

Diagnóstico de Falhas de Rolamento em Motores de Indução Trifásicos a partir de um Modelo Matemático

Carolina A. Bianchini* Marcelo Favoretto Castoldi*
Alessandro Goedel*

* Programa De Pós-Graduação Em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, PR, (e-mail: carolinabianchini@alunos.utfpr.edu.br; marcastoldi@utfpr.edu.br; agoedel@utfpr.edu.br).

Abstract: The wide use of three-phase induction motors (TIM) in various industry sectors encourages the search for techniques for monitoring and diagnosing defects in these machines to avoid production stops and unforeseen maintenance. Bearing fault detection is performed by analyzing the behavior of some motor variables, such as vibration and stator current, and their classification using artificial intelligence and machine learning. 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 loads and speeds. Therefore, this work aims to implement a model for TIM's bearing failure simulations in dq0 reference that provides current data of a stator phase to analyze this frequency spectrum. From information extracted from this spectrum, 200 samples representing different TIM situations with bearing failures are submitted to two pattern classifiers, Multilayer Perceptron network and Kohonen network, to validate the proposed diagnostic method.

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. A detecção de falhas em rolamento pode ser efetuada por meio da análise do comportamento de algumas variáveis do motor, como vibração e corrente do estator, e sua classificação realizada a partir de inteligência artificial e aprendizado de máquina. Porém, há poucos estudos sobre a modelagem e simulação dessas falhas, a qual se apresenta como um recurso viável para abranger diversos motores e condições específicas de funcionamento, como diferentes cargas e velocidades. Logo, este trabalho busca construir um modelo para simulações de falhas de rolamento no MIT na referência dq0 que forneça dados de corrente de uma fase do estator para análise do seu espectro de frequências. A partir de informações extraídas desse espectro, 200 amostras que representam diversas situações do MIT com falhas de rolamento são submetidas a dois classificadores de padrões, rede Perceptron Multicamadas e rede de Kohonen, a fim de validar o método de diagnóstico proposto.

Keywords: Three-phase induction motor; modeling and simulation; bearing fault; frequency spectrum; pattern classification.

Palavras-chaves: Motor de indução trifásico; modelagem e simulação; falhas de rolamento; espectro de frequências; classificação de padrões.

1. INTRODUÇÃO

O motor de indução trifásico (MIT) é amplamente utilizado em diversas áreas da indústria devido ao seu baixo custo, robustez, facilidade de controle e eficiência. Embora possua alta confiabilidade, o MIT está sujeito a falhas, tornando-se necessários investimentos em técnicas de monitoramento e diagnóstico dessas máquinas para evitar paradas inesperadas, perdas de produção e aumento de custo.

As falhas no MIT ocorrem geralmente em três componentes principais: estator, rotor e rolamentos (Gangsar and

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 and Tiwari, 2020; Terron-Santiago et al., 2021).

Operando em condições normais com carga nominal e bom alinhamento, as falhas no rolamento devido ao uso surgem com pequenas fissuras nas pistas que podem evoluir para descamações e fragmentações e se propagar, gerando vibra-

ções, 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. Há diversas abordagens para o reconhecimento de má operação das máquinas, como monitoramento do campo magnético e vibrações, 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. No entanto, ambas 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). 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 utilizar a MCSA para obtenção de dados. Outros estudos também fizeram essa escolha como Toma et al. (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*), *Decision Tree* e *Random Forest*. Já o trabalho de Singh and Kumar (2017) utiliza Transformada de Wavelet Contínua no sinal de corrente do estator e Elbouchikhi et al. (2017), as técnicas de decomposição em modos empíricos e Transformada Hilbert-Huang no sinal de corrente para detectar de forma eficiente as falhas de rolamento.

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 d-q), circuitos magnéti-

cos, métodos de elementos finitos (FEM - do inglês, *Finite Element Method*) e métodos híbridos, que combinam as técnicas mencionadas (Terron-Santiago et al., 2021).

Embora os modelos baseados em circuitos magnéticos e em métodos de elementos finitos, como os realizados por Lannoo et al. (2020) e Sapena-Bano et al. (2019), 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 com essa última técnica, usando o referencial d-q, como o trabalho de Zhang et al. (2020b). Ele 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. Já Ojaghi et al. (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*).

Os dois últimos trabalhos baseiam-se na modelagem proposta por Blödt et al. (2008), cujo trabalho é de grande contribuição científica. O estudo de Blödt et al. (2008) 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 verificação, 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 dq0. Mediante a inserção de variações na indutância do MIT, serão simulados três tipos de falhas de rolamento: nas pistas externa e interna e nas esferas. A partir da análise do espectro de frequências da corrente de uma fase do estator, picos de frequências relacionadas às características e seus módulos serão selecionados para configurarem os atributos de 200 amostras. Estas, por sua vez, serão utilizadas em dois classificadores de padrões, um supervisionado (PMC) e outro não-supervisionado (rede de Kohonen), de modo a validar a diferença entre as falhas e avaliar o método de simulação proposto.

2. FALHAS DE ROLAMENTO NO MIT

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 levará 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.

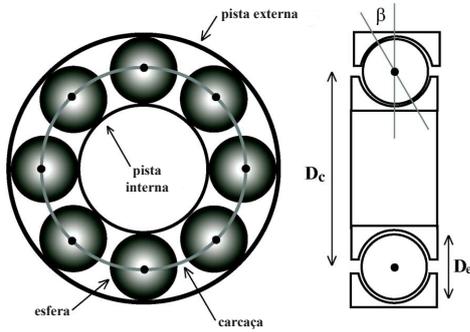


Figura 1. Geometria do rolamento (adaptado de Blödt et al. (2008)).

Tais frequências características de vibração f_c , que podem ser devido a falhas na pista externa (f_{ext}), na pista interna (f_{int}) ou nas esferas internas (f_{esf}), são calculadas por (1), (2) e (3) (Blödt et al., 2008):

Falhas na pista externa:

$$f_{ext} = \frac{N_e}{2} f_r \left(1 - \frac{D_e}{D_c} \cos\beta\right), \quad (1)$$

Falhas na pista interna:

$$f_{int} = \frac{N_e}{2} f_r \left(1 + \frac{D_e}{D_c} \cos\beta\right), \quad (2)$$

Falhas nas esferas:

$$f_{esf} = \frac{D_c}{D_e} f_r \left(1 - \frac{D_e^2}{D_c^2} \cos^2\beta\right), \quad (3)$$

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 , o ângulo de contato entre a esfera e a carcaça e f_r , a frequência de rotação.

Analisando a perturbação em si, é dito que 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 , e o mesmo pode ser expresso em função do tempo t e da posição angular θ da falha no referencial do estator. As variações no entreferro podem ser descritas matematicamente como em (4) (Blödt et al., 2008):

$$g_c(\theta, t) = g_0 \left[1 - e \cdot \cos(\theta + \psi(t)) \sum_{k=-\infty}^{k=+\infty} \delta\left(t - \frac{k}{f_c}\right) \right], \quad (4)$$

em que g_c representa o novo comprimento do entreferro, g_0 , o comprimento do entreferro na situação normal; e é o grau de excentricidade relativa e k 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 (5) (Blödt et al., 2008):

$$w_{cr} = \frac{1}{2} w_r \left(1 - \frac{D_e}{D_c} \cos\beta\right). \quad (5)$$

Além disso, a variação do comprimento do entreferro g_c influencia a variação da permeância, uma vez que são inversamente proporcionais entre si. A permeância, por sua vez, está relacionada à indutância da máquina. Logo, pode-se assumir o estabelecido em (6):

$$L_c(\theta, t) = L_0 \cdot \frac{1}{1 - e \cdot \cos(\theta + \psi(t)) \sum_{k=-\infty}^{k=+\infty} \delta\left(t - \frac{k}{f_c}\right)}, \quad (6)$$

onde L_c é o novo valor da indutância e L_0 a indutância 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. Logo, 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 na Tabela 1:

Tabela 1. Frequências no espectro do estator devido a falhas (Blödt et al., 2008)

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

Neste trabalho, a variação da indutância será inserida na simulação do motor no Simulink para que se possa analisar a presença da falha através do espectro de frequências da corrente de uma fase do estator. Caso as frequências descritas na Tabela 1 sejam detectadas no espectro com uma magnitude acima de um valor mínimo estipulado, poderá ser concluído que a máquina possui a falha.

Assim, essas frequências e suas magnitudes serão os atributos de entrada da amostra a ser submetida a dois classificadores de padrão, que servem para validar a diferença entre as falhas, a modelagem e simulação propostas. Dessa forma, na próxima seção, serão abordados os principais conceitos dos dois classificadores de padrão a serem utilizados no trabalho.

3. CLASSIFICADORES DE PADRÕES

Nesta seção, será apresentada uma breve descrição sobre os classificadores de padrões utilizados neste trabalho, a rede Perceptron Multicamadas (PMC) e a rede auto-organizável de Kohonen. As duas possuem treinamentos diferentes entre si, sendo a primeira caracterizada por um treinamento supervisionado e a segunda, não-supervisionado.

As amostras de entrada para os dois classificadores serão os valores e módulos de frequências relacionadas às frequências características, conforme descritas na Tabela 1.

3.1 Rede Perceptron Multicamadas

A 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).

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 y de cada neurônio j pode ser calculada por (7) (Silva et al., 2017), em que $\mathbf{x} = \{x_1, x_2, \dots, x_M\}$ é o vetor de k amostras de entrada dos neurônios de determinada camada, M é a dimensão das amostras, w_j é o peso associado ao neurônio j , θ é o limiar e $g(\cdot)$ é a função de ativação do neurônio.

$$y_j(k) = g \left(\sum_{i=1}^M x_i(k) \cdot w_{ji} + \theta_j \right). \quad (7)$$

Em seguida, na fase *backward*, um sinal de erro E (resultante da diferença entre a saída desejada d e a gerada y) é propagado de forma reversa, da saída à entrada, para ajuste dos pesos e limiares de cada neurônio j , conforme (8) (Silva et al., 2017):

$$E(k) = \frac{1}{2} \sum_{j=1}^n (d_j(k) - y_j(k))^2. \quad (8)$$

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

3.2 Redes Auto-organizáveis de Kohonen

Utilizadas para classificar as falhas de rolamento extraídas dos sinais de vibração dos rolamentos por Zhang et al. (2020a), 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):

$$\begin{cases} \mathbf{w}^{(v)} \leftarrow \mathbf{w}^{(v)} + \eta \cdot (\mathbf{x}^{(k)} - \mathbf{w}^{(v)}) \\ \mathbf{w}^{(\Omega)} \leftarrow \mathbf{w}^{(\Omega)} + \frac{\eta}{2} \cdot (\mathbf{x}^{(k)} - \mathbf{w}^{(\Omega)}) \end{cases} \quad (9)$$

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

4. METODOLOGIA

O estudo foi realizado em quatro etapas: modelagem, simulação, extração de características e classificação de padrões. Para as três últimas etapas, o ambiente Simulink /MATLAB[®] foi utilizado como ferramenta para criação do projeto com base no modelo matemático do MIT com falhas de rolamento, processamento e classificação de cada simulação.

4.1 Modelo matemático do MIT com falhas

O equacionamento do motor de indução trifásico é transformado para a referência dq0 estacionária, de forma a facilitar a manipulação das equações, uma vez que, no sistema de referência trifásico, a máquina é descrita por seis equações diferenciais de primeira ordem com indutâncias variantes no tempo. Já na referência escolhida, essas variáveis são constantes. Logo, as tensões dos enrolamentos do estator, v_e , e rotor referenciado ao estator, v'_r , são representadas pelas equações em (10) (Ong, 1998):

$$\begin{aligned} v_{qe} &= \frac{p}{w_b} \Psi_{qe} + r_e i_{qe}, \\ v_{de} &= \frac{p}{w_b} \Psi_{de} + r_e i_{de}, \\ v_{0e} &= \frac{p}{w_b} \Psi_{0e} + r_e i_{0e}, \\ v'_{qr} &= \frac{p}{w_b} \Psi'_{qr} - \frac{w_r}{w_b} \Psi'_{dr} + r'_r i'_{qr}, \\ v'_{dr} &= \frac{p}{w_b} \Psi'_{dr} + \frac{w_r}{w_b} \Psi'_{qr} + r'_r i'_{dr}, \\ v'_{0r} &= \frac{p}{w_b} \Psi'_{0r} + r'_r i'_{0r}, \end{aligned} \quad (10)$$

em que os subscritos q , d e 0 indicam os eixos "q" e "d" e a seqüência zero, p é o operador diferencial $\frac{d}{dt}$, r_e e r'_r são as resistências do estator e rotor referido ao estator, i_e e i'_r , as correntes do estator e rotor referido ao estator, respectivamente. Já w_b é a frequência angular de base, calculado por (11):

$$w_b = 2\pi f_s, \quad (11)$$

onde f_s é a frequência síncrona. As variáveis Ψ_e e Ψ'_r indicam os fluxos concatenados por segundo no estator e rotor referido ao estator, calculados por (12):

$$\Psi = w_b \lambda, \quad (12)$$

em que λ é o fluxo concatenado. Os valores de Ψ_e e Ψ'_r são obtidos pela equação (13) (Ong, 1998):

$$\begin{bmatrix} \Psi_{qe} \\ \Psi_{de} \\ \Psi_{0e} \\ \Psi'_{qr} \\ \Psi'_{dr} \\ \Psi'_{0r} \end{bmatrix} = \begin{bmatrix} x_{lem} & 0 & 0 & x_m & 0 & 0 \\ 0 & x_{lem} & 0 & 0 & x_m & 0 \\ 0 & 0 & x_{le} & 0 & 0 & 0 \\ x_m & 0 & 0 & x'_{lrm} & 0 & 0 \\ 0 & x_m & 0 & 0 & x'_{lrm} & 0 \\ 0 & 0 & 0 & 0 & 0 & x'_{lr} \end{bmatrix} \begin{bmatrix} i_{qe} \\ i_{de} \\ i_{0e} \\ i'_{qr} \\ i'_{dr} \\ i'_{0r} \end{bmatrix}, \quad (13)$$

sendo:

$$x_{lem} = x_{le} + x_m, \quad (14)$$

$$x'_{lrm} = x'_{lr} + x_m. \quad (15)$$

As variáveis x_{le} 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 (16):

$$x = w_b L, \quad (16)$$

em que L é a indutância. Enquanto que o torque eletromagnético T_{em} é dado por (17) (Ong, 1998):

$$T_{em} = \frac{3}{2} \frac{P}{2w_b} (\Psi_{de} i_{qe} - \Psi_{qe} i_{de}), \quad (17)$$

onde P é o número de polos.

Neste trabalho, a proposta é provocar uma variação nas indutâncias L de dispersão do estator e rotor e de magnetização, de modo a simular a falha de rolamento. Logo, esta variável será ajustada nas reatâncias do modelo matemático do motor conforme (6).

Na próxima seção, será descrita a implementação dessa variação da indutância no ambiente Simulink/MATLAB[®] para testar as diversas situações de motor saudável e com defeitos, segundo a abordagem matemática proposta.

4.2 Simulações do MIT com falhas

Inicialmente, foi criado o projeto do modelo matemático do motor no ambiente Simulink/MATLAB[®] com base nas equações descritas na seção anterior e descrito por Ong (1998).

Para implementar no modelo a indutância proposta em (6), foi criado um sub-sistema específico para variação das reatâncias indutivas x_{le} , x'_{lr} e x_m para cada tipo de falha, nas pistas externa e interna e nas esferas, indicados nas Figuras 2, 3 e 4, respectivamente.

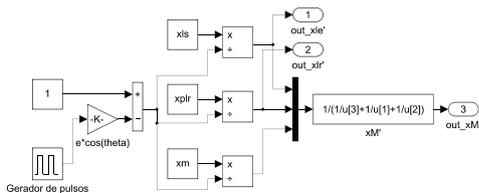


Figura 2. Bloco para simulação de falha na pista externa.

Nas três situações, é inserido um gerador de pulsos com o seu período sendo o inverso da frequência característica da falha. O sinal proveniente deste recebe um ganho referente

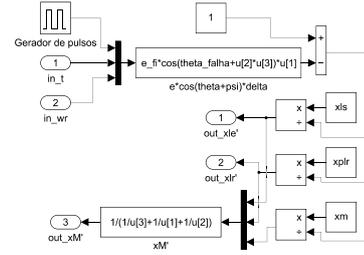


Figura 3. Bloco para simulação da falha na pista interna.

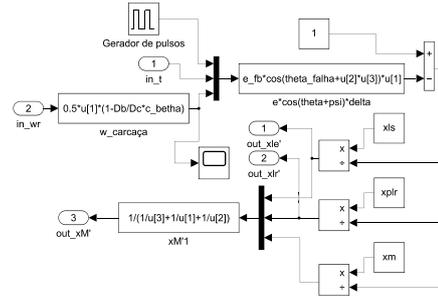


Figura 4. Bloco para simulação da falha na esfera.

ao grau de excentricidade e multiplicado pelo cosseno de $(\theta + \psi(t))$, em que ψ é diferente para os três casos de falha, conforme descrito na seção 2. 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 dq0 conforme (10), (13) e (17).

Com o modelo do motor de indução com falhas implementado, foram realizadas diversas simulações. Foram considerados o motor sem carga, com 25%, 50%, 75% e 100% de carga nominal no eixo e com uma excentricidade relativa e de 10%, 25%, 50%, 75% e 90% de severidade, para quatro situações: motor normal e motor com falhas nas pistas externa e interna e nas esferas. Além disso, para os 100 casos, foram testadas situações de 10% de desequilíbrio na tensão de uma fase, totalizando 200 amostras de simulação. A simulação considera a alimentação da máquina como conectada diretamente à rede.

O motor de indução simulado é de 1 hp, trifásico, 60 Hz, 4 polos e 200 V. Possui resistências $r_s = 3,4\Omega$ e $r_r = 2,0\Omega$, indutâncias $L_{ls} = L'_{lr} = 6,9$ mH e $L_m = 163,7$ mH e $J_{rotor} = 0,1$ kgm². O rolamento em questão é o zz-6025 com $D_c = 38,5$ mm, $D_e = 7,8$ mm e $N_e = 9,0$.

As simulações foram realizadas de forma a gerar dados de corrente de uma fase do estator no domínio do tempo para, posteriormente, extrair-se características do seu espectro de frequências que possibilitassem a visualização e verificação das falhas.

4.3 Extração de características

Em situações em que o motor apresenta algum defeito no rolamento ocasionando falha no funcionamento, é possível verificar a presença de determinadas frequências no espectro da corrente do estator.

De forma a detectá-las, obteve-se o espectro de frequências no regime permanente da corrente de uma fase do estator por meio da transformada rápida de Fourier (FFT - do inglês, *Fast Fourier Transform*), permitindo avaliar a presença e ausência desses picos de frequência, conforme a Tabela 1.

Essas frequências no espectro de corrente de cada simulação, bem como sua magnitude em dB, foram os parâmetros selecionados para caracterizar as amostras de entrada dos classificadores de padrões. É válido ressaltar que, como a frequência característica da falha depende da rotação do rotor, ela varia conforme é alterada a carga. Logo, os valores de frequência de cada simulação não são exatamente os mesmos.

Para extrai-las utilizou-se o critério de armazenar as frequências e seus módulos que apresentassem magnitude superior a -70 dB. Em seguida, de forma a usar somente duas (F_1 e F_2) na classificação de padrões, selecionaram-se do armazenamento aquelas que se identificassem com seus valores calculados por meio de (1), (2) e (3), subtraídas ou somadas à f_s , conforme algoritmo descrito a seguir:

```

INÍCIO
 $F_1 \leftarrow 0$ 
 $F_2 \leftarrow 0$ 
para  $p \leftarrow 1$  até  $P$  faça
  para  $j \leftarrow 1$  até  $J$  faça
    se  $F[p] = F_{menor}[j]$  então
       $F_1 \leftarrow F_{menor}[j]$ 
       $p \leftarrow p + 1$ 
    para  $k \leftarrow 1$  até  $K$  faça
      se  $F[p] = F_{maior}[k]$  então
         $F_2 \leftarrow F_{maior}[k]$ 
        FIM
      fim se
    fim para
  fim para
fim para
fim para
fim para
FIM
  
```

onde F_{menor} é um vetor com os valores de $f_s - 1.f_c$, F_{maior} , um vetor com os valores de $f_s + 1.f_c$, F , o vetor com os picos armazenados do espectro para cada simulação e P , a quantidade de picos coletados. Já as variáveis J e K representam o número de frequências relacionadas possíveis para as três falhas nas cinco situações de carga; logo seus valores para o presente estudo é quinze. O mesmo processo foi realizado para a identificação do pico de 180 Hz, que indica o desequilíbrio da alimentação.

De posse dos valores de F_1 , F_2 e seus módulos, juntamente com a variável que identifica desequilíbrio, foram gerados os 200 dados com 5 atributos que representam as diversas situações simuladas. Esses dados foram submetidos aos dois classificadores de padrões, cuja metodologia é descrita na próxima seção.

4.4 Configuração dos classificadores de padrão

Foram utilizados cinco atributos para as amostras de entrada dos classificadores. Caso a amostra possuísse desbalanceamento de fase, o primeiro atributo da amostra receberia 180 ou zero. O segundo parâmetro da amostra é o

valor da frequência relacionada $f_s - f_c$. Como foram simuladas situações com graus de severidade diferentes para a mesma localização da falha, o terceiro atributo da amostra correspondeu ao módulo que a frequência relacionada do segundo atributo obteve no espectro. O quarto e quinto atributo seguem a mesma lógica que o segundo e o terceiro parâmetros, porém para a frequência relacionada $f_s + f_c$.

Para a rede PMC, a taxa de aprendizado η foi de 0,1, a precisão ε de 10^{-6} e o fator de momentum α de 0,9. As épocas de treinamento foram limitadas a 1000 épocas.

Treinaram-se duas redes PMC para distinguir as amostras entre oito classes, diferenciando também o desequilíbrio de fases. Para isso, a rede foi configurada com cinco neurônios na camada de entrada, dois e três neurônios na intermediária e dois neurônios na camada de saída.

Também foram treinadas redes auto-organizáveis de Kohonen, buscando-se identificar as oito classes. Toda a implementação foi realizada utilizando o MATLAB®. Para o estudo, foram testadas as topologias 4x4 e 5x5 para obtenção daquela com maior acurácia.

O fluxograma da Figura 5 apresenta a sequência das ações tomadas no diagnóstico proposto.

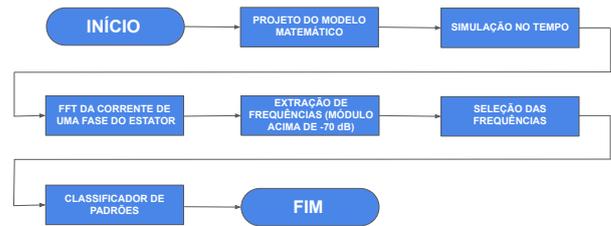


Figura 5. Fluxograma do diagnóstico proposto.

5. RESULTADOS

Após a simulação das diversas situações mencionados na seção anterior, foi possível averiguar a presença ou não das falhas simuladas. As Figuras 6, 7 e 8 apresentam o espectro da corrente do estator para a situação de defeito na pista externa, pista interna e nas esferas do rolamento, respectivamente, quando o motor está a plena carga, com uma fase desequilibrada de 10% e um nível de excentricidade $e = 90\%$.

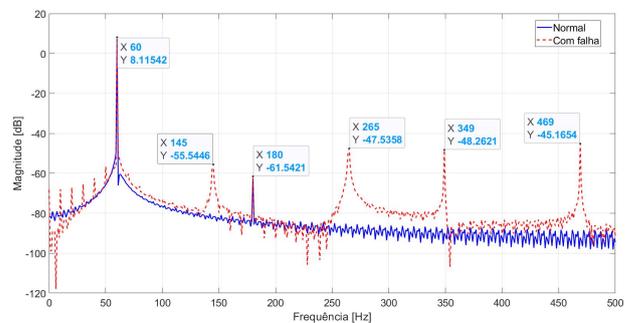


Figura 6. Espectro de corrente de uma fase do estator com defeito na pista externa.

O pico de frequência em 180 Hz indica o desequilíbrio na alimentação, sendo que a simulação com o motor

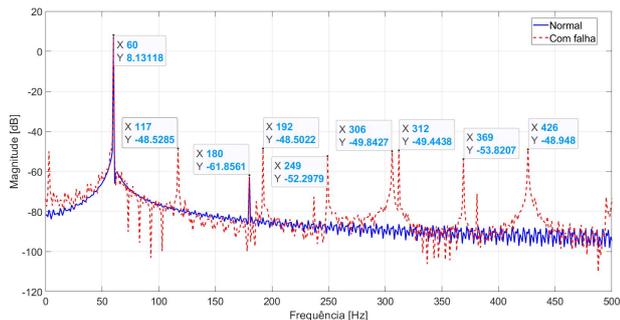


Figura 7. Espectro de corrente de uma fase do estator com defeito na pista interna.

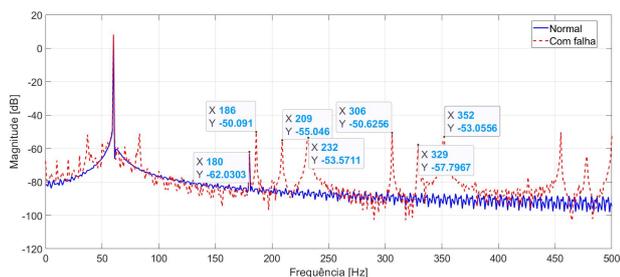


Figura 8. Espectro de corrente de uma fase do estator com defeito nas esferas.

normal das figuras também apresenta essa condição. As frequências relacionadas a cada falta estão estabelecidas na Tabela 2, as quais são os outros picos que aparecem no espectro, de acordo com Blödt et al. (2008), com exceção para o pico em 60 Hz, que é a frequência síncrona da máquina.

Tabela 2. Frequência relacionadas das falhas de rolamento e desbalanceamento de fase.

Localização/tipo da falha	Descrição da frequência	Magnitude [Hz]
Pista externa	$f_s - 1.f_{ext}$	145
	$f_s + 1.f_{ext}$	265
	$f_s - 2.f_{ext}$	349
	$f_s + 2.f_{ext}$	469
Pista interna	$f_s + f_r + 0.f_{int}$	117
	$f_s + f_r - 1.f_{int}$	192
	$f_s - 1.f_{int}$	249
	$f_s - f_r - 1.f_{int}$	306
	$f_s - f_r + 1.f_{int}$	312
	$f_s + 1.f_{int}$	369
	$f_s + f_r + 1.f_{int}$	426
Esferas	$f_s + f_{cr} - 1.f_{esf}$	186
	$f_s - 1.f_{esf}$	209
	$f_s - f_{cr} - 1.f_{esf}$	232
	$f_s - f_{cr} + 1.f_{esf}$	306
	$f_s + 1.f_{esf}$	329
$f_s + f_{cr} + 1.f_{esf}$	352	
Rede desbalanceada	-	180

Após a separação em cinco subconjuntos de treinamento e teste, utilizando o método de validação cruzada (k-fold), 160 amostras foram treinadas e 40 foram testadas para cada rodada de validação. As épocas de treinamento, o erro quadrático médio (EQM) obtido no teste e a taxa de acerto dos cinco folds encontram-se na Tabela 3.

Tabela 3. Resultados do treinamento e teste da PMC com dois e três neurônios na camada escondida.

Neurônios	K-Fold	Épocas de treinamento	EQM Teste	Taxa de Acerto (%)
2	1	1000	0,09	82,5
	2	1000	0,24	52,5
	3	1000	0,25	50
	4	1000	0,11	77,5
	5	977	0,09	82,5
3	1	367	0	100
	2	223	0	100
	3	390	0	100
	4	338	0	100
	5	339	0	100

Na situação de classificação entre oito classes, dois neurônios na camada escondida não foi suficiente para obter acurácia máxima, sendo 82,5% a maior taxa de acertos obtida entre as rodadas. Com três neurônios na camada intermediária, a PMC obteve uma taxa de acertos de 100%, em todas as rodadas e com número menor de épocas para convergência.

Para a rede de Kohonen, foi feito apenas uma rodada de treinamento e teste para as três topologias a serem analisadas, sendo 160 amostras destinadas ao treinamento e 40 amostras, ao teste.

A distribuição das amostras nos mapas auto-organizáveis gerados no teste da rede permitem identificar *clusters* que representam as classes das falhas de rolamento simuladas (Figuras 9 e 10).

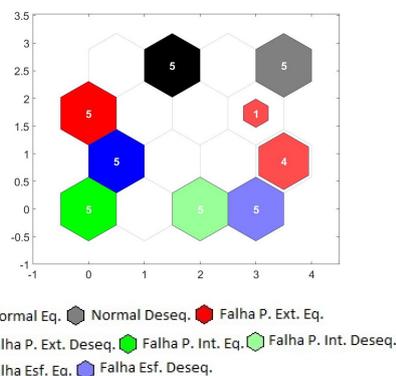


Figura 9. Mapa auto-organizável de Kohonen com topologia 4x4.

Além da clusterização das amostras por tipo de falha, é possível perceber que as amostras com desequilíbrio de tensão (células com cores mais claras) tendem a se agrupar também. É válido ressaltar que as topologias 4x4 e 5x5 foram suficientes para clusterizar as amostras nas suas respectivas classes além de agrupar aquelas com desbalanceamento na alimentação, obtendo 100% de taxa de acerto em ambas situações.

6. CONCLUSÃO

O diagnóstico de falhas do MIT é uma ação imprescindível atualmente visto que é largamente empregado em diversos

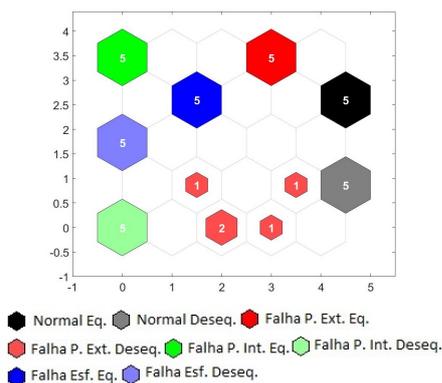


Figura 10. Mapa auto-organizável de Kohonen com topologia 5x5.

setores. Simular essas falhas, em especial a falha de rolamento, permite que diversas situações sejam testadas para uma variedade de versões e modelos de motores.

O modelo do MIT na referência dq0 permitiu a inserção da variação das indutâncias da máquina de forma simples e que reproduzisse as falhas de rolamento, uma vez que foi possível verificar no espectro de corrente de uma fase do estator as frequências relacionadas a frequências características de vibração passíveis de aparecimento quando na presença da falha.

Ademais, foi possível validar os resultados obtidos, visto que os picos de frequências e suas magnitudes que se destacaram no espectro de frequências da corrente, nas diversas situações de falhas de rolamento e condições da máquina, foram corretamente classificadas quando submetidas a dois classificadores de padrões de treinamentos distintos, PMC e rede de Kohonen. Além disso, a configuração de ambas as redes não foram complexas, sendo uma rede PMC de 3 neurônios na camada escondida e um mapa topológico de Kohonen 4x4 suficientes para classificar as amostras.

Finalmente, em trabalhos futuros, objetiva-se adicionar as mesmas informações provenientes de dados de corrente de outras amostras, porém obtidas experimentalmente, a fim de tornar mais robusto o método empregado neste trabalho.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro para a realização deste trabalho por meio de uma bolsa de estudos de Demanda Social (CAPES-DS), e à Universidade Tecnológica Federal do Paraná (UTFPR).

REFERÊNCIAS

Blödt, M., Granjon, P., Raison, B., and Rostaing, G. (2008). Models for bearing damage detection in induction motors using stator current monitoring. *IEEE Transactions on Industrial Electronics*, 55(4), 1813–1822.

Elbouchikhi, E., Choqueuse, V., Amirat, Y., Benbouzid, M.E.H., and Turri, S. (2017). An efficient hilbert–huang transform-based bearing faults detection in induction machines. *IEEE Transactions on Energy Conversion*, 32(2), 401–413.

Frosini, L. (2020). Novel diagnostic techniques for rotating electrical machines - a review. *Energies*, 13(19), 5066.

Gangsar, P. and Tiwari, R. (2020). Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mechanical Systems and Signal Processing*, 144, 106908.

Haykin, S. (2009). *Neural Networks and Learning Machines*. Springer, Upper Saddle River, NJ, EUA, 3 edition.

Immovilli, F., Bianchini, C., Cocconcelli, M., Bellini, A., and Rubini, R. (2013). Bearing fault model for induction motor with externally induced vibration. *IEEE Transactions on Industrial Electronics*, 60(8), 3408–3418.

Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. In *Biological Cybernetics*, volume 43, 59–69.

Lannoo, J., Vanoost, D., Peuteman, J., Debruyne, S., Gerssem, H.D., and Pissoot, D. (2020). 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*, 33(5), 33:e2749.

Ojaghi, M., Sabouri, M., and Faiz, J. (2018). Analytic model for induction motors under localized bearing faults. *IEEE Transactions on Energy Conversion*, 33(2), 617–626.

Ong, C.M. (1998). *Dynamic Simulation of Electric Machinery using Matlab/Simulink*. Prentice Hall, Upper Saddle River, NJ, EUA, 1 edition.

Sapena-Bano, A., Chinesta, F., Aguado, M.P.S.J., Borzacchiello, D., and Puche-Panadero, R. (2019). 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*, 111, 315 – 324.

Silva, I.N., Spatti, D.H., Flauzino, R.A., Liboni, L.H.B., and dos Reis Alves, S.F. (2017). *Artificial Neural Networks: A Practical Course*. Springer, Cham, Zugo, Suíça, 1 edition.

Singh, S. and Kumar, N. (2017). Detection of bearing faults in mechanical systems using stator current monitoring. *IEEE Transactions on Industrial Informatics*, 13(3), 1341–1349.

Terron-Santiago, C., Martinez-Roman, J., Puche-Panadero, R., and Sapena-Bano, A. (2021). A review of techniques used for induction machine fault modelling. *Sensors*, 21(14), 4855.

Toma, R.N., Prosvirin, A.E., and Kim, J.M. (2020). Bearing fault diagnosis of induction motors using a genetic algorithm and machine learning classifiers. *Sensors*, 20(7), 1884.

Zhang, J., Wu, J., Hu, B., and Tang, J. (2020a). Intelligent fault diagnosis of rolling bearings using variational mode decomposition and self-organizing feature map. *Journal of Vibration and Control*, 26(21-22), 1886–1897.

Zhang, S., Wang, B., Kanemaru, M., Lin, C., Liu, D., Miyoshi, M., hoo Teo, K., and Habetler, T.G. (2020b). Model-based analysis and quantification of bearing faults in induction machines. *IEEE Transactions on Industry Applications*, 56(3), 2158–2170.