

# IDENTIFICAÇÃO DE FALHAS EM MOTORES DE INDUÇÃO PELA ABORDAGEM DAS REDES NEURAIAS

FERNANDA MARIA DA CUNHA<sup>1</sup>, DANILO HERNANE SPATTI<sup>1</sup>, IVAN NUNES DA SILVA<sup>1</sup>

1. *Laboratório de Automação Inteligente de Processos e Sistemas, Depto. de Engenharia Elétrica, Escola de Engenharia de São Carlos, Universidade de São Paulo*  
Av. Trabalhador Sancarlense, 400, Centro, CEP 13566-590, São Carlos - SP  
E-mails: [fcunha12@gmail.com](mailto:fcunha12@gmail.com), [danielospatti@usp.br](mailto:danielospatti@usp.br), [insilva@sc.usp.br](mailto:insilva@sc.usp.br)

**Abstract**— The recognition of electrical and mechanical faults are the main goals of monitoring systems for electric motors. Such systems are being developed by computational intelligence techniques in order to identify and classify incipient faults to avoid financial losses, irregularities in the electrical or mechanical functioning of the motor, and even unexpected downtime. In this paper, we will describe a fault diagnosis system applied to three-phase induction motors, consisting of the wavelet transform and two topologies of artificial neural networks, which received as input data statistical parameters extracted from the three current on power supplies the motors. The failures analyzed were short circuits in the stator windings and rotor bars sectioned. The results achieved by intelligent diagnosis system were significant, characterizing it as efficient for the accuracy of the results and low computational effort required.

**Keywords**— Three-phase induction motor, fault diagnosis system, pattern recognition, artificial neural network.

**Resumo**— O reconhecimento de falhas elétricas e mecânicas são as principais metas dos sistemas de monitoramento de motores elétricos. Tais sistemas estão sendo desenvolvidos com técnicas da inteligência computacional, buscando pelo reconhecimento de padrões identificar e classificar falhas incipientes para evitar perdas financeiras, irregularidades no funcionamento elétrico ou mecânico do motor e, até, paradas inesperadas. Neste artigo, será descrito um sistema de diagnóstico de falhas aplicado em motores de indução trifásicos, constituído pela transformada wavelet e por duas topologias de redes neurais artificiais, as quais receberam como dados de entrada parâmetros estatísticos extraídos das três correntes de alimentação dos motores. As falhas analisadas foram curtos-circuitos nos enrolamentos dos estator e barras seccionadas do rotor. Os resultados alcançados pelo sistema de diagnóstico inteligente foram significativos, caracterizando o como eficiente pela precisão dos resultados e pelo baixo esforço computacional exigido.

**Palavras-chave**— Motor de indução trifásico, sistema de diagnóstico de falhas, reconhecimento de padrões, redes neurais artificiais.

## 1 Introdução

Motores de indução são elementos primordiais na indústria, em lojas comerciais por meio de equipamentos de pequeno porte e em residências por meio de eletrodomésticos, representando, aproximadamente, 85% de energia elétrica consumida pelo mundo (Cabal-Yopez, 2012). Dentre os existentes, destacam-se os trifásicos pela eficiência na execução de suas funções, menor custo, robustez, longo tempo de vida útil e quase ausência de manutenção (Fitzgerald, 2006). Contudo, falhas elétricas ou mecânicas podem ocorrer devido à umidade e poeira do ambiente, ou por desbalanceamento da corrente e da tensão, ou por outros fatores.

A identificação de falhas em motores de indução trifásica (MIT) é realizada por sistemas de diagnósticos não invasivos, que realizam a leitura de valores quantitativos de variáveis do motor para reconhecer um padrão. Tais variáveis são: corrente trifásica do estator, tensão, vibração, temperatura, torque ou velocidade. Os sistemas de diagnóstico de falhas inteligentes são compostos por técnicas de processamento de sinais, a fim de melhorar a relação sinal/ruído; transformadas matemáticas, como exemplo a transformada de Fourier; e, por conseguinte, métodos

baseados em sistema inteligentes. A função dos sistemas inteligentes é atuar como o administrador do processo de identificação da falha, aplicando estratégias determinísticas e heurísticas para abstrair o padrão que faz o reconhecimento da falha no MIT (Santos, 2012).

Dentre as diferentes metodologias dos sistemas inteligentes destacam-se as redes neurais artificiais (RNA), a lógica *fuzzy* (LF) e o algoritmo de otimização de nuvem de partículas (PSO – *Particle Swarm Optimization*) atuando, principalmente, na resolução de duas falhas que serão retratadas neste artigo: curto-circuito no enrolamento do estator e barras seccionadas do rotor. Em relação a RNA, destacam-se as seguintes topologias aplicadas na resolução da primeira falha: perceptron multicamadas (MLP – *multilayer perceptron*) (Ghate, 2010; Asfani, 2012; Santos, 2013), Funções de Base Radial (*Radial Basis Function*) (Ghate, 2011), Mapas Auto-organizáveis (*Self-Organizing Maps*) (Ghate, 2010). Destinadas à segunda falha, destacam-se as redes MLP (Bouزيد, 2010; Pawlak, 2010; Sadeghian, 2009) e *General Regression Neural Networks* (Kaminski, 2010).

A rede Elman é um tipo de topologia de rede neural empregada, principalmente, na utilização de séries temporais. No entanto, esta rede também tem sido aplicada na identificação de padrões, como no diagnóstico de falhas em MIT. Nos artigos Asfani

(2012) e Leite (2009), a rede Elman foi implementada para identificar falhas no enrolamento do estator, e no artigo Mahamad (2010) para detectar falhas em rolamentos.

A LF é amplamente utilizada em sistemas para detectar anomalias nos enrolamentos do estator (Karakose, 2010; Kumar, 2010; Mini, 2010) e anomalias no rotor (Karakose, 2010). Em Razik (2010), o algoritmo PSO foi utilizado para explorar e extrair os espectros de frequência que representam falhas no rotor.

Assim, o sistema de diagnóstico de falha proposto neste artigo utilizou das redes neurais MLP e Elman para definir o status do motor. Contudo, antes do processamento das RNA, a transformada discreta *wavelet* (DWT) foi aplicada aos segmentos dos sinais de corrente para realçar as particularidades do sinal e auxiliar a etapa subsequente, que é a de extração de características. Os autores do artigo Yan (2013) relatam diversos trabalhos referentes às aplicações recentes da transformada *wavelet* (TW) no diagnóstico de falhas em máquinas elétricas rotativas.

Desta forma, o objetivo deste artigo é definir uma metodologia para o sistema de manutenção preditivo, capaz de analisar a corrente trifásica do motor e identificar o estado de funcionamento do motor. Serão avaliados motores MIT com status de sem falhas, curto-circuito nos enrolamentos do estator e barras seccionadas do rotor.

Assim, o artigo está organizado em seções, sendo na Seção 2, a descrição da metodologia proposta para o sistema de identificação de falhas. A Seção 3 destaca da bancada do laboratório, onde foram realizados os ensaios, bem como as características da configuração do sistema proposto, seguidos pela Seção 4, que apresenta os resultados experimentais gerados pelo sistema. Finalmente, a Seção 5 relata a conclusão.

## 2 Sistema de Diagnóstico de Falhas em MIT

### 2.1 Procedimentos Gerais do Sistema Proposto

Nesta seção, há a descrição dos procedimentos contidos no sistema proposto para identificar a falta presente no MIT. A Fig. 1 ilustra um diagrama em blocos representando os procedimentos do sistema, assim como a sequência de execução dos mesmos.

A metodologia proposta utiliza do sinal proveniente da corrente da rede elétrica que aciona os motores de indução. Cada sinal da corrente trifásica é filtrado pela transformada *wavelet*, resultando em coeficientes *wavelet* de baixa e alta frequência. Os coeficientes de baixa frequência do quarto nível da TW serão distribuídos em janelas, as quais serão formadas por oito ciclos de onda do sinal. Cada janela inicia-se com um valor que representa o início do ciclo de uma onda. O motivo de um segmento ser formado por ciclos completos é para prevenir a ocorrência do efeito de borda durante o processo de seg-

mentação do sinal e, assim, evitar uma perda significativa de dados.

Os principais procedimentos do sistema de diagnóstico são descritos nas próximas subseções.

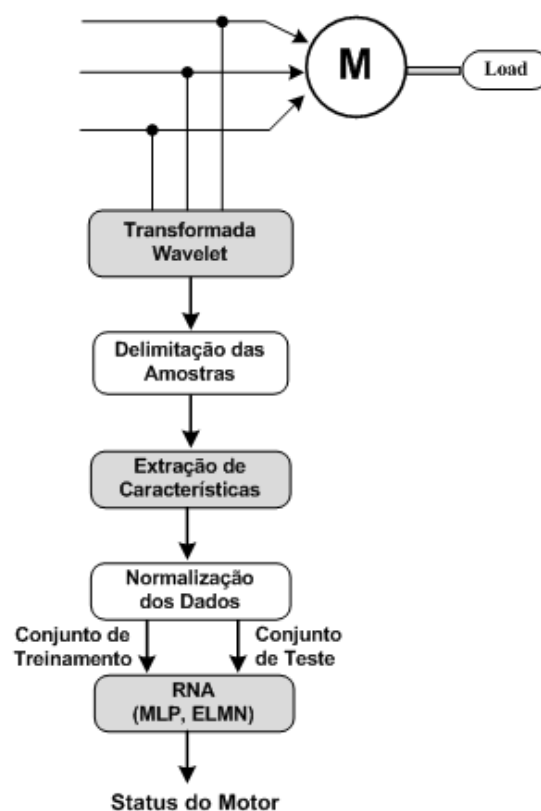


Figura 1. Representação em blocos dos procedimentos do sistema de identificação de falhas.

### 2.2 Transformada Discreta Wavelet

A TW é a decomposição de um sinal entre uma versão deslocada e redimensionada da função *wavelet* original. Ou seja, a função *wavelet* é a base para a expansão de novas funções a partir de operações de dilatação e translação de uma *wavelet* mãe. A transformada contínua *wavelet* realiza a análise de multiresolução pela dilatação e translação de uma função *wavelet*. Contudo, a DWT usa banco de filtros na análise de multiresolução.

Um banco de filtros é formado por filtros que separam um sinal em bandas de frequência, como mostra a Fig. 2. O sinal discreto  $x(k)$  é filtrado pelos filtros  $L(z)$ , o passa-baixa, e  $H(z)$ , o passa-alta, os quais separam o conteúdo da frequência do sinal em bandas de frequência de tamanho igual. Ou seja, cada saída dos filtros contém a metade do conteúdo da frequência, mas a quantidade de dados igual ao sinal  $x(k)$ . Por isso, o operador *downsampling* por um fator de 2, representado por  $\downarrow 2$ , é aplicado nos dados de saída dos filtros, resultando nos coeficientes  $y_h(k)$  e  $y_l(k)$  que contém metade da quantidade de dados do

signal de entrada. Estes coeficientes são chamados de coeficientes *wavelet* e contém detalhes e aproximações do sinal  $x(k)$  que representam o conteúdo do sinal em várias bandas de frequência.




Figura 2. Expansão em dois níveis da DWT.

A DWT pode ser expandida em vários níveis, dependendo da resolução desejada. A Fig. 2 ilustra dois níveis. A saída dos filtros  $L(z)$  e  $H(z)$  do segundo nível aumenta a resolução do tempo e diminui o conteúdo da frequência, o que caracteriza o aumento do tamanho da janela usada na análise dos coeficientes *wavelet* (Merry, 2005).

### 2.3 Extração de Características

O processo de extração de características é de primordial importância para um diagnóstico exato do status do motor. Ou seja, as características de cada segmento serão geradas e organizadas em conjuntos, os quais servirão para o treinamento e teste das RNA. A partir do conjunto de dados de treinamento, as redes neurais serão capazes de aprender a identificar se há ou não falhas de acordo com o padrão apresentado, e se houver uma falha, classificá-la. Por isso, a extração de características é fundamental para um correto aprendizado das redes neurais e, conseqüentemente, um correto diagnóstico.

Diante da relevância desse procedimento para o sistema de diagnóstico, buscou-se no cálculo de variáveis estatísticas uma metodologia objetiva e eficiente, capaz de generalizar informações contidas num segmento de dados. Variáveis ou medidas estatísticas são aplicadas a um conjunto de dados com o intuito de analisá-lo para criar um modelo, e expor este modelo ou padrão. As medidas estatísticas definidas no sistema proposto foram: variância, *skewness* e *kurtosis*. Estas medidas são calculadas pelas seguintes equações matemáticas:

- variância:

$$\text{var} = \frac{\sum_{j=1}^N (x_j^i - \mu^i)^2}{N} \quad (1)$$

sendo que  $N$  é o número total de elementos da amostra  $i$ ,  $x_j^i$  é o valor do  $j$ -th elemento da amostra  $i$ , e  $\mu$  é a média da amostra  $i$ .

- *skewness*:

$$SK = \frac{1}{(N-1)s^3} \sum_{j=1}^N (x_j^i - \mu^i)^3 \quad (2)$$

sendo que  $s$  é o desvio padrão.

- *kurtosis*:

$$KU = \frac{1}{(N-1)s^4} \sum_{j=1}^N (x_j^i - \mu^i)^4 \quad (3)$$

Os coeficientes de *skewness* e de *kurtosis* são também identificados, respectivamente, como o terceiro e quarto momento de um conjunto. *Skewness* é uma medida que indica o quão simétrica uma distribuição está em torno de sua média, o que traduz o valor zero para uma distribuição normal com dados simétricos em torno da média. O coeficiente *kurtosis* mede a forma como a concentração dos dados está do pico da média.

### 2.4 Redes Neurais Artificiais

As RNS são abordagens da inteligência computacional capazes de aprender e agrupar dados em conjuntos. Sua estrutura é composta de neurônios artificiais (unidades de processamento) interligados por múltiplas conexões e dispostos em camadas (camada escondida e camada de saída). As conexões entre cada camada tem um valor (peso sináptico) que ajusta-se durante a fase de treinamento da rede. O objetivo destes ajustes é gerar um conjunto de saídas desejadas a partir do conjunto de entradas.

Diferentes arquiteturas de redes neurais estão sendo aplicadas na resolução de problemas direcionados à MIT. Neste artigo, as topologias MLP e Elman foram implementadas para identificar as falhas no MIT.

A rede MLP possui uma arquitetura *feed forward* e consiste em pelo menos uma camada neural escondida e uma camada neural de saída. O processo de treinamento da rede é supervisionado e, geralmente, o algoritmo de aprendizagem é o *backpropagation*, baseado na técnica do gradiente descendente. Entretanto, as redes neurais MLP definidas neste artigo implementaram o algoritmo de treinamento Levenberg-Marquardt, um algoritmo que utiliza a técnica de otimização dos mínimos quadrados não linear.

A rede neural Elman, comumente, é uma rede de duas camadas com realimentação da saída da primeira camada para a entrada da primeira camada, conforme ilustrado na Fig. 3. A ligação recorrente significa que a função de aprendizado pela rede pode ser baseada nas entradas correntes, além de um registro dos estados anteriores e das saídas da rede. Portanto, a rede Elman é capaz tanto de detectar quanto de gerar padrões variantes no tempo.

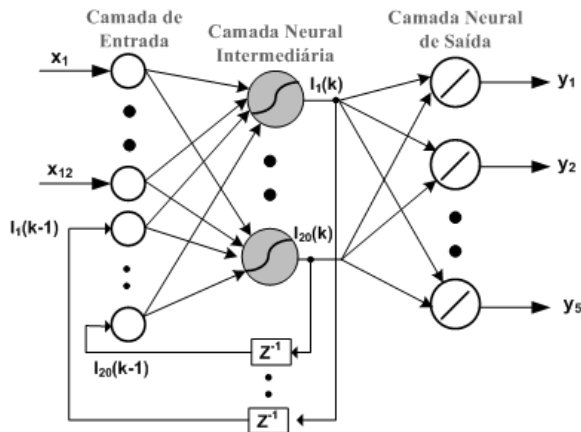


Figura 3. Rede Neural Elman.

### 3 Configuração do Sistema Proposto

A base de dados experimental foi criada a partir de sinais de corrente obtidos de motores sem falhas e com falhas. Ou seja, diferentes situações de funcionamento do motor formaram a base de dados: motor sem falhas, motor com duas perfurações consecutivas nas barras do rotor, motor com quatro perfurações consecutivas nas barras do rotor, curto-circuito entre as espiras de enrolamentos da fase A do estator, curto-circuito entre as espiras de enrolamentos da fase B do estator.

Os MIT foram acionados diretamente pela rede elétrica sob diferentes condições de carga (2.0 Nm, 3.0 Nm and 4.0 Nm) para todas as situações de funcionamento descritas. O sinal de corrente obtido pelo motor foi transformado pela DWT utilizando as funções da família Daubechies. Neste artigo, usou-se a quarta e a sexta ordem das *wavelets* Daubechies. A DWT foi executada quatro níveis consecutivos e, posteriormente, os coeficientes *wavelets* de detalhes deste nível foram amostrados.

O tamanho de cada amostra é determinado por oito ciclos completos do sinal no domínio tempo-frequência, sem sobreposição de informação. Em seguida, o processo de extração de característica foi executado, gerando novas amostras de dados, as quais foram normalizadas no intervalo de [-1,1]. Estas novas amostras foram divididas entre o conjunto de treinamento (332 amostras), e o conjunto de teste (212 amostras) que serão aplicados, reciprocamente, no treinamento e teste das redes neurais.

Em relação as redes neurais, foi desenvolvido uma rede neural para cada falha analisada. Isto é, para as falhas no rotor criou-se uma rede MLP e uma rede Elman capazes de distinguir os padrões motor sem falhas, motor com duas barras quebradas no rotor, motor com quatro barras quebradas no rotor e outras falhas. Da mesma forma, para as falhas no estator, foram implementadas as redes MLP e Elman que identificaram os padrões motor sem falha, motor com curto-circuito na fase A, motor com curto-circuito na fase B e outras falhas.

A quantidade de neurônios e de camadas neurais escondidas das redes MLP e Elman foram determinadas pelo método de tentativa e erro durante a fase de treinamento das mesmas, sendo que ambas receberam como dados de entrada um vetor de 9 elementos. A Tabela 1 detalha as dimensões das redes neurais MLP e Elman definidas no sistema de diagnóstico de falhas.

Tabela 1. Número de neurônios presentes nas camadas neurais das RNA implementadas no sistema proposto.

RNA	Falha no Rotor	Falha no Estator
MLP	[18,4]	[20,10,4]
Elman	[16,10,4]	[20,4]

### 4 Resultados

A metodologia defendida para um sistema de diagnóstico de falhas em MIT é formada por procedimentos que contemplam o processamento do sinal, extração de características e análise para identificação do status do motor. A etapa final é realizada pelas redes neurais MLP e Elman, ambas com aprendizado supervisionado.

Os resultados obtidos pelo sistema proposto para o conjunto de teste provindo da DWT da família Daubechies 4 estão descritos nas Tabelas 2 e 3. Ademais, os resultados gerados pelo conjunto de teste oriundos da DWT da família Daubechies 6, são apresentados nas Tabelas 4 e 5.

Usando limites específicos para cada rede neural, os resultados são apresentados e distinguidos entre os valores de detecção verdadeira (TD) e detecção falsa (FD). Por exemplo, a rede MLP para o motor sem falhas da Tabela 5, alcançou resultados que representam 30 de 42 casos de teste como detecção verdadeira e 12 de 42 casos como detecção

Tabela 2. Eficiência do sistema de diagnóstico de falhas voltado às falhas do rotor.

Tipo de RNA	Status do Motor								Eficiência
	Sem Falhas		Duas Barras Quebradas		Quatro Barras Quebradas		Outras Falhas		
	TD	FD	TD	FD	TD	FD	TD	FD	
MLP	28/42	14/42	31/42	11/42	42/42	0/42	71/84	13/84	81,9
Elman	41/42	1/42	33/42	9/42	23/42	19/42	84/84	0/84	86,2

Tabela 3. Eficiência do sistema de diagnóstico de falhas voltado às falhas no estator.

Tipo de RNA	Status do Motor								Eficiência
	Sem Falhas		Curto-Circuito na Fase A		Curto-Circuito na Fase B		Outras Falhas		
	TD	FD	TD	FD	TD	FD	TD	FD	
MLP	39/42	3/42	39/42	3/42	38/42	4/42	73/84	11/84	90
Elman	34/42	8/42	35/42	7/42	42/42	0/42	81/84	3/84	91,4

Tabela 4. Eficiência do sistema de diagnóstico de falhas voltado às falhas do rotor.

Tipo de RNA	Status do Motor								Eficiência
	Sem Falhas		Duas Barras Quebradas		Quatro Barras Quebradas		Outras Falhas		
	TD	FD	TD	FD	TD	FD	TD	FD	
MLP	24/42	18/42	41/42	1/42	42/42	0/42	77/84	7/84	87,6
Elman	25/42	17/42	24/42	18/42	20/42	22/42	84/84	0/84	72,8

Tabela 5. Eficiência do sistema de diagnóstico de falhas voltado às falhas no estator.

Tipo de RNA	Status do Motor								Eficiência
	Sem Falhas		Curto-Circuito na Fase A		Curto-Circuito na Fase B		Outras Falhas		
	TD	FD	TD	FD	TD	FD	TD	FD	
MLP	30/42	12/42	29/42	13/42	35/42	7/42	84/84	0/84	84,8
Elman	29/42	13/42	34/42	8/42	42/42	0/42	82/84	2/84	89

falsa. Além disso, a eficiência da rede é calculada pela média da TD. De acordo com a melhor eficiência, o sistema de diagnóstico formado pela DWT da família Daubechies 4 gerou melhores resultados. Em relação à identificação das falhas dos MIT, a rede neural Elman teve uma eficiência superior à rede MLP para as duas classificações de falhas.

## 5 Conclusão

Este artigo descreve métodos potenciais que combinam a rede neural artificial com a DWT para detectar curto-circuitos no enrolamento do estator e barras quebradas no rotor de MIT, sob diferentes níveis de carga. As redes Elman obtiveram melhores desempenhos do que as redes MLP. Entretanto, é importante destacar que o tempo de treinamento gasto pelas redes Elman são superiores ao das redes MLP. Além disso, os resultados alcançados pelas redes MLP diferem um pouco, com uma pequena diferença na eficiência.

Um fator essencial, que justifica os bons resultados das redes neurais, foi a correta extração das características do sinal de corrente. Isto foi possível devido ao cálculo de parâmetros estatísticos de cada amostra da corrente. Então, os resultados

experimentais demonstram que a metodologia proposta para um sistema *offline* de detecção e classificação de falhas é eficiente.

## Agradecimentos

Os autores agradecem ao CNPq (Processo 503912/2012-3) e a FAPESP (Processo 2011/17610-0) pelo apoio financeiro concedido para o desenvolvimento desta pesquisa.

## Referências Bibliográficas

- Asfani, D. A., Muhammad, A. K., Syafaruddin, M., Purnomo, H. and Hiyama, T. (2012). Temporary Short Circuit Detection in Induction Motor Winding Using Combination of Wavelet Transform and Neural Network. *Expert Systems with Applications*, Vol. 39, No. 5, pp.5367-5375.
- Bouزيد, M., Champenois, G., Bellaaj, N. and Jelassi, K. (2010). Automatic and robust diagnosis of broken rotor bars fault in induction motor. *The XIX International Conference on Electrical Machines - (ICEM 2010)*, Vol. 2, pp. 1-7.
- Cabal-Yepez, E., Valtierra-Rodriguez, M., Romero-Troncoso, R. J., Garcia-Perez, A., Osornio-Rios,

- R. A., Miranda-Vidales, H. and Alvarez-Salas, R. (2012). FPGA-based Entropy Neural Processor for Online Detection of Multiple Combined Faults on Induction Motors. *Mechanical Systems and Signal Processing*, Vol. 30, pp. 123-130.
- Fitzgerald, A. E., Kingsley, C. and Umans, D. (2006). *Electric Machinery*, Bookman.
- Ghate, V. N. and Dudul, S. V. (2010). Optimal MLP Neural Network Classifier for Fault Detection of Three Phase Induction Motor. *Expert Systems with Applications*, Vol. 37, No. 4, pp. 3468–348.
- Ghate, V. N. and Dudul, S. V. (2011). Cascade Neural Network Based Fault Classifier For Three Phase Induction Motor. *IEEE Transactions on Industrial Electronics*, Vol. 58, No. 5, pp. 1555–1563.
- Kaminski, M., Kowalski, C. T. and Orłowska-Kowalska, T. (2010). General Regression Neural Networks as Rotor Fault Detectors of the Induction Motor. *IEEE International Conference on Industrial Technology (ICIT)*, pp. 1239–1244.
- Karakose, M., Aydin, I. and Akin, E. (2010). The Intelligent Fault Diagnosis Frameworks Based on Fuzzy Integral. *International Symposium On Power Electronics Electrical Drives Automation and Motion (SPEEDAM)*, pp.1634-1639.
- Kumar, K. V., Kumar, S. S., Praveena, B., John, J. P. and Paul, J. E. (2010). Soft Computing Based Fault Diagnosis. *International Conference on Computing Communication and Networking Technologies (ICCCNT)*, pp. 1-7.
- Leite, D. F., Hell, M. B., Costa Jr., P. and Gomide, F. (2009). Real-time Fault Diagnosis of Nonlinear Systems. *Nonlinear Analysis: Theory, Methods & Applications*, Vol. 71, No. 12, pp. e2665-e2673.
- Mahamad, A. K. and Hiyama, T. (2010). Fault Classification Performance of Induction Motor Bearing Using AI Methods. *Proceeding of 5th IEEE Conference on Industrial Electronics and Applications*, pp. 56-61.
- Merry, R. and Steinbuch, M. (2005). *Wavelet Theory and Applications, a Literature Study*. Eindhoven University of Technology.
- Mini, V., Setty, S. and Ushakumari, S. (2010). Fault Detection and Diagnosis of an Induction Motor Using Fuzzy Logic. *IEEE Region 8 International Conference on Computational Technologies in Electrical and Electronics Engineering (SIBIRCON)*, pp. 459-464.
- Pawlak, M. and Kowalski, C. (2010). Low-cost Embedded System for the IM Fault Detection Using Neural Networks. *The XIX International Conference on Electrical Machines (ICEM 2010)*, pp. 1–5.
- Razik, H., Correa, M. B. R. and Silva, E. R. C. (2010). The Tracking of Induction Motor's Faulty Lines Through Particle Swarm Optimization Using Chaos. *IEEE International Conference On Industrial Technology (ICIT)*, pp. 1245-1250.
- Sadeghian, A., Ye, Z. and Wu, B. (2009). Online Detection Of Broken Rotor Bars In Induction Motors By Wavelet Packet Decomposition And Artificial Neural Networks. *IEEE Transactions on Instrumentation and Measurement*, Vol. 58, No. 7, pp. 2253–2263.
- Santos, F. M. C., Silva, I. N. and Suetake, M. (2012). Sobre a Aplicação de Sistemas Inteligentes para Diagnóstico de Falhas em Máquinas de Indução – Uma Visão Geral. *Sba: Controle & Automação*, Vol. 23, No. 5, pp. 553-569.
- Santos, F. M. C., Silva, I. N. and Suetake, M. (2013). Neural Network Classifier For Faults Detection In Induction Motors. *International Conference on Computer Applications Technology (ICCAT)*, pp 1-5.
- Yan, R., Gao, R. X. and Chen, X. (2013). Wavelets for fault diagnosis of rotary machines: A review with applications. *Signal Processing*, In review, (available online 22 April 2013).