



## USO DA INTELIGÊNCIA ARTIFICIAL PARA O DIAGNÓSTICO AUTOMÁTICO DE FALHAS ENTRE ESPIRAS NO ESTATOR

Isabela Oliveira Zaparoli\*<sup>1</sup>, Résia Silva de Morais<sup>1</sup>, Júlia Tannús de Souza<sup>1</sup>, Josemar de Souza Moreira<sup>2</sup>, Luis Ricardo Candido Cortes<sup>1</sup>, Keiji Yamanaka<sup>1</sup>

<sup>1</sup>COPEL – Universidade Federal de Uberlândia

<sup>2</sup>PPGEL – Universidade Federal de São João del-Rei

**Resumo** - O motor de indução é uma máquina robusta e apresenta inúmeras vantagens, uma vez que pode ser exposto a uma ampla variedade de ambientes. Entretanto, diversas falhas podem ocorrer durante a operação do motor. Este trabalho traz um estudo da análise da corrente do motor para analisar o curto-circuito inicial entre espiras nos enrolamentos do estator do motor de indução de uma forma automática, utilizando Redes Neurais Artificiais. Foi desenvolvida uma interface no software MATLAB para que seja feita a análise de sinais de corrente coletados do motor e detecção da falha de forma simples e automática. Os resultados obtidos neste trabalho demonstram que a técnica aplicada é satisfatória na detecção do problema e exige pouco esforço computacional para realizar a detecção.

**Palavras-Chave** - Curto-circuito entre espiras; Diagnóstico de falhas; Learning Vector; Quantization; Self-Organizing Maps; Multilayer Perceptron.

### USE OF ARTIFICIAL INTELLIGENCE FOR AUTOMATIC DIAGNOSTIC OF FAILURE BETWEEN STATOR COILS

**Abstract** - The induction motor is a robust machine and has numerous advantages as it can be exposed to a wide variety of environments. However, several faults may occur during engine operation. This work brings a study of motor current analysis to analyze the initial short-circuit inter-turns in the stator windings of the induction motor in an automatic way, using Artificial Neural Networks. An interface was then developed in MATLAB software to analyze current signals collected from the motor and detect the fault simply and automatically. The results obtained in this work demonstrate that the applied technique was satisfactory in the detection of the problem and requires little computational effort to carry out the detection.

**Keywords** - Short-circuit inter-turns; Fault diagnosis; Learning Vector; Quantization; Self-Organizing Maps; Multilayer Perceptron.

### I. INTRODUÇÃO

Os Motores de Indução Trifásicos (MITs) são as máquinas rotativas mais utilizadas, atualmente, em setores industriais. O MIT é definido como uma máquina assíncrona que tem basicamente a função de transformar energia elétrica em motriz. A eficiência deste motor está automaticamente associada com suas propriedades construtivas robustas, de fácil manutenção, simplicidade de construção e baixo custo. Além disso, o consumo de energia do MIT nas ações de aceleração e frenagem, por exemplo, é menor, e pode-se obter velocidades maiores, o que implica em potências maiores [1, 2].

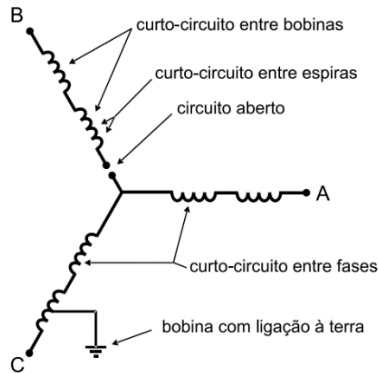
Em torno de 90% das máquinas elétricas instaladas na indústria são motores de indução e correspondem a 60% do gasto de todo o consumo energético [3]. Deste modo, a confiabilidade da operação destas máquinas nos projetos industriais torna-se um ponto crítico, devido às grandes perdas ocorridas em função de uma parada brusca durante o processo industrial [1]. Embora os motores de indução sejam eficientes, estão sujeitos a falhas, que podem custar avarias irreversíveis no MIT, além de prejuízos no processo de produção. Possíveis falhas podem ser em partes mecânicas, tais como desalinhamento entre o motor e a carga, desbalanceamento, rolamentos, ressonância, defeitos de fabricação, folga mecânica e excentricidade. Também podem ser em partes elétricas, tais como barras quebradas, desequilíbrio de tensão e falhas no enrolamento de estator e/ou rotor no caso de rotores bobinados[4].

Há cinco categorias que diferenciam as falhas do estator: 1) Falha de circuito aberto - ausência de continuidade elétrica em um enrolamento; 2) Curto-circuito entre espiras - contato entre duas ou mais espiras de uma mesma bobina; 3) Curto-circuito entre bobinas - contato entre espiras de bobinas diferentes de uma mesma fase; 4) Curto-circuito entre fases - contato entre espiras de fases diferentes; 5) Curto-circuito fase-terra - corrente encontra um caminho de baixa impedância à terra [5].

\*oliveirazaparoli@gmail.com

Uma vez que ocorre uma falha do tipo 2 (curto-circuito entre espiras), o desencadeamento da falha de curto-circuito culmina nas falhas de 3, 4 e 5 (Figura 1) [6]. O curto-circuito entre as espiras do estator é uma falha muito severa, pois a sua evolução para falhas mais graves é muito rápida, demandando maior atenção no processo de monitoramento do MIT.

Figura 1: Representação gráfica das diversas falhas de estator.  
Fonte: Adaptado de [5].



Sabe-se que é economicamente inviável armazenar máquinas para fins de troca, em caso de falhas. Além disso, o monitoramento online do MIT é de muita importância para a eficiência produtiva e de qualidade [7]. Investigar técnicas de detecção e diagnóstico de falhas se tornaram, nos últimos dez anos, de grande almejo para a sociedade científica, tais como em [7, 8, 9, 1, 10, 11, 12, 4].

Devido à necessidade de um diagnóstico não invasivo e simples de ser aplicado, mesmo em plantas industriais, surge a motivação de implementar técnicas de detecção e diagnóstico de falhas nos motores de indução, usando redes neurais artificiais (RNAs) na solução de problemas. Esta tecnologia tem sido aplicada extensivamente na área de monitoramento de falhas, pois mostra-se eficiente, confiável e simples, desde que seja fornecida uma base de dados confiável à rede [12]. Neste trabalho, foram escolhidas três estruturas diferentes de RNA afim de compará-las em relação a taxa de acerto no diagnóstico de falhas.

## II. MATERIAIS E MÉTODOS

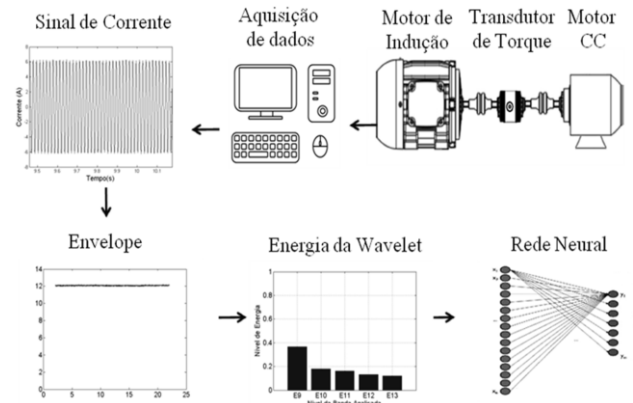
Os passos necessários para a implementação da metodologia proposta (Figura 2) são: i) Medir o sinal de corrente do motor durante o processo de partida; ii) Obter o sinal modulador (envelope) a partir de um processo de demodulação; iii) Aplicar a WE (Transformada de Wavelet) para obter o espectro do sinal; iv) Classificar automaticamente em níveis de falha do sinal através de redes neurais, comparando as suas eficiências, resultando no diagnóstico final.

A principal contribuição da técnica desenvolvida é a análise da corrente de partida da máquina para o diagnóstico de uma falha inicial nos enrolamentos do estator. Em geral, esse tipo de investigação é realizado em um estado estacionário e principalmente no domínio da frequência, neste caso, eles podem ser confundidos com desequilíbrio de tensão e indicar falso diagnóstico.

## A. Testes experimentais

Para a coleta de dados, foi simulada uma falha de curto-circuito no enrolamento do estator de um motor de indução trifásico gaiola de esquilo cujas especificações são: 3 HP, 4 polos, 60 Hz, 220 V, 8.7 A, 1730 rpm e 576 espiras no enrolamento do estator {1} (Figura 3). Além disso, na bancada também foram utilizados: uma máquina de corrente contínua {2} operando como gerador, para representar uma carga; um acoplamento flexível {3}, para conectar o gerador ao MIT; e um torquímetro, que permitiu garantir as mesmas condições em todos os testes. Para representar um baixo isolamento entre as espiras do motor, suas bobinas foram derivadas externamente {4}. Estas derivações foram conectadas em série (duas a cada vez) com um banco de resistores {5}, para limitar a condição de corrente de baixa isolamento (curto-circuito).


Figura 2: Fluxograma da metodologia proposta.



O ajuste de carga do motor é realizado variando a tensão de alimentação do circuito de campo do motor, a tensão foi mantida em 70v configurando que o motor de indução opere em regime permanente com uma carga que exige aproximadamente 30% do torque nominal. A condição de carga foi mantida a mesma em todas as condições estudadas: sem falha e com 3, 6 e 9 espiras em curto-circuito, o que corresponde a 0,52%, 1,04% e 1,56%.

Foram adquiridos sinais de corrente de partida de somente uma das fases, com uma frequência de amostragem de 25,6 kHz e um tempo total de 0,8 segundos usando um sensor de efeito Hall Tectronix A622 AC/DC - 100 Hz, conectado a uma placa de aquisição da National Instruments NI PCI-4461 {6}.

Figura 3: Bancada experimental.



## B. Técnica de Extração do Envelope

O diagnóstico de falhas em motores pode ser dificultado, pois os sinais de corrente contêm outras informações, tais como ruídos. Por isto, utilizam-se técnicas de demodulação da corrente elétrica a fim de separar o sinal modulante do sinal portador.

O sinal modulador é uma sequência de tempo conhecida como “envelope” que, na maioria das vezes, carrega informações de falhas. O processo de demodulação de sinais consiste em uma técnica de análise de sinal bem conhecida e amplamente utilizada na identificação de falhas do motor de indução. Após a operação de demodulação, o envelope obtido conterá todas as características da falha, que serão predominantes e de fácil identificação. Neste trabalho, foi utilizada a Transformada de *Hilbert* como ferramenta de demodulação.

## C. Transformada de Wavelet

A rede neural precisa de parâmetros de treinamento e de teste. Efetivamente, estes valores foram calculados utilizando o método da Energia da *Wavelet* (WE) [13] e o cálculo realizado no software MATLAB. O método da WE consiste em analisar a quantidade de energia presente em cada nível de frequência da Transformada *Wavelet* (TW) do sinal de corrente. Esta ferramenta surgiu como uma generalização da Transformada de Fourier de curto termo (STFT), pois também funciona utilizando a ideia de janelas de análise, porém, no caso da *Wavelet*, esta janela tem tamanho variável e se localiza no domínio do tempo e da frequência, tornando-se possível que a análise do sinal seja feita em qualquer um dos domínios.

Normalmente, o aumento da energia em uma banda específica da *Wavelet* é usada para monitorar o aumento da falha do motor, mas, como as falhas iniciais são pequenas, sua influência na corrente é tão sutil que não provoca um aumento visualmente perceptível da energia. Assim, as RNAs são utilizadas para diagnosticar falhas a partir parâmetros.

Para calcular a Transformada *Wavelet* de um sinal, primeiramente, seleciona-se uma função matemática base, denominada “*Wavelet*-mãe”. No caso deste trabalho, escolheu-se a Daubechies. Após isto, o sinal a ser analisado deve ser decomposto em versões escalonadas da “*Wavelet*-mãe”. Isto significa que a TW de um sinal é o produto interno de um sinal e versões escalonadas e deslocadas da função “*Wavelet*-mãe”. Para este caso foram utilizados 10 níveis de decomposições. Cada um dos níveis desta função possui uma energia característica, devido ao espectro de frequência que está localizado nesta banda. Com estas informações, é possível analisar a quantidade de energia de uma banda de frequência para um rotor sem falha e com falha e compará-las, a fim de identificar um padrão e com isso tornar possível a detecção de falhas. O cálculo da WE pode ser feito de acordo com as Equações de 3 a 5 [14].

$$Ec = |bj, c(t)|^2 \quad (3)$$

Sendo  $bj, c$  a amplitude do coeficiente da Transformada *Wavelet* Discreta para cada ponto discreto da sua respectiva

banda de frequência. A energia total é dada pelo somatório das energias de cada banda.

$$E = \sum_{c=1}^{2^j} Ec \quad (4)$$

Pela normalização dos valores de energia, a chamada Energia da *Wavelet*, que corresponde à quantidade de energia em cada pacote *Wavelet*, ou cada nível, é definida por:

$$H = \left[ \frac{E_1}{E}, \frac{E_2}{E}, \dots, \frac{E_{2^j}}{E} \right] \quad (5)$$

Após estas etapas, os níveis de falha do sinal foram classificados usando três RNAs diferentes, a fim de comparar suas eficiências, já que cada rede possui estruturas diferentes e pode apresentar desempenhos diferentes. As redes utilizadas são apresentadas a seguir. Estas foram implementadas no *software* MATLAB pelos autores.

## D. Self-Organizing Maps (SOM)

*Self-Organizing Maps* (SOM) é uma Rede Neural Artificial inicialmente proposta por Kohonen [15]. Ela possui 2 camadas, aceita padrões n-dimensionais como entrada e os mapeia para um conjunto de neurônios de saída, o qual representa o espaço dos dados a serem agrupados. A camada de saída gera um mapa tipicamente bidimensional, que significa as posições dos neurônios em relação aos seus vizinhos. O objetivo desta rede é organizar os neurônios topologicamente próximos de modo que respondam de maneira semelhante a entradas semelhantes. Para isso, todos neurônios da camada de entrada são conectados aos neurônios de saída.

## E. Learning Vector Quantization (LVQ)

*Learning Vector Quantization* (LVQ) é uma extensão da rede SOM de Kohonen [15], cujo treinamento é não-supervisionado, com treinamento supervisionado dos mapas. Constitui-se em um método que classifica padrões, no qual cada unidade de saída representa uma determinada classe, às quais é associado um vetor peso (vetor de referência). Durante o treinamento da LVQ, os vetores de referência são ajustados e as unidades de saída posicionadas de tal forma a aproximar as superfícies de decisão do classificador de *Bayes*. Após treinada, esta rede possibilita classificar as entradas através da associação destas à classe relativa ao vetor de referência ao qual o vetor de entrada mais se aproxima.

## D. Multilayer Perceptron (MLP)

*Multilayer Perceptron* (MLP) é uma classe de rede neural artificial *feedforward*. Uma MLP consiste em pelo menos três camadas de nós: uma camada de entrada, uma camada oculta e uma camada de saída. Exceto pelos nós de entrada, cada nó é um neurônio que usa uma função de ativação não linear. O MLP utiliza uma técnica de aprendizagem supervisionada chamada *backpropagation* para treinamento. Suas múltiplas camadas e ativação não linear distinguem a MLP de um *Perceptron* linear. Pode distinguir dados que não são linearmente separáveis [16].

### III. RESULTADOS E DISCUSSÃO

Sabendo-se que o curto-circuito em uma determinada fase apresenta uma influência distinta nas correntes de cada fase alimentação do motor, será testada a capacidade das redes neurais para diagnosticar falha a partir da análise da corrente das três fases do motor, utilizando dados de apenas uma fase para realizar o treinamento.

As Figuras 4 a 7 mostram a energia dos 10 níveis de decomposição para cada uma das condições estudadas. Como pode-se observar, é quase imperceptível notar diferença entre as condições de falha, a não ser para a condição de 1,56% de espiras em curto, que mostrou um aumento na energia da banda 7.

Figura 4: Energia da Wavelet do sinal de corrente sem falha.





Figura 5: Energia da Wavelet do sinal de corrente com 0,52% de falha.



Foi criada, no *software* MATLAB, uma interface contendo as três redes neurais utilizadas no trabalho para realizar o monitoramento da máquina de forma prática e rápida sem demandar do operador no âmbito industrial o conhecimento prévio sobre as características apresentadas pela máquina quando está sob a presença de falha.

A interface desenvolvida permite ao usuário alterar separadamente a estrutura e os parâmetros que serão utilizados para o treinamento das redes neurais (Figura 8) e realizar testes com novas coletas de dados a partir das redes que foram treinadas, classificando os dados em 4 grupos: sem falha,

0,52%, 1,04% e 1,56% de falha, na qual os resultados são apresentados de forma clara e didática (Figura 9).

Figura 6: Energia da Wavelet do sinal de corrente com 1,04% de falha.




Figura 7: Energia da Wavelet do sinal de corrente com 1,56% de falha.


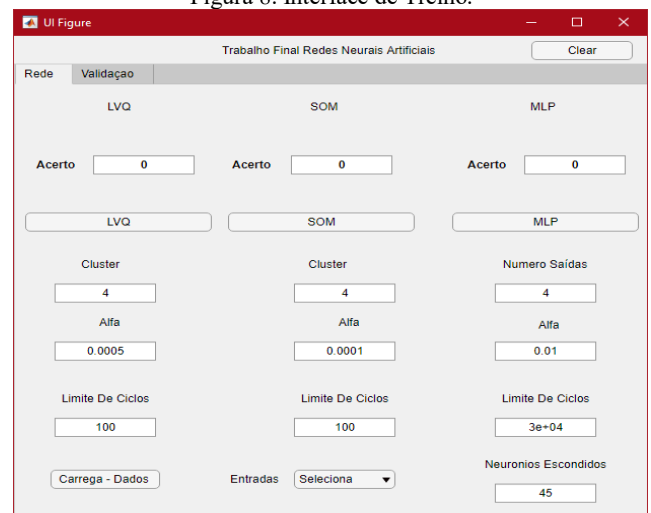


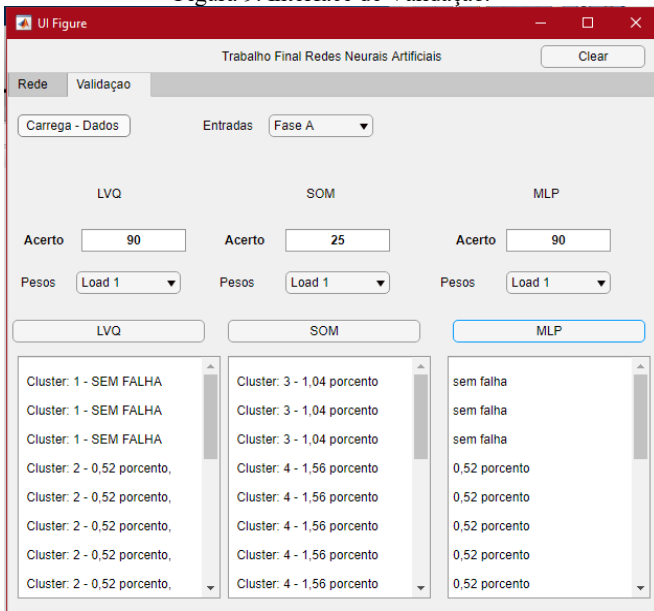
Figura 8: Interface de Treino.



Diversos testes foram realizados variando a estrutura da rede e parâmetros de treinamento. A Tabela I mostra os parâmetros de treinamento das redes (número de neurônios na camada de saída e na camada escondida no caso da MLP, alfa

e ciclos limite) que apresentaram os melhores resultados de reconhecimento dos níveis de falha propostos para este estudo. O treinamento só é interrompido quando a rede classifica corretamente todos os dados apresentados ou atinge o número de ciclos limite. Nas tabelas II, III e IV é mostrado o percentual de acerto das três redes neurais a partir de sinais coletados nas fases A, B e C do motor, respectivamente.

Figura 9: Interface de Validação.



Como já era esperado, resultados diferentes foram obtidos para cada uma das fases. As fases A e B apresentaram maiores percentuais de acerto na classificação, sendo que a fase A utilizada no treinamento, obteve melhores resultados acima de 90% tanto com a LVQ quanto a MLP. Já para a fase C, o percentual de acerto é muito pequeno e não apresenta confiabilidade dos resultados em nenhuma das redes. Utilizando a fase B, foi obtido 100% de acerto usando a LVQ mas para a SOM e MLP os resultados não foram satisfatórios.

Tabela I: Parâmetros de testes usados para treinar e comparar as redes.

Testes	Redes	Alfa	Ciclos Limite	Nº de Neurônios na camada de saída	Nº de Neurônios na camada escondida
1	LVQ	0.1	100	-	4
	SOM	0.1	100	-	4
	MLP	0.1	100000	5	4
2	LVQ	0.01	100	-	4
	SOM	0.01	100	-	4
	MLP	0.1	100000	5	4
3	LVQ	0.1	300	-	4
	SOM	0.1	300	-	4
	MLP	0.1	100000	15	4
4	LVQ	0.01	300	-	4
	SOM	0.01	300	-	4
	MLP	0.001	100000	15	4

Tabela II: Percentual de acerto utilizando a Fase A.

Teste	LVQ	SOM	MLP
1	90%	40%	80%
2	90%	50%	90%

3	90%	40%	85%
4	90%	50%	90%

Tabela III: Percentual de acerto utilizando a Fase B.

Teste	LVQ	SOM	MLP
1	100%	55%	75%
2	100%	55%	75%
3	100%	55%	75%
4	100%	55%	75%

Tabela IV: Percentual de acerto utilizando a Fase C.

Teste	LVQ	SOM	MLP
1	50%	5%	50%
2	50%	5%	50%
3	50%	5%	50%
4	50%	5%	50%

## IV. CONCLUSÕES

Foram implementadas técnicas de detecção e diagnóstico de falhas nos motores de indução, usando redes neurais artificiais na solução de problemas. A metodologia proposta é não invasiva e é simples de ser aplicada, mesmo em plantas industriais. As três redes foram eficazes para tal propósito quando testadas para a mesma fase utilizada no treinamento, porém, para diagnosticar falha em fases diferentes da utilizada no treinamento, não foram obtidos resultados confiáveis, exceto para a fase B utilizando LVQ. Assim, para garantir confiabilidade no diagnóstico, é necessário realizar a coleta e teste nas três fases. Para solucionar o problema de diagnóstico utilizando fases diferentes, propõe-se para trabalhos futuros treinar a rede com dados considerando-se as três fases.

## AGRADECIMENTOS

Os autores agradecem ao CNPq e à Capes, pelo apoio e incentivo financeiro por meio de bolsas de pós-graduação.

## REFERÊNCIAS

- [1] Avelar, V.S., Baccharini, L.M.R. e Amaral, G.F.V. (2011). Desenvolvimento de um sistema inteligente para diagnóstico de falhas nos enrolamentos do estator de motores de indução. *X SBAI – Simpósio Brasileiro de Automação Inteligente*.
- [2] Goedel, A., Silva, I.N. da.; Serni, P.J.A. (2006). Uma abordagem neural para estimação de conjugado em motores de indução. *Sba Controle & Automação*, Campinas, v. 17, n. 3, p. 364-380.
- [3] Ferreira, F.J.T.E. e de Almeida, A.T. (2016). Energy savings potential associated with stator winding connection mode change in induction motors. *In Electrical Machines (ICEM), 2016. XXII International Conference on., pp. 2775–2783. IEEE*.
- [4] Zapparoli, I.O. (2018) *Análise do envelope do transitório da corrente para a detecção de curto entre espiras em motores de indução trifásicos*. 2018. 87 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal de São João Del-rei, São João Del-rei.
- [5] Siddiqui, K.M., Sahay, K., and Giri, V. (2014). Health monitoring and fault diagnosis in induction motor - A

- review. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 3(1):6549–6565.
- [6] Bonnett, A.; Soukup, G. Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors. *Industry Applications, IEEE. Transactions on*, v. 28, n. 4, p. 921–937, Jul 1992.
- [7] Baccarini, L.M.R.; de Menezes, B.R. e Caminhas, W.M. (2010). Fault induction dynamic model, suitable for computer simulation: Simulation results and experimental validation. *Mechanical Systems and Signal Processing*, 24, 300 – 311.
- [8] Martins, S. A. M., Nepomuceno, E. G. e Figueiredo, J. P. (2011). Detecção de estruturas de modelos narmax polinomiais: uma abordagem inteligente multi-objetivo. *Anais do X Simpósio Brasileiro de Automação Inteligente*, pp. 320–325.
- [9] Razik, H.; Correa, M. and Da Silva, E.R.C. (2010). The tracking of induction motor's faulty lines through particle swarm optimization using chaos. *Industrial Technology (ICIT), 2010. IEEE International Conference on*, 1245–1250.
- [10] Brito, J., Lamim Filho, P.C.M., Silva, V.A.D. e Pederiva, R. (2012). Estudo comparativo entre técnica tradicional e técnica moderna para detecção de baixa isolamento em motores de indução trifásicos. *CONEM - VII Congresso Nacional de Engenharia Mecânica*.
- [11] Santos, F.M.da.C. (2013). *Identificação de Falhas em motores de indução trifásicos usando sistemas inteligentes*. 2013. 237 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Escola de Engenharia de São Carlos da Universidade de São Paulo. São Paulo.
- [12] Vitor, A.L.de O. (2015). *Detecção de falhas de estator em motores de indução trifásicos utilizando transformada wavelet, medida rms e potência de previsão*. 2015. 131 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Campus Cornélio Procópio, Universidade Tecnológica Federal do Paraná, Cornélio Procópio.
- [13] Liu, T. e Huang, J. A Novel Method for Induction Motors Stator Interturn Short Circuit Fault Diagnosis by Wavelet Packet Analysis. *IEEE Transactions on Electrical Machines and Systems*, 2005.
- [14] Zaparoli, I.O. (2018) Detecção de Barras Quebradas em Motores de Indução Utilizando Método da Energia da Wavelet. *Anais da XVI CEEL - Conferência de Estudos em Engenharia Elétrica*.
- [15] Kohonen, T. *Self-Organizing Maps*, Springer, New York, 1995.
- [16] Rosenblatt, Frank. *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Spartan Books, Washington DC, 1961.