

Detecção de falhas de estator em motores de indução trifásicos acionados por inversores de frequência

Stator fault detection in three-phase induction motors started by frequency inverters

Pedro P. N. Odorizzi¹, Alessandro Goedel², Wesley A. de Souza³, Marcelo F. Castoldi⁴

RESUMO

Este estudo tem como objetivo a investigação de curtos-circuitos no estator de Motores de Indução Trifásicos acionados por inversores de frequência por meio de processamento de sinais utilizando a Transformada Rápida de Fourier e uma Rede Neural Artificial do tipo Perceptron Multicamadas. Serão coletadas e analisadas as correntes de fase do estator, separando aquelas que apresentam o curto-circuito em questão e as que estão em condição normal. Os dados obtidos passarão por processamento, normalização e aplicação na Transformada Rápida de Fourier, características como média, desvio padrão e variância serão separadas para alimentar a Rede Neural Artificial a fim de detectar os padrões. A metodologia aplicada apresentou bons resultados, onde os classificadores apresentaram uma acurácia superior a 93%.

PALAVRAS-CHAVE: inversor de frequência, *motor de indução trifásico*, rede neural artificial.

ABSTRACT

This study aims to investigate short circuits in the stator of Three-Phase Induction Motors driven by frequency inverters through signal processing using the Fast Fourier Transform and a Multilayer Perceptron Artificial Neural Network. The phase currents of the stator will be collected and analyzed, separating those exhibiting the short circuit in question from those in normal condition. The obtained data will undergo processing, normalization, and application of the Fast Fourier Transform. Features such as mean, standard deviation, and variance will be extracted to feed the Artificial Neural Network in order to detect patterns. The applied methodology yielded good results, with the classifiers achieving an accuracy rate exceeding 93%.

KEYWORDS: *frequency inverters, three phase induction motor, artificial neural network.*

INTRODUÇÃO

Os Motores de Indução Trifásicos (MITs) estão sujeitos a várias condições de carga e ambientais. Essa combinação, juntamente com o envelhecimento natural do motor, pode resultar em várias falhas. Essas falhas podem ser intrínsecas à máquina em si ou resultantes de condições operacionais severas. Portanto, é crucial monitorar o estado do motor para detectar qualquer falha em estágio inicial evitando possíveis falhas catastróficas do motor (Drif, 2007).

Pode-se classificar as falhas em MITs em duas categorias: falhas mecânicas e falhas elétricas. Diversos fatores podem levar a falhas mecânicas e elétricas que ocorrem nos componentes do motor (rotor e estator). No estator tem-se as classificações de falha como

¹ Discente em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil. E-mail: pedroodorizzi@alunos.utfpr.edu.br. ID Lattes: 8252874461686502.

² Docente no Curso de Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil. E-mail: agoedel@utfpr.edu.br. ID Lattes: 1920650157123774.

³ Docente no Curso de Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil. E-mail: wesleyangelino@utfpr.edu.br. ID Lattes: 8594457321079718.

⁴ Docente no Curso de Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil. E-mail: marcastoldi@utfpr.edu.br. ID Lattes: 6178029384175205.



falhas de vibração das bobinas, falhas de isolamento, perda de sincronismo da frequência e transientes. Já no rotor são as falhas: vibração das bobinas, falhas de isolamento, falhas eletromagnéticas e falhas magnéticas (Merizalde, Hernandez e Duque, 2017).

É importante notar que cerca de 30% a 40% das falhas relatadas em motores de indução pertencem à categoria de falhas no estator, o que representa um alto índice, dado que existem diversos tipos de possíveis falhas” (Nandi, Toyota e Li, 2005).

Assim, este trabalho visa contribuir na detecção e classificação de curtos-circuitos em estatores de motores de indução trifásicos, quando acionados por inversores de frequência. Utiliza-se a Transformada Rápida de Fourier (TRF) para o processamento dos dados e Redes Neurais Artificiais (RNA) do tipo Perceptron Multicamadas (PMC).

METODOLOGIA

OBTENÇÃO DE DADOS

Os dados experimentais utilizados neste trabalho, coletados por Godoy (2016), foram obtidos da bancada de ensaios experimentais do Laboratório de Sistemas Inteligentes da Universidade Tecnológica Federal do Paraná - Campus Cornélio Procópio.

A bancada do LSI foi projetada para monitorar tensão, corrente, vibração, torque e velocidade de um motor de indução trifásico. Os sensores Hall enviam as tensões e a corrente de linha para as placas de condicionamento de sinais, que, por sua vez, repassam esses sinais para as entradas analógicas da placa de aquisição Godoy (2016).

O banco de dados apresentado por Godoy (2016) contém informações sobre motores em dois tipos de condições: operando sem defeito e operando com defeitos de curto-circuito de estator. Nesse banco de dados foram realizadas análises e registradas diversas variáveis elétricas e mecânicas, incluindo torque, velocidade, tensões e correntes.

O motor utilizado neste trabalho está descrito no Quadro 1 a seguir. Todos os níveis de curto circuito adquiridos foram utilizados no trabalho.

Quadro 1 – Motor utilizado na pesquisa.

Parâmetros	Motor 1
Fabricante	WEG
Potência (kW)	0,74
Frequência (Hz)	60
Tensão de alimentação (V)	220/380
Corrente de alimentação (A).	3,02/1,75
Número de pólos	4
Nível de Curto-Circuito (%)	3/ 5/10

Fonte: Elaborado pelos autores (2023).

O MIT foi acionado por um inversor de frequência G110, da fabricante Siemens, utilizando o método V/f como forma de controle.

Os dados do inversor de frequência G110 acionando um motor sem falhas foram analisados e, posteriormente, com um curto-circuito no estator, variando o nível de curto-circuito em 3%, 5% e 10%.

No experimento realizado com o motor, o torque de carga variou do motor partindo a vazio até 5 N.m em incrementos de 0,5 N.m. A frequência do inversor foi de 60 Hz.

Nos ensaios de curto-circuito, começando com um nível de 3%, foram realizadas amostragens a cada 3 segundos em cada nível de carga, desde o motor partindo do vazio até atingir 5 N.m. Ao atingir a carga final, alterou-se o nível de 3% para 5%, repetiu-se o

processo para este nível de curto-circuito e posteriormente alterou-se para 10%, repetindo os ensaios em carga.

No caso dos dados saudáveis, o motor variou sua carga da mesma forma que no ensaio do motor com falhas, também com amostragens de 3 segundos.

Nota-se que existem três vezes mais dados de falhas do que de dados saudáveis, portanto, para equilibrar a quantidade de dados para o treinamento e teste da rede, foi aplicado um janelamento de 1 segundo aos dados saudáveis. Dessa maneira, 1 sinal adquirido durante 3 segundos foi dividido em 3 sinais. Portanto, o Quadro 2 apresenta a quantidade de dados disponíveis.

Quadro 2 – Dados obtidos.

Dados Saudáveis	Dados com falha
30	30

Fonte: Elaborado pelos autores (2023).

TRATAMENTO DE DADOS

Esta pesquisa envolve uma metodologia para analisar os dados de corrente de uma fase de um motor de 0,74 kW, tanto em seu estado sem falhas de curto-circuito no estator quanto quando apresentando essas falhas. Em ambos os casos, o motor foi acionado pelo inversor de frequência G110 a uma frequência fixa de 60 Hz por um período de 1 segundo.


Após a coleta dos dados, a primeira etapa do estudo envolve a normalização dos registros de corrente, com o objetivo de estabelecer uma escala consistente para facilitar a comparação e análise dos valores. Para a normalização dos dados, são selecionados os maiores e menores valores do conjunto, posteriormente a isto, o valor que se deseja normaliza subtrai o menor valor do conjunto e, posteriormente, é dividido pela subtração do valor máximo pelo valor mínimo. Em seguida, aplica-se a TRF nos registros de corrente. Empregou-se esta técnica para identificar as diferentes componentes de frequência presentes no sinal.

Posteriormente, os dados no domínio da frequência serão divididos em intervalos de frequência de 5 Hz, cobrindo uma faixa que varia de 0 Hz a 420 Hz. Essa subdivisão permitirá a investigação detalhada das características do sinal de corrente em cada intervalo específico.


Para cada intervalo de frequência, calculou-se três medidas estatísticas fundamentais: média, desvio padrão e variância das amplitudes dos dados de corrente. Espera-se que essas métricas forneçam informações relevantes sobre o comportamento do motor e do inversor em cada faixa de frequência.

As Figuras 1.a e 1.b representam os sinais de corrente de fase a no domínio do tempo e da frequência, respectivamente.

Figura 1– Corrente de fase do motor com 3% de curto circuito, a vazio. (a) no domínio tempo. (b) no domínio da frequência



(a)




(b)

Fonte: Elaborado pelos autores (2023).

Adicionalmente, os resultados obtidos nessa análise estatística foram utilizados como entradas para um modelo de rede neural artificial. Treinou-se essa RNA para identificar padrões e detectar possíveis falhas nos dados de corrente do motor, distinguindo entre situações normais e anormais. Isso proporcionou uma abordagem automatizada para a detecção de falhas.

A Figura 2 representa o esquema realizado para tratamento de dados e posteriormente aplicação na rede neural.

Figura 2 – Cronograma de atividades.



Fonte: Elaborado pelos autores (2023).

CLASSIFICAÇÃO DE FALHAS

A RNA utilizada neste projeto é uma PMC com uma estrutura específica. Esta é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída.

A PMC empregada possui uma camada de entrada com 252 neurônios, uma camada oculta com 10 neurônios e uma camada de saída, com 1 neurônio, responsável por fornecer os resultados desejados. Essa configuração permite à rede aprender e representar relações complexas entre os dados de entrada e as saídas correspondentes. O Quadro 3 apresenta a topologia das redes neurais utilizadas para analisar a capacidade de classificação do método utilizado.

Quadro 3 – Topologia da rede neural.

Rede 1		Rede 2	
Característica	Quantidade	Característica	Quantidade
Camada de entrada	252	Camada de entrada	252
Camada escondida 1	10	Camada escondida 1	15
Camada de saída	1	Camada de saída	1

Fonte: Elaborado pelos autores (2023).

No contexto deste estudo, os dados que apresentam falhas são associados a um resultado de saída igual a 1, enquanto os dados saudáveis são associados a um resultado de saída igual a 0. Essa codificação é utilizada para treinar a rede neural a distinguir entre as duas classes de dados.

Para a implementação na rede neural, os dados foram divididos em conjuntos de treinamento e validação. Os dados de treinamento foram utilizados para que a rede possa determinar parâmetros e classificar os dados como apresentando falhas ou sendo saudáveis. Os dados de validação foram inseridos na rede após ela ter concluído seu período de treinamento. Isso permitiu a avaliação da precisão dos resultados obtidos pela classificação da rede.

O Quadro 4 apresenta como foi realizada a distribuição dos dados para treinamento e para validação. Vale ressaltar que foram selecionados, para os dados de validação, 7 dados saudáveis e 8 dados com falha.

Quadro 4 – Distribuição de dados.

Dado	Quantidade
Treinamento	45
Validação	15

Fonte: Elaborado pelos autores (2023).

Todo o processamento de dados, como também a criação e implementação da rede neural, foram realizados a partir do software Matlab.

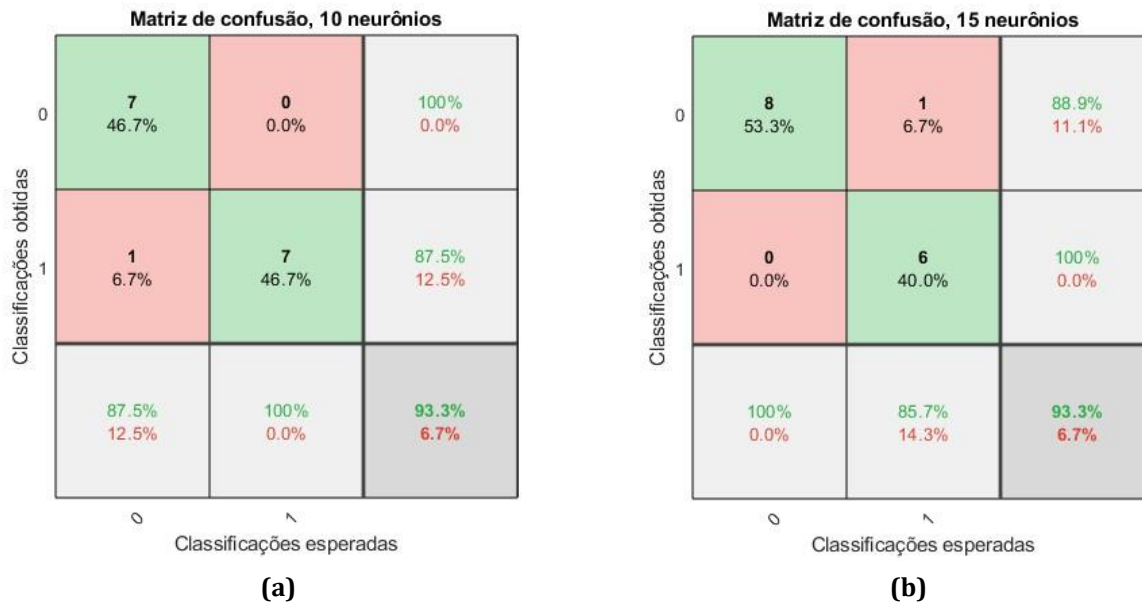


RESULTADOS

Após o tratamento dos dados, conforme citado anteriormente, e a aplicação destes na rede neural artificial, obtiveram-se os resultados da classificação das redes com 10 neurônios em sua camada oculta e 15 neurônios em sua camada oculta.

Assim tem-se que as Figuras 4.a e 4.b representam as matrizes de confusão do resultado para a rede com 10 neurônios na camada oculta rede com 15, respectivamente.

Figura 4 – Resultados dos classificadores.



Fonte: Elaborado pelos autores (2023).

Nota-se que em ambos os casos, as redes alcançaram uma acurácia superior a 93,3%. Na rede treinada com 10 neurônios, ocorreu um erro ao classificar como saudável uma máquina apresentando falha, enquanto na rede treinada com 15 neurônios, houve um erro de classificação em que um dado saudável foi erroneamente identificado como falha.

O erro falso negativo, foi apresentado pela rede 1 é aquele onde qual uma máquina que apresenta a falha é erroneamente classificada como saudável. Nesse caso, a persistência dessa avaria pode causar danos graves ao motor, podendo levá-lo a superaquecer.

O falso positivo, por sua vez, embora indique a necessidade de manutenção futura no equipamento, não representa riscos para a integridade do motor, uma vez que este estava operando de maneira saudável.

CONCLUSÕES

O estudo proposto envolveu o uso de RNAs e o método de pré-processamento de dados utilizando a TRF para a detecção de curto-circuito em estatores, com base em características estatísticas, e obteve bons resultados.

Observa-se que ambos os classificadores alcançaram uma taxa de acurácia superior a 93%, o que indica uma excelente capacidade de classificação de MITs com ou sem a falha de curto-circuito no estator nas condições deste estudo.



No geral, a metodologia aplicada demonstrou resultados satisfatórios com a base de dados utilizada neste estudo. Para dar continuidade à pesquisa, a metodologia deve ser aplicada a um conjunto maior de amostras para confirmar a acurácia dos classificadores gerados e seus resultados.

Agradecimentos

Os autores agradecem o suporte recebido pela UTFPR e pelo CIPECA/DAELE pela estrutura laboratorial.

Conflito de interesse

Não há conflito de interesse.

REFERÊNCIAS

Drif, M.; Cardoso, A. M. Rotor cage fault diagnostics in three-phase induction motors, by the instantaneous phase-angle signature analysis. In: IEEE. 2007 IEEE International Electric Machines & Drives Conference. 2007. v. 2, p. 1440–1445.

Filippo, G. F. Motor de indução. Ed. Érica, 2000.

Godoy, W. F. Multiclassificador inteligente de falhas no domínio do tempo em motores de indução trifásicos alimentados por inversores de frequência. Tese (Doutorado) - Universidade de São Paulo, 2016.

Merizalde, Y.; Hernández-Callejo, L.; Duque-Perez, O. State of the art and trends in the monitoring, detection and diagnosis of failures in electric induction motors. *Energies*, MDPI, v. 10, n. 7, p. 1056, 2017.

Nandi, S.; Toliyat, H. A.; Li, X. Condition monitoring and fault diagnosis of electrical motors - a review. *IEEE transactions on energy conversion*, IEEE, v. 20, n. 4, p. 719–729, 2005.