmos de Otimização e Sistemas Inteligentes**. 2019. 147 f. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR. Disponível em: <https://repositorio.utfpr.edu.br/jspui/handle/1/5436>. Acesso em: 10 dez. 2022.

GULDEMIR, H. Detection of airgap eccentricity using line current spectrum of induction motors. **Electric Power Systems Research**, v. 64, n. 2, p. 109–117, 2003.

GUYON, I.; WESTON, J.; BARNHILL, S. Gene Selection for Cancer Classification using Support Vector Machines. **Machine Learning**, v. 46, p. 389–422, 2002.

HAROUN, S.; SEGHIR, A. N.; TOUATI, S. Multiple features extraction and selection for detection and classification of stator winding faults. **IET Electric Power Applications**, v. 12, p. 339–346, 2018.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2. ed. [S. l.]: Springer, 2009.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Upper Saddle River, NJ, EUA: Springer, 2009.

HELMI, H.; FOROUZANTABAR, A. Rolling bearing fault detection of electric motor using time domain and frequency domain features extraction and ANFIS. **IET Electric Power Applications**, v. 3, n. 5, p. 662–669, 2019.

HUSNA, A.; INDRIAWATI, K.; WIDJANTORO, B. L. Discriminant Feature Extraction of Motor Current Signal Analysis and Vibration For Centrifugal Pump Fault Detection. In: INTERNATIONAL CONFERENCE ON INSTRUMENTATION, CONTROL, AND AUTOMATION (ICA), ago. 2021, Bandung, Indonésia. **Proceedings [...]**. [S. l.]: IEEE, 2021. KKI&K, p. 207–212.

- IMMOVILLI, F. *et al.* Bearing Fault Model for Induction Motor With Externally Induced Vibration. **IEEE Transactions on Industrial Electronics**, v. 60, n. 8, p. 3408–3418, 2013.
- INCE, T. *et al.* Early Bearing Fault Diagnosis of Rotating Machinery by 1D Self-Organized Operational Neural Networks. **IEEE Access**, v. 9, p. 139260–139270, 2021.
- JAMES, G. *et al.* **An Introduction to Statistical Learning: with Applications in R**. 1. ed. [S. l.]: Springer, 2013.
- JAWADEKAR, A. *et al.* Artificial neural network-based induction motor fault classifier using continuous wavelet transform. **Systems Science & Control Engineering: An Open Access Journal**, v. 2, n. 1, p. 684–690, 2014.
- JUPYTER. **Jupyter Notebook**. [S. l.: s. n.], 2023. Project Jupyter. Disponível em: <https://jupyter.org/>. Acesso em: 8 fev. 2023.
- KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, p. 59–69, 1982.
- KOTSIANTIS, S. B.; PINTELAS, P. E. Induction Machine Fault Detection and Classification Using Non-Parametric, Statistical-Frequency Features and Shallow Neural Networks. **Annals of Mathematics, Computing & Teleinformatics**, v. 1, n. 1, p. 46–55, 2003.
- KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. 1. ed. [S. l.]: Springer, 2013.
- KULKARNI, A.; CHONG, D.; BATARSEH, F. A. Foundations of data imbalance and solutions for a data democracy. In: **Data Democracy: At the Nexus of Artificial Intelligence, Software Development, and Knowledge Engineering**. Edição: Feras A. Batarseh e Ruixin Yang. [S. l.]: Academic Press, 2020. cap. 5.
- LANNOO, J. *et al.* Improved air gap permeance model to characterise the transient behaviour of electrical machines using magnetic equivalent circuit method. **International Journal of Numerical Modelling: Electronic Networks, Devices and Fields**, v. 33, n. 5, 33:e2749, 2020.
- LI, C.; MO, L.; YAN, R. Fault Diagnosis of Rolling Bearing Based on WHVG and GCN. **IEEE Transactions on Instrumentation and Measurement**, v. 70, p. 1–11, 2021.
- MARMOUCH, S.; AROUI, T.; KOUBAA, Y. Statistical Neural Networks for Induction Machine Fault Diagnosis and Features Processing Based on Principal Component Analysis. **IEEE Transactions on Electrical and Electronic Engineering**, v. 16, p. 307–314, 2021.
- MARTINEZ, J.; BELAHCEN, A.; DETONI, J. A 2D magnetic and 3D mechanical coupled finite element model for the study of the dynamic vibrations in the stator of induction motors. **Mechanical Systems and Signal Processing**, v. 66-67, p. 640–656, 2016.

NAVASARI, E.; ASFANI, D. A.; NEGARA, M. Y. Detection Of Induction Motor Bearing Damage With Starting Current Analysis Using Wavelet Discrete Transform And Artificial Neural Network. In: 10TH INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY AND ELECTRICAL ENGINEERING (ICITEE), jul. 2018, Bali, Indonésia. **Proceedings [...]**. [S. l.]: IEEE, 2018. Universitas Gadjah Mada e King Mongkut's Institute of Technology Ladkrabang, p. 316–319.

OJAGHI, M.; SABOURI, M.; FAIZ, J. Analytic Model for Induction Motors Under Localized Bearing Faults. **IEEE Transactions on Energy Conversion**, v. 33, n. 2, p. 617–626, 2018.

ONG, C.-M. **Dynamic Simulation of Electric Machinery**: using Matlab/Simulink. 1. ed. Upper Saddle River, NJ, EUA: Prentice Hall, 1998.

PALÁCIOS, R. H. C.; GODOY, W. F. *et al.* Time domain diagnosis of multiple faults in three phase induction motors using intelligent approaches. In: IEEE 11TH INTERNATIONAL SYMPOSIUM ON DIAGNOSTICS FOR ELECTRICAL MACHINES, POWER ELECTRONICS AND DRIVES (SDEMPED), set. 2017, Tinos, Grécia. **Proceedings [...]**. [S. l.]: IEEE, 2017. University of Bologna, p. 85–89.

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

PALÁCIOS, R. H. C. **Aplicação de Técnicas Inteligentes com Análise no Domínio do Tempo para Reconhecimento de Defeitos em Motores de Indução Trifásicos**. 2016. 187 f. Tese (Doutorado em Ciências) – Programa de Engenharia Elétrica da Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, SP. Disponível em: <https://teses.usp.br/teses/disponiveis/18/18153/tde-03062016-110622/fr.php>. Acesso em: 4 dez. 2022.

PRINCE; HATI, A. S. A comprehensive review of energy-efficiency of ventilation system using Artificial Intelligence. **Renewable and Sustainable Energy Reviews**, v. 146, p. 111153, 2021.

QUINLAN, J. R. **C4.5: Programs for Machine Learning**. 1. ed. San Mateo, CA, EUA: Morgan Kaufmann Publishers, Inc., 1993.

QUINLAN, J. R. Discovering Rules by Induction from Large Collections of Examples. **Expert Systems in the Microelectronic Age**, p. 168–201, 1979.

RANDALL, R. B.; ANTONI, J. Rolling element bearing diagnostics — A tutorial. **Mechanical Systems and Signal Processing**, v. 25, p. 485–520, 2011.

REZAEI-ALAM, F.; REZAEI-ALAM, B. An enhanced analytical technique based on winding function theory for analysis of induction motors. **International Transactions on Electrical Energy Systems**, v. 31, n. 5, :e12863, 2021.

- ROBLES, E. *et al.* Advanced power inverter topologies and modulation techniques for common-mode voltage elimination in electric motor drive systems. **Renewable and Sustainable Energy Reviews**, v. 140, p. 110746, 2021.
- SANTOS, H. *et al.* Non-invasive sound-based classifier of bearing faults in electric induction motors. **IET Science, Measurement & Technology**, v. 15, p. 434–445, 2021.
- SAPENA-BANO, A. *et al.* Induction machine model with finite element accuracy for condition monitoring running in real time using hardware in the loop system. **Electrical Power and Energy Systems**, v. 111, p. 315–324, 2019.
- SAUER, I. L. *et al.* A comparative assessment of Brazilian electric motors performance with minimum efficiency standards. **Renewable and Sustainable Energy Reviews**, v. 41, p. 308–318, 2015.
- SILVA, I. N. da *et al.* **Artificial Neural Networks: A Practical Course**. 1. ed. [S. l.]: Springer, 2017.
- SIMULINK. **Three-Phase Asynchronous Machine**. [S. l.: s. n.], 2022. MATLAB & Simulink Documentation. Disponível em: <https://www.mathworks.com/help/sps/ug/three-phase-asynchronous-machine.html>. Acesso em: 15 ago. 2022.
- SINGH, S.; KUMAR, N. Detection of Bearing Faults in Mechanical Systems Using Stator Current Monitoring. **IEEE Transactions on Industrial Informatics**, v. 13, n. 3, p. 1341–1349, 2017.
- SKF. **Rolamentos rígidos de esferas**. [S. l.: s. n.], 2022. SKF Produtos. Disponível em: <https://www.skf.com/br/products/rolling-bearings/ball-bearings/deep-groove-ball-bearings>. Acesso em: 24 nov. 2022.
- TERRON-SANTIAGO, C. *et al.* A Review of Techniques Used for Induction Machine Fault Modelling. **Sensors**, v. 21, n. 14, p. 4855, 2021.
- TOMA, R. N.; PROSVIRIN, A. E.; KIM, J.-M. Bearing Fault Diagnosis of Induction Motors Using a Genetic Algorithm and Machine Learning Classifiers. **Sensors**, v. 20, n. 7, p. 1884, 2020.
- WEG. **Motores W22**. [S. l.: s. n.], 2022. W22 - WEG Produtos. Disponível em: https://www.weg.net/catalog/weg/BR/pt/c/BR_MT_3PHASE_LV_W22_IR3/list. Acesso em: 23 nov. 2022.
- YUAN, L. *et al.* Rolling Bearing Fault Diagnosis Based on Convolutional Neural Network and Support Vector Machine. **IEEE Access**, v. 8, p. 137395–137406, 2020.
- ZHANG, J. *et al.* Intelligent fault diagnosis of rolling bearings using variational mode decomposition and self-organizing feature map. **Journal of Vibration and Control**, v. 26, n. 21-22, p. 1886–1897, 2020.

ZHANG, S. *et al.* Model-Based Analysis and Quantification of Bearing Faults in Induction Machines. **IEEE Transactions on Industry Applications**, v. 56, n. 3, p. 2158–2170, 2020.