

## Aplicação de Classificação de Padrões no Reconhecimento de Falhas em Motores Elétricos.

## Application of Standard Classification in Fault Recognition in Electric Motors.

### RESUMO

Este trabalho apresenta um método para classificação rápida de falhas de estator em motores de indução conectados em linha, operando em regime permanente sob condições de tensão de desequilíbrio e carga. Motores de indução são amplamente utilizados em diversas aplicações industriais devido aos seus fatores de favoritismo já consolidados como robustez, baixo custo e alta confiabilidade. A detecção precoce e o diagnóstico adequado de falhas reduzem o custo de manutenção e também aumentam a eficácia do processo. Assim, a amplitude do sinal da corrente do estator, no domínio do tempo, é apresentada como entrada para uma rede de neural multicamada para a classificação de falhas do estator. Após uma discretização adequada do sinal atual, é aplicada a técnica de análise de componentes principais, permitindo a redução da complexidade do classificador. Os resultados obtidos de testes experimentais são promovidos e comparados para validar este estudo.

**PALAVRAS-CHAVE:** Motores de indução. Falhas de estator. Rede neural.

### ABSTRACT

This paper presents a method for rapid classification of stator faults in induction motors connected in line operating at steady state, under unbalance and load voltage conditions. induction motors are widely used in many industrial applications due to their already established favoritism factors such as robustness, low cost and high reliability. early detection and proper fault diagnosis reduces maintenance cost and also increases process efficiency. thus, the time domain signal amplitude of the stator current is presented as input to a multilayer perceptron network for stator fault classification. after proper discretization of the current signal, the principal component analysis technique is applied, allowing the reduction of the classifier complexity. the results obtained from experimental tests are promoted and compared to validate this study.

**KEYWORDS:** Induction Motors. Stator Faults. Neural Networks.

**Guilherme Henrique Attis Campanez**  
[guilhermecampanez@alunos.utfpr.edu.br](mailto:guilhermecampanez@alunos.utfpr.edu.br)  
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

**Rodrigo Henrique Cunha Palácios**  
[rodrigopalacios@utfpr.edu.br](mailto:rodrigopalacios@utfpr.edu.br)  
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

**Recebido:** 19 ago. 2019.

**Aprovado:** 01 out. 2019.

**Direito autoral:** Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



## INTRODUÇÃO

Os motores de indução trifásicos (TIMs) consomem mais de 60% da energia elétrica no setor industrial (Hajian, 2010) e são o principal meio de transformação de energia elétrica em mecânica motriz (Godoy, 2015). Os TIMs podem apresentar falhas de funcionamento que são divididas em dois grandes grupos: falhas elétricas e falhas mecânicas. Dentre as falhas elétricas, destacam-se os problemas relativos aos enrolamentos do estator, enrolamentos do rotor (presentes em alguns modelos de motores). Uma vez que a estrutura não está mais respondendo de maneira balanceada, este desequilíbrio elétrico, que é criado devido a alguns pontos sem indução no rotor, pode causar níveis significativos de vibrações da máquina. De acordo com (Palácios, 2016), este tipo de defeito não leva o motor a uma pane imediata, ou seja, a máquina pode continuar com seu funcionamento mesmo que existam trincas e ruptura das barras. Entretanto, deve ser analisado o estado e a gravidade da quebra, visto que ela pode atingir outros elementos, causando assim maiores disfunções do equipamento. Visto a necessidade de manter os TIMs funcionando com confiabilidade e baixo tempo de inatividade, é importante detectar a existência de um defeito de forma rápida, precisa e com facilidade.

## METODOLOGIA

Considerando que esta pesquisa tem como finalidade a identificação de falhas de estator, assim como perceber o funcionamento do motor de forma saudável, foi proposta inicialmente uma metodologia que utiliza dados experimentais e que reproduz o funcionamento desta máquina em condições de campo.

Na Figura 1 é apresentado o fluxograma que exemplifica resumidamente as ações para o tratamento dos sinais de corrente.

Os motores trifásicos utilizados neste trabalho são de alto rendimento da marca WEG, de 1 e 2 hp, ambos com 4 polos e 36 slots. As correntes do estator foram medidas nos motores citados acima, ambos com enrolamentos de estator personalizados, como pode ser visto na Tabela I.

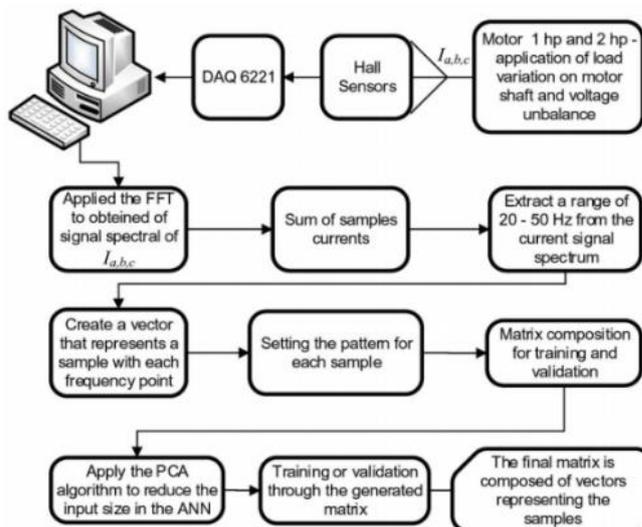
Em posse dos dados aquisitados, é então aplicada a FFT para a obtenção do espectro do sinal no domínio da frequência de cada fase por amostra, conforme se pode observar o exemplo de uma amostra na Figura 2. Em seguida, efetuou-se a soma destas correntes e utilizou-se um algoritmo para extrair os dados da faixa de frequência de 20 - 50 hz, pois por uma análise gráfica, verificou-se em algumas amostras observadas um comportamento distinto no sinal das falhas estudadas.

Tabela 1 – limites das tensões e conjugado de carga para aquisição dos dados: motores de 1 e 2 hp.

| $\%V_a$ | $\%V_b$ | $\%V_c$ | 1 hp (N.m) Motor 1 | 2 hp (N.m) Motor 2 |
|---------|---------|---------|--------------------|--------------------|
| 100     | 100     | 100     | 0,5 – 6,0          | 0,5 – 9,0          |
| 92      | 100     | 100     | 0,5 – 6,0          | 0,5 – 9,0          |
| 100     | 108     | 100     | 0,5 – 6,0          | 0,5 – 9,0          |
| 92      | 100     | 108     | 0,5 – 6,0          | 0,5 – 9,0          |

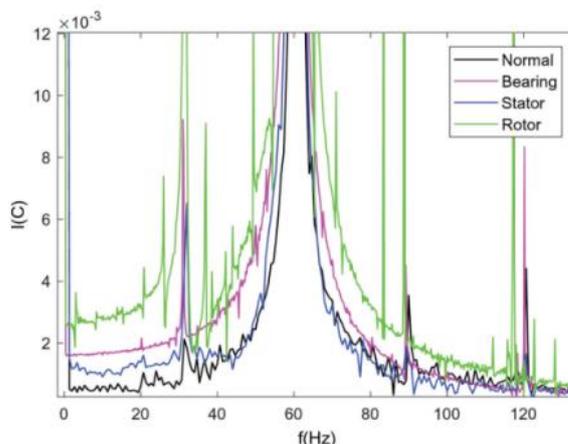
Fonte: Autoria própria (2019).

Figura 1 – Fluxograma das ações para a aquisição e tratamento de sinais.



Fonte: R. H. C. Palácios, I. N. da Silva, A. Goedel, and W. F. Godoy, “A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors,” *Electric Power Systems Research*, vol. 127, pp. 249 – 258, 2015.

Figura 2 – Sinais no domínio da frequência das correntes em sobreposição de situações do motor com falhas e saudável que é subsídio para a composição da amostra de entrada dos métodos classificadores e estimadores de defeitos.



Fonte: Autoria própria (2019).

Neste trabalho a Rede Neural Artificial, realizada no software Matlab, possui uma topologia com 10 entradas empiricamente definidas com uma única camada oculta composta de 6 neurônios artificiais utilizando a função tangente hiperbólica como ativação e 2 neurônios na camada de saída que consideram uma função de ativação linear. A Rede Neural Artificial é treinada utilizando amostras considerando falhas do estator, do rolamento e do rotor, além de dados de motores saudáveis, em que as amostras para o motor saudável são definidas como padrão binário negativo e as outras como binário positivo.

**RESULTADOS EXPERIMENTAIS**

Neste primeiro teste, são apresentados os resultados de multiclassificação de falhas distintas, sem avaliar a severidade. Neste caso, na Tabela 2, os dados gerais do processamento das 762 amostras do motor de 1 hp e 857 amostras do motor de 2 hp são apresentados.

Tabela 2 – Resultado dos testes de multiclassificação para identificar falhas de estator, rolamento, rotor e motor saudável com motores de 1 e 2 hp.

| Potência do motor                     | 1 hp   | 2 hp   |
|---------------------------------------|--------|--------|
| Tempo gasto para construir o modelo   | 8,37 s | 9.71 s |
| Número total de instâncias            | 762    | 857    |
| Instâncias classificadas corretamente | 100    | 92.88  |
| Estatística Kappa                     | 1      | 0.88   |
| Erro absoluto médio                   | 0.001  | 0.038  |
| Erro quadrático médio da raiz         | 0.003  | 0.167  |
| Erro absoluto relativo (%)            | 0.525  | 12.06  |
| Erro quadrático relativo da raiz (%)  | 0.797  | 42.05  |

Fonte: Autoria própria (2019).

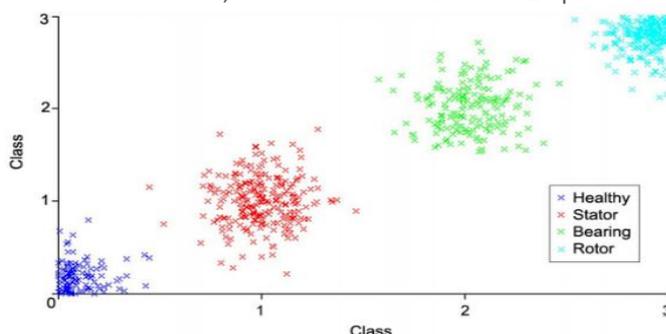
Nas Figuras 3 e 4 é apresentada graficamente a distribuição amostral da classificação das amostras em forma de densidade. Especificamente, na Figura 4 o aparecimento de vários "quadrados" na cor azul no espaço das amostras com defeitos de rolamento. Complementarmente, percebe-se também o aparecimento de "quadrados" na cor verde posicionados no local das amostras de motor saudáveis, indicando exatamente o posicionamento dos erros gerados pelo processamento da Rede Neura Artificial.

Tabela 3 – Matriz de confusão dos testes de multiclassificação para identificar falhas de estator, rolamento, rotor e motor saudável com motores de 2 hp.

| Classe – Motor – 2hp | 0  | 1   | 2  | 3   |
|----------------------|----|-----|----|-----|
| Saudável             | 35 | 0   | 25 | 0   |
| Estator              | 0  | 240 | 0  | 0   |
| Rolamento            | 36 | 0   | 84 | 0   |
| Rotor                | 0  | 0   | 0  | 437 |

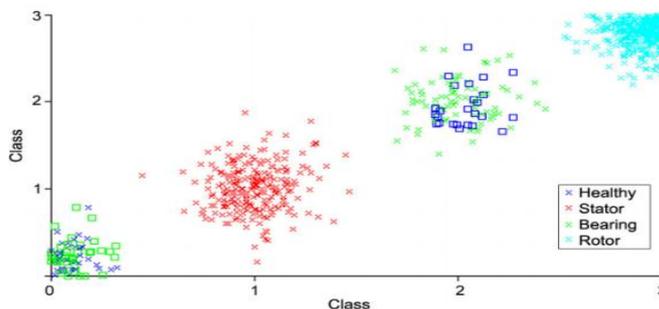
Fonte: Autoria própria (2019).

Figura 3 – Gráfico com os erros de classificação no espaço amostral de falhas de estator, rolamento, rotor e motor saudável de 1 hp.



Fonte: Autoria própria (2019).

Figura 4 – Gráfico com os erros de classificação no espaço amostral de falhas de estator, rolamento, rotor e motor saudável de 2 hp.



Fonte: Autoria própria (2019).

Os testes da severidade da falha no estator foram executadas por meio de 300 amostras oriundas do motor de 1 hp divididas em 240 amostras com curto circuitos entre as espiras das bobinas considerando 1%, 3%, 5% e 10% de comprometimento desta estrutura somado a 60 amostras de motor saudável. No caso do motor de 2 hp, foram testadas 240 amostras com as mesmas severidades de falhas exploradas no motor de 1 hp.

Contudo, neste motor foram utilizadas 110 amostras do motor saudável, tendo um total de 350 amostras.

Tabela 4 – Resultado dos testes de multiclassificação para identificar a severidade de falhas no estator do motor de 1 e 2 hp.

| Potência do motor                     | 1 hp  | 2 hp  |
|---------------------------------------|-------|-------|
| Tempo gasto para construir o modelo   | 3.4 s | 4 s   |
| Número total de instâncias            | 300   | 350   |
| Instâncias classificadas corretamente | 65.66 | 67.42 |
| Estatística Kappa                     | 0.57  | 0.58  |
| Erro absoluto médio                   | 0.149 | 0.134 |
| Erro quadrático médio da raiz         | 0.334 | 0.318 |
| Erro absoluto relativo (%)            | 46.83 | 42.78 |
| Erro quadrático relativo da raiz (%)  | 83.72 | 80.38 |

Fonte: Autoria própria (2019).

Na Tabela 4 pode-se observar o resultado global dos testes com os motores de 1 hp e 2 hp. Nota-se que foram obtidos 65.66% e 67.42% de classificações corretas das severidades do defeito. Percebe-se na Tabela 6 que todas as amostras saudáveis e as amostras com maior severidade, com curto circuito 10%, foram classificadas corretamente. Nas amostras com severidade intermediáveis produziram erros entre elas.

Este mesmo padrão de comportamento pode-se observar na Tabela 5, no entanto, aproximadamente 77% das amostras com maior severidade foram classificadas corretamente.

Tabela 5 – Matriz de confusão dos testes de multiclassificação para identificar a severidade de falhas no estator com motor de 1 hp.

| Classe – Motor – 1hp | 0  | 1  | 2  | 3 | 4 |
|----------------------|----|----|----|---|---|
| Saudável             | 60 | 0  | 0  | 0 | 0 |
| Curto-Circuito 1%    | 0  | 26 | 26 | 8 | 0 |

| Classe – Motor – 1hp | 0 | 1  | 2  | 3  | 4  |
|----------------------|---|----|----|----|----|
| Curto-Circuito 3%    | 0 | 17 | 21 | 21 | 1  |
| Curto-Circuito 5%    | 0 | 9  | 19 | 30 | 2  |
| Curto-Circuito 10%   | 0 | 0  | 0  | 0  | 60 |

Fonte: Autoria própria (2019).

Tabela 6 – Matriz de confusão dos testes de multiclassificação para identificar a severidade de falhas no estator com motor de 2 hp.

| Classe – Motor – 2hp | 0   | 1  | 2  | 3  | 4  |
|----------------------|-----|----|----|----|----|
| Saudável             | 110 | 0  | 0  | 0  | 0  |
| Curto-Circuito 1%    | 0   | 30 | 16 | 9  | 5  |
| Curto-Circuito 3%    | 0   | 13 | 22 | 23 | 2  |
| Curto-Circuito 5%    | 0   | 5  | 23 | 28 | 4  |
| Curto-Circuito 10%   | 0   | 3  | 5  | 6  | 46 |

Fonte: Autoria própria (2019).

## CONCLUSÃO

Após passar pelas etapas descritas na metodologia, pode se concluir que esse protótipo se mostrou eficaz na coleta de dados de falhas nos motores, atendendo seu principal objetivo. No entanto ainda há a necessidade de melhorias no algoritmo para que sejam encontradas falhas em outras partes do motor.

Com um conhecimento moderado e o auxílio de tópicos descritos neste trabalho o projeto pode ser reproduzido e melhorado, fazendo assim com que os resultados obtenham uma margem de erro menor, aumentando a confiabilidade do método.

## AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Universidade Tecnológica Federal do Paraná e do Conselho Nacional de Desenvolvimento Científico e Tecnológico CNPq – Brasil.

## REFERÊNCIAS

- M. Hajian, J. Soltani, G. Markadeh, and S. Hosseinnia, "Adaptive nonlinear direct torque control of sensorless im drives with efficiency optimization," IEEE Transactions on Industrial Electronics, vol. 57, no. 3, pp. 975–985, 2010.
- W. F. Godoy, I. N. da Silva, A. Goedel, and R. H. C. Palácios, "Evaluation of stator winding faults severity in inverter-fed induction motors," Applied Soft Computing, vol. 32, no. 0, pp. 420–431, 2015.
- R. H. C. Palácios, I. N. da Silva, A. Goedel, and W. F. Godoy, "A novel multi-agent approach to identify faults in line connected threephase induction motors," Applied Soft Computing, vol. 45, pp. 1 – 10, 2016