

UMA ESTRATÉGIA NEURAL PARA DIAGNÓSTICO DE CURTO-CIRCUITO ENTRE ESPIRAS NO ENROLAMENTO DE ESTATOR EM MÁQUINAS DE INDUÇÃO TRIFÁSICAS

PAULO BRONIERA JUNIOR, ALESSANDRO GOEDEL, CLAYTON LUIZ GRACIOLA

Universidade Tecnológica Federal do Paraná - UTFPR

Programa de Pós-Graduação em Engenharia Elétrica – PPGEE-CP

Avenida Alberto Carazai, 1640 – Cornélio Procópio/PR, Brasil - CEP 86300-000

E-mails: paulobry@hotmail.com, agoedel@utfpr.edu.br, claytongraciola@gmail.com

Abstract — The application of induction motors in industry is widespread. Several studies have presented strategies for the diagnosis and prediction of failures in these motors. One technique used is based on the recent utilization of intelligent systems for detecting faults in electric motors. Thus, this paper proposes an alternative tool to traditional methods for fault detection of a short circuit between the turns of the stator winding, using artificial neural networks to analyze the stator current signals in the time domain. Experimental results are presented to validate the proposed work in two neural structures investigated.

Keywords — Three Phase Induction Motor, Artificial Neural Networks, Faults in Electric Motors.

Resumo — A aplicação dos motores de indução trifásicos na indústria é extensa. Desta forma, vários estudos têm apresentado estratégias para o diagnóstico e a predição de falhas nestas máquinas. Este trabalho propõe uma ferramenta alternativa às técnicas tradicionais para detecção de falhas de curto-circuito entre as espiras do enrolamento de estator utilizando redes neurais artificiais as quais analisam os sinais de corrente de estator no domínio do tempo. Resultados experimentais são apresentados para validar a proposta do trabalho em duas estruturas neurais investigadas.

Palavras-chave — Motor de Indução Trifásico, Redes Neurais Artificiais, Falhas em Motores Elétricos.

1 Introdução

A aplicação de Motores de Indução Trifásicos (MIT) na indústria é extensa, sendo este o principal meio de conversão eletromecânica de energia. Este fato ocorre devido as suas características já consolidadas, tais como baixo custo, versatilidade e robustez (Suetake et al., 2011).

Embora estes motores sejam usualmente bem construídos e robustos a possibilidade de falhas é inerente a operação do dispositivo. Defeitos incipientes dentro da máquina geralmente afetam seu desempenho antes mesmo que falhas significativas ocorram, trazendo assim, prejuízos ao processo industrial (Brito, 2002; Suetake, 2012; Belline et al., 2008; Filho, 2003).

De acordo com Tallam et al. (2007) as principais falhas encontradas em motores de indução trifásicos são provenientes de problemas elétricos ou mecânicos. Dentre os problemas elétricos destacam-se as falhas no estator que são da ordem de 38% do total (Bouزيد et al., 2012).

O diagnóstico deste tipo de falha pode ser realizado por meio de técnicas tradicionais não-invasivas. Estas estratégias se fundamentam na análise de grandezas como vibração, tensão, corrente, torque e velocidade (Bellini et al., 2008; Santos et al., 2012).

O trabalho de Bouزيد et al. (2012) define um sistema de detecção de falhas de estator em motores de indução trifásicos que analisam as componentes simétricas por meio dos espectros harmônicos dos

sinais de corrente. O artigo de Ukil et al. (2010) descreve a utilização das assinaturas dos sinais de corrente de estator para diagnosticar falhas de curto-circuito entre as espiras no enrolamento de estator de um MIT.

Entre as técnicas utilizadas para o diagnóstico de falhas em motores elétricos pode-se destacar a utilização dos sistemas inteligentes, em especial as Redes Neurais Artificiais (RNA). Esta metodologia apresenta robustez para o tratamento de incertezas no processamento de sinais. Ainda, as RNA reduzem de forma significativa o número de elementos sensores que monitoram as condições de operação da máquina. Tais sensores contribuem de forma direta com o aumento dos custos de implementação das técnicas tradicionais (Suetake, 2012).

O artigo de Ghate e Dudul (2010) apresenta um classificador de padrões neural, o qual utiliza-se de uma rede Perceptron Multicamadas (PMC) que tem como entrada dados estatísticos retirados dos sinais de corrente do motor. Os sinais de corrente são coletados das fases do motor de indução, a fim de detectar falhas de curto-circuito entre as espiras do enrolamento de estator.

Em Martins et al. (2007) é definido um classificador de padrões que utiliza redes neurais artificiais as quais classificam os sinais de corrente de estator por meio da análise da componente principal (*Principal Component Analysis – PCA*) para diagnosticar falhas de curto-circuito no enrolamento de estator em motores de indução trifásicos.

A proposta deste trabalho consiste em desenvolver uma estratégia para a detecção de falhas no

enrolamento de estator baseado em uma rede neural artificial através do monitoramento das correntes no domínio do tempo. Mais especificamente, a rede deve ser capaz de aprender os padrões dos sinais de corrente do estator e identificar as falhas de curto-circuito entre as espiras.

Assim, este trabalho está dividido da seguinte maneira: na Seção 2 apresenta-se uma descrição das principais falhas nos motores elétricos. Na Seção 3 são apresentados os aspectos relacionados às RNAs. Na Seção 4 é apresentada a metodologia utilizada para o tratamento dos sinais e os resultados experimentais. Finalmente, na Seção 5, as conclusões do trabalho são apresentadas.

2 Classificação das Falhas no MIT

Atualmente a maioria das máquinas são movimentadas por motores elétricos que podem, com o uso, apresentar algum tipo de falha. Estas falhas podem ser classificadas em dois grupos: i) falhas elétricas e ii) falhas mecânicas.

A Figura 1 apresenta um diagrama em blocos dos principais tipos de falhas. As falhas elétricas são destacadas devido aos problemas relativos ao enrolamento de estator, o enrolamento de rotor, as barras quebradas no rotor, os anéis quebrados no rotor e conexões. Por outro lado, as falhas mecânicas podem ser oriundas de problemas de rolamentos, excentricidade, desgaste de acoplamento, desalinhamento conforme relata Singh e Kazzaz (2010).

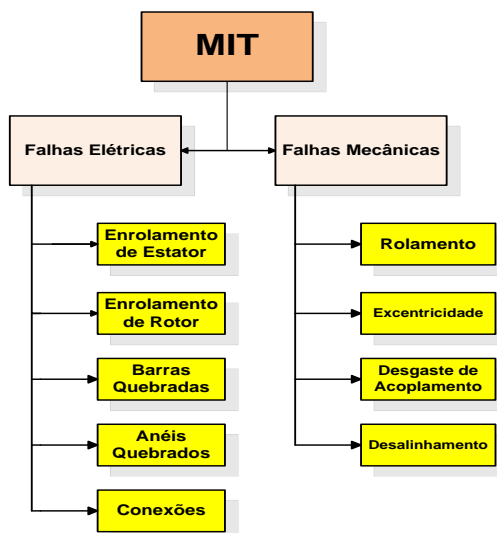


Figura 1 – Classificação das falhas no MIT

Os enrolamentos de estator dos motores de indução trifásicos são submetidos a situações indesejadas por diversos fatores tais como a elevação da temperatura devido a sobrecargas mecânicas, vibra-

ções e problemas relativos a qualidade de energia elétrica. De acordo com Han et al. (2007), as falhas no enrolamento de estator podem representar até 38% das paradas indesejadas dos motores elétricos, conforme pode ser visto na Figura 2.

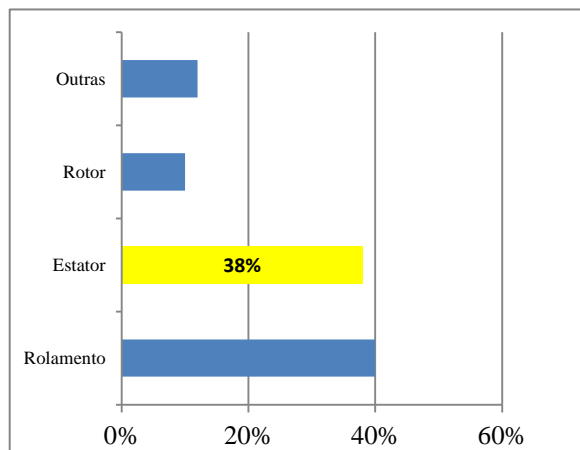


Figura 2 – Possibilidade de ocorrência de falhas em MIT

As falhas de estator podem ser divididas nas seguintes categorias: curto-circuito entre espiras, curto-circuito entre enrolamentos e curto-circuito entre o enrolamento e a carcaça da máquina.

A deterioração do isolamento do estator normalmente começa com o curto-circuito envolvendo poucas espiras. De acordo com Baccarini et al. (2010) a corrente de curto-circuito é de aproximadamente duas vezes a corrente de rotor bloqueado e provoca aquecimento localizado que rapidamente se estende para outros setores do enrolamento. O tempo de evolução da falha depende das condições de operação do motor e é difícil de ser estimado. O que se sabe é que a evolução é rápida e desta forma, se torna indispensável o monitoramento contínuo do motor para a detecção de tal falha (Baccarini, 2010).

3 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são modelos computacionais que utilizam técnicas de processamento inerentemente paralelas, os quais se adaptam a um grande número de unidades simples de processamento (Silva et al, 2010). Assim, através dessa ferramenta computacional é possível desenvolver modelos capazes de realizar previsões sobre o comportamento de um determinado processo, e também executar ações que visam o controle adequado do mesmo.

As aplicações com redes neurais têm aumentado a cada dia. Fornecendo uma nova visão e alternativa a detecção de falhas em motores elétricos, essa

metodologia se tornou atraente com o aumento do poder computacional dos microprocessadores.

Assim, dentro do contexto deste trabalho, objetiva-se investigar duas arquiteturas neurais para detectar falhas no enrolamento de estator usando as amplitudes dos sinais de corrente.

3.1 Neurônio Artificial

O neurônio artificial é a unidade básica de processamento de uma rede neural artificial. Este neurônio, associado computacionalmente a uma estrutura matricial, possui uma ou mais entradas (X_1, \dots, X_n) e uma saída (Y). A cada entrada fica associado um peso (W_1, \dots, W_n) que pondera de forma quantitativa cada entrada em relação à saída.

A equação matemática que descreve o funcionamento de um neurônio é expressa por:

$$Y = g \left(\sum_{i=1}^n W_i \cdot X_i + b \right) \quad (1)$$

onde:

- n é o número de entradas do neurônio;
- W_i é o peso associado com a i -ésima entrada;
- b é o limiar associado ao neurônio;
- X_i é a i -ésima entrada do neurônio;
- $g(\cdot)$ é a função de ativação do neurônio;
- Y é a saída do neurônio.

A partir da estrutura do neurônio artificial é possível obter varias topologias de RNA. Estas podem ser classificadas como redes multicamadas ou redes de camada única.

3.2 Redes Multicamadas

Este trabalho tem por objetivo o diagnóstico de falhas de estator utilizando uma RNA. Assim, a abordagem desta proposta utiliza a rede neural como classificadora de padrões. Conforme Silva et al. (2010), a rede perceptron multicamadas e a rede de Função Base Radial (*Radial Base Function* - RBF), podem ser usadas para esta finalidade.

As redes *perceptron* de múltiplas camadas (PMC) possuem arquitetura *feedforward*, cujo o treinamento é realizado de forma supervisionada. Desta forma a rede ajusta seus respectivos pesos sinápticos de forma adequada para uma determinada aplicação.

A topologia das redes neurais de funções de base radial é constituída por uma camada de entrada, apenas uma camada neural intermediária e uma ca-


mada de saída. Os neurônios da camada intermediária possuem a função de ativação do tipo gaussiana e os neurônios da camada de saída contêm a função de ativação do tipo linear (Azevedo et al, 2000).

A RBF também é caracterizada por conter duas etapas de treinamento distintas, sendo que a primeira está associada aos ajustes dos pesos da camada intermediária através de um método de aprendizagem não supervisionado o qual é exclusivamente dependente das características dos dados de entrada. Já a segunda etapa de treinamento está associada aos ajustes dos pesos dos neurônios da camada neural de saída, a qual utiliza-se da técnica de aprendizagem do tipo regra delta generalizada (Silva et al., 2010).


4 Identificação de Falhas no Estator do MIT

Este trabalho, no que diz respeito aos aspectos metodológicos, utiliza as leituras das correntes de estator no domínio do tempo de um MIT com e sem falhas de estator. Estes sinais são apresentados a uma RNA com o objetivo de identificar a existência ou não de falhas de curto-circuito entre as espiras do enrolamento de estator. A Figura 3a apresenta a estrutura de ensaios do laboratório.

Os sinais de corrente foram coletados de forma individual por três sensores Hall conforme apresentado na Figura 3b. Estes foram conectados a uma placa de aquisição de sinais a qual está ligada a um microcomputador.



(a)



(b)

Figura 3 – Bancada de aquisição de dados: a) Bancada de aquisição de dados em uma visão geral; b) Condicionamento de corrente e tensão da bancada de aquisição de dados.

De posse dos dados, o processamento do sinal foi realizado conforme ilustra o diagrama em blocos da Figura 4.

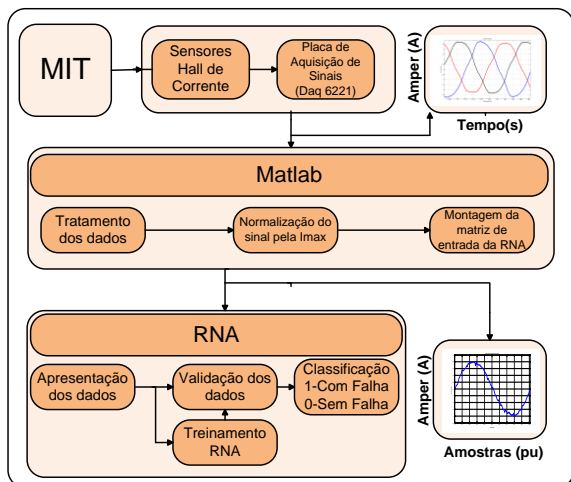



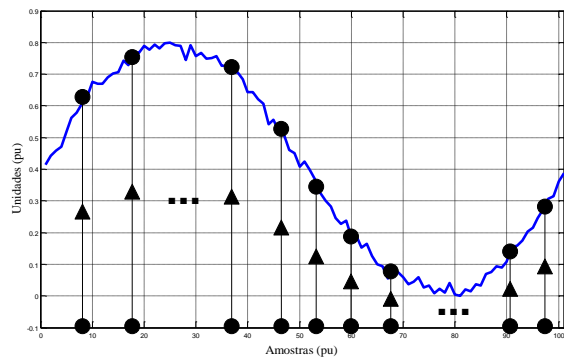
Figura 4 – Rotina de tratamento de dados

A taxa de amostragem dos sinais de corrente foi de $25Ksamples/s$ em um tempo de aquisição igual a 5s. Desta forma foram realizados 134 ensaios e obteve-se um total de 125.000 pontos para cada fase. Deste conjunto de dados, 5.000 pontos foram escolhidos de forma aleatória e armazenados em vetores para condicionamento, conforme apresentado na Figura 5(a).

Após o armazenamento da corrente para cada fase, os respectivos sinais foram condicionados de duas formas: na primeira o sinal foi tratado ponto a ponto resultando em um vetor também de 5.000 pontos. Este totaliza 10 ciclos de onda amostrados, cada um com 500 pontos. Para simplificar e reduzir o número de entradas da rede, utiliza-se uma rotina de tratamento de dados para identificar um ciclo de onda completo e sub amostrá-lo resultando em um vetor de 100 pontos, conforme mostra a Figura 5(b). Já no segundo método os sinais de corrente foram condicionados a partir de seus valores RMS os quais resultaram em apenas três entradas para RNA.



(a)



(b)

Figura 5 – Sinais de Corrente de estator: a) Correntes de estator (fase a, b e c) armazenadas cada uma em um vetor de 5.000 pontos; b) Ciclo de onda sub amostrado em 100 pontos resultante do condicionamento das correntes de estator (entrada da rede).

A partir destes procedimentos foram geradas duas tabelas contendo em cada uma 134 amostras com e sem falhas de curto-circuito entre as espiras do enrolamento de estator. Destas amostras 89 foram utilizadas para treinamento e 55 para validação. As respectivas amostras de sinais com falhas de estator receberam uma *tag* de saída desejada igual a 1, e as amostras de sinais sem falhas receberam uma *tag* de saída desejada igual a 0.

Com o objetivo de avaliar a RNA frente a possíveis interferências nos sinais de corrente apresentados, foi inserido de forma randômica e na mesma frequência do sinal amostrado um ruído branco. Este causou alterações em todo o sinal amostrado, conforme apresenta a Figura 6.

Para isto foi desenvolvido um rotina que estabelece valores randômicos de -1 a 1, os quais são limitados a 10% do valor do sinal de corrente normalizado de 0 a 1. Desta forma o sinal amostrado contendo ruído foi apresentado a rede somente na etapa de validação, a fim de verificar a robustez da RNA, frente a interferências contidas no sinal de corrente apresentado em suas entradas.

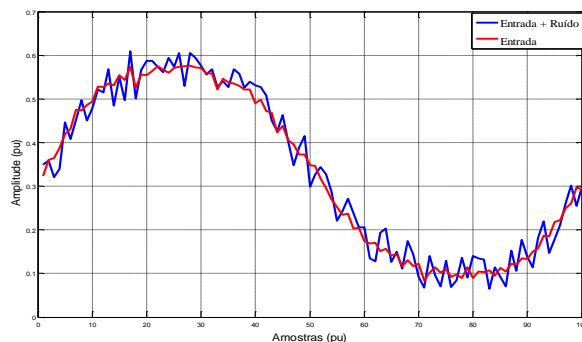


Figura 6 – Sinal de Entrada com Ruído

Após a etapa de coleta, tratamento e teste de robustez, os dados foram submetidos a três arquiteturas de rede com duas topologias diferenciadas, apresentadas na Tabela 1.

Tabela 1 – Parâmetros da RNA

Tipo	Rede 1	Rede 2	Rede 3
Arquitetura	RBF	PMC	PMC
Treinamento	PS	PS	PS
Nº Camadas	2	2	2
Neurônios 1ª Camada	2	3	8
Neurônios 2ª Camada	1	1	1
Algoritmo de treinamento	Auto Organizado/ Regra Delta	BP	BP+LM
Função de ativação 1ª Camada	Gaussiana	Tangente Hiperbólica	Tangente Hiperbólica
Função de ativação 2ª camada	Linear	Linear	Linear

(LM) Levenberg Maquardt; (BP) Backpropagation

Neste trabalho foram considerados dois métodos de condicionamento de sinais. O primeiro consiste na soma das três correntes de fase e o segundo no valor eficaz das correntes de fase.

As redes propostas foram submetidas ao treinamento com o mesmo sinal de entrada, tendo uma taxa de aprendizagem especificada conforme apresentado na Tabela 2 para o primeiro método de tratamento e conforme a Tabela 3 para o segundo método de tratamento dos sinais de corrente. Como critério de parada, foi estabelecido o erro quadrático médio (EQM), sendo este definido de acordo com o melhor desempenho de cada rede.

Tabela 2 – Resultados para 1º método: soma das correntes

Tipo	Rede 1	Rede 2	Rede 3
Amostra de treinamento	89	89	89
Amostra de validação	55	55	55
EQM	$1e^{-13}$	$1e^{-11}$	$1e^{-11}$
Coef. De Aprendizado	0.0001	0.001	0.1
Épocas	287.832	349	45
Falso positivo	5	13	3
Falso negativo	3	4	0
Erro classificação	8/55	17/55	3/55
Porcentual de acerto	85,4%	69,1%	94,54%

Para o primeiro método a Rede 1 convergiu com 287.832 épocas com 85,4% de acerto, enquanto a

Rede 2 atingiu o critério de parada com 349 épocas com apenas 69,1% de acerto. Já à Rede 3 o número de épocas de treinamento foi menor, atingindo um valor máximo de 45 épocas de treinamento com 94,54% de acertos na classificação dos padrões.

Tabela 3 – Resultados para 2º método: Valor eficaz das correntes

Tipo	Rede 1	Rede 2	Rede 3
Amostra de treinamento	89	89	89
Amostra de validação	55	55	55
EQM	$1e^{-9}$	$1e^{-9}$	$1e^{-2}$
Coef. De Aprendizado	0.01	0.001	0.1
Épocas	19.357	328	428
Falso positivo	6	13	4
Falso negativo	3	4	0
Erro classificação	9/55	17/55	4/55
Porcentual de acerto	83,64%	69,1%	92,73%

Para o segundo método a Rede 1 convergiu com 19.357 épocas com 83,64% de acerto, enquanto a Rede 2 atingiu o critério de parada com 328 épocas com apenas 69,1% de acerto. Já a Rede 3 o número de épocas de treinamento foi de 428 épocas e com 92,73% de acertos na classificação dos padrões.

5 – Conclusão

Este trabalho apresentou a proposta de um método alternativo às técnicas tradicionais para detecção de falhas de curto-circuito entre as espiras do enrolamento de estator. Este método utilizou-se de redes neurais artificiais que analisam os sinais de corrente de estator no domínio do tempo.

Foram coletados 134 amostras de sinais de corrente de estator. Os dados foram condicionados de duas maneiras, os quais foram treinados e validados por três arquiteturas diferentes de redes neurais. Através dos resultados obtidos, pode-se observar que das três arquiteturas propostas para o trabalho, a Rede 3 apresentou o melhor desempenho para tal aplicação, possibilitando assim a validação do método proposto.

Agradecimentos

Este trabalho conta com o apoio da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná (Processo No 06/56093-3), do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Processo N°474290/2008-5, 473576/2011-2, 552269/2011-5) e bolsas Capes-DS.

Referências

- Azevedo, Fernando mendes de, Lourdes Mattos Brasil Brasil, e Roberto Célio Limão de Oliveira. (2000). *Redes Neurais com Aplicações em Controle e em Sistemas Especialista*, Bookstore, Florianópolis, RS.
- Baccarini, Lane Maria Rabelo. (2005). Detecção e Diagnóstico de Falhas em Motores de Indução, *Tese de Doutorado*, Universidade Federal de Belo Horizonte, Belo Horizonte, MG.
- Baccarini, Lane Maria Rabelo, Benjamim Rodrigues de Menezes, e Walmir Matos Caminhas. (2010). Fault Induction dynamic model, suitable for computer simulation: Simulation results and experimental validation. *Mechanical Systems and Signal Processing*, pp 300-311.
- Bayindir, Ramazan, Ibrahim Sefa, Ilhami Colak, e Askin Bektas. (2010). Fault Detection and Protection of Induction Motors Using Sensors. *IEEE Transactions on Energy Conversion*, pp 734-741.
- Bellini, A., F. Filippett, e C. Tassoni. (2008). Advances in Diagnostic Techniques for Induction Machines. *IEEE Transactions on Industrial Electronics* 55(12), pp 4109-4126.
- Brito, J. N. (2002). Desenvolvimento de um Sistema Inteligente híbrido para diagnóstico de Falhas em Motores de indução Trifásicos. Universidade Estadual de Campinas-PDGGEM/UNICAMP, Campinas, SP.
- Filho, P.C.M.L. (2003). Acoplamento Preditivo de Motores de Indução Trifásicos através da análise de Fluxo Magnético. *Dissertação de Mestrado*. Universidade Estadual de Campinas, Campinas – SP.
- Frosini, L., e E. Bassi. (2010). Stator current and motor efficiency as indicators for different types of bearing faults in induction motors. *IEEE Transactions on Industrial Electronics*, pp 244-251.
- Ghate, V., N., e S. V. Dudul. (2010). Optimal MLP neural network classifier for fault detection of three phase induction motor. *Expert Systems with Applications* 37(4), pp 3468-3481.
- Goedtel, Alessandro. (2010). Estimativa de Conjugado em Eixos de Motores De Indução Trifásicos Através de Redes Neurais Artificiais. Universidade Estadual Paulista, Bauru, SP.
- Han, T., B. yang, e Z. Yin. (2007). Feature-based fault diagnosis system of induction mo-tors using vibration signal. *Journal of Qua-lity in Maintenance Engineering*, pp 163-175.
- Haykin, Simon. (2001). *Redes Neurais: Princípios e Prática*, Bookman, Porto Alegre, RS.
- Martins, J.F., V. Fernão Pires, e A. J. Pires. (2007). Unsupervised neural-network-based algorithm for an on-line diagnosis of tree-phase induction motor stator fault. *IEEE Transactions on Industrial Electronics*, 259-264.
- Santos, Fernanda Maria da Cunha, Ivan Nunes da Silva, e Marcelo Suetake. (2012). Sobre a Aplicação de Sistemas Inteligentes para Diagnósticos de Falhas em Máquinas de Indução - Uma Visão Geral. *Controle & Automação* 23, n. 5, pp 553-569.
- Silva, Ivan Nunes da, Danilo Hernane Spatti, e Rogerio Andrade Flauzino. (2010). *Redes Neurais Artificiais*. Artiliber, São Paulo, SP.
- Singh, G., e S. A. Kazzaz. (2010). Induction machine drive condition monitoring and diagnostic research a survey. *Electric Power Systems Research* 64 (2), pp 145-158.
- Suetake, Marcelo. (2012). Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos. *Tese de Doutorado*. Universidade de São Paulo, São Carlos, SP.
- Tallam, R. M., S. B., Stone, G. C. Lee, G. B. Kliman, e J. Yoo. (2007). A survey of methods for detection of stator-related faults in induction machines. *IEEE Transactions on Indutry Applications* 43(4), pp 920-933.
- Ukil, Abhisek, Shuo Chen, e Andrea Andenna. (2010). Detection of stator short circuit faults in three-phase induction motors using motor current zero crossing instants. *Electric Power Systems Research*, pp 1036-1044.