

UMA ABORDAGEM NEURAL NO MONITORAMENTO PREDITIVO DE TEMPERATURA NUM MOTOR DE INDUÇÃO TRIFÁSICO

TIAGO DRUMMOND LOPES, ALESSANDRO GOEDEL, PAULO BRONIERA JUNIOR, CLAYTON LUIZ GRACIOLA, DEMERVAL MIZUYAMA

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: *tidrummond@gmail.com*, *agoedel@utfpr.edu.br*, *paulobjr@hotmail.com*,
claytongraciola@gmail.com, *mizuyama@utfpr.edu.br*

Abstract — The three phase induction motor is the main element of converting electrical energy into mechanical driving at industrial production processes. The operation of this machine in a electrical network with power quality problems, cause undesired consequences such as overheating, excessive vibration, torque variation, increased losses, loss of power and operation failure. Thus, this work presents a methodology to monitor and estimate the carcass temperature by using a low cost sensor and also artificial neural networks. Experimental results are presented to validate the proposal.

Keywords — Three Phase Induction Motor, Artificial Neural Networks, Temperature Monitoring, Motor Protection.

Resumo — O motor de indução trifásico é o principal elemento de conversão de energia elétrica em mecânica motriz nos processos produtivos das indústrias. A operação desta máquina numa rede elétrica com problemas de qualidade de energia, causa consequências indesejadas tais como: sobreaquecimento, vibração excessiva, variação de torque, aumento das perdas, perda de potência e falha de operação. A proposta deste trabalho consiste na apresentação de uma metodologia para monitorar e estimar a temperatura na carcaça de um motor utilizando um sensor de baixo custo e redes neurais artificiais. Resultados experimentais são apresentados para validar a proposta.

Palavras-chave — Motor de Indução Trifásico, Redes Neurais Artificiais, Monitoramento de Temperatura, Proteção de Motores.

1 Introdução

O mais utilizado elemento de conversão de energia elétrica em mecânica motriz é o Motor de Indução Trifásico (MIT), o qual é indispensável nos processos produtivos industriais, devido ao baixo custo de aquisição e de manutenção, adaptação frente a diversas cargas mecânicas e robustez em ambientes agressivos (Bouza, 2012; Fitzgerald et al., 2006; Goedel, 2007; Suetake, 2012; Wang, 2001).

De acordo com o Balanço Energético Nacional de 2010 apresentado em (ELETROBRÁS-PROCEL, 2012), estima-se que anualmente 346 bilhões de MWh (MegaWatts hora), o equivalente a 47% da energia elétrica produzida no Brasil, são destinados às indústrias. Tendo em vista a aplicação do MIT em ambientes não industriais, pode-se inferir que a parcela de consumo energético do mesmo é superior a 24% da produção nacional de energia elétrica.

A sobrecarga térmica causa deterioração nos diversos componentes da máquina de indução trifásica, entre eles: os condutores do estator e do rotor, o isolamento, o núcleo e os rolamentos, destacando-se como uma das principais causadoras de falhas nos motores (Bonnett, 1992). Segundo listado em (Toliyat, 2004) as condições que submetem o MIT a temperaturas que ultrapassam o limite térmico são:

1. Condições de sobrecarga térmica transiente ou de partida: *i*) Sobrecarga transiente ou de partida, *ii*)

Partidas frequentes e rotor bloqueado, *iii*) Curto circuito, falta à terra.

2. Condições de sobrecarga em funcionamento: *i*) Sobrecarga, *ii*) Desequilíbrio das tensões de alimentação.

3. Condições anormais de resfriamento: *i*) Temperatura ambiente alta, *ii*) Redução da capacidade de arrefecimento.

O desequilíbrio de tensão é uma adversidade rotineira e preocupante, caracterizada pela variação desigual em amplitude e/ou fases das tensões trifásicas. Este fenômeno é causado pela conexão desigual de cargas monofásicas ou bifásicas no sistema (ANEEL-PRODIST, 2012; Anwari, 2010). O motor que opera em condição de desequilíbrio apresenta simultaneamente características girante e pulsante em seu torque eletromagnético. Segundo Oliveira (2011), devem ser consideradas as componentes de sequência inversa da tensão associando um campo girante de mesma frequência com sentido de rotação inverso àquele da sequência direta. Esse fenômeno, além de sobreaquecimento, gera um aumento significativo da vibração do eixo, diminuindo em até quatro anos e meio de serviço na vida útil do MIT trabalhando com um fator de dois por cento de desequilíbrio (Oliveira, 2011; Abreu, 2002).

Destarte, é fato que o monitoramento de temperatura se faz necessário, tendo em vista que tal ação revela quando o motor está trabalhando em condições anormais, possibilitando a intervenção do

operador com o objetivo de evitar que o equipamento se danifique com o sobreaquecimento.

A termografia é uma técnica que permite a medição e a visualização, com precisão, das temperaturas no entorno da superfície da máquina. A radiação infravermelha é convertida em dados de temperatura e posteriormente transformada em sinais elétricos. O dispositivo de aquisição consiste em uma câmera infravermelha, a qual é responsável por medir o gradiente de temperatura superficial por meio de sensores infravermelhos e capturar imagens de alta qualidade (Picazo-Ródenas, 2012).

Sensores de fibra ótica baseados em redes de Bragg são utilizados para o monitoramento de temperatura em motores elétricos. Esses sensores são espalhados nos *slots* do estator do motor, qualificando uma medição distribuída, a fim de obter um mapeamento da temperatura ao longo do estator (Sousa, 2011; Haramoni et al., 2008).

Em (Avolio, 1992) verifica-se um método de medição de temperatura de motores desenvolvido exclusivamente para este fim, o qual versa na utilização de termopares inseridos nos núcleos do estator e do rotor. O sinal de temperatura é convertido em sinal elétrico e com isso monitorado através de dispositivos específicos. Assim, o uso destes sensores geralmente tem associado um custo elevado e, por vezes, invasivo na máquina. Dessa forma, justifica-se a necessidade do uso de estimadores de temperatura para atuar na proteção do equipamento.

O uso de sistemas inteligentes vem destacando-se na identificação de falhas em máquinas elétricas. De forma a tratar com robustez as incertezas no processamento de dados utiliza-se as Redes Neurais Artificiais (RNA) (Suetake, 2012).

Em (Niewierowicz, 2011) é apresentado uma metodologia para estimar as perdas elétrica e magnética de um motor, utiliza-se de uma rede Perceptron Multicamadas (PMC). A rede tem como entrada: a temperatura em dois pontos do estator, o coeficiente de transferência de calor convectiva e o tempo, já como saída tem-se a perda elétrica e a perda magnética.

A proposta deste trabalho consiste na apresentação de uma metodologia para monitorar e estimar a temperatura na carcaça de um motor de indução trifásico utilizando apenas um sensor de baixo custo e RNA.

O artigo está dividido nas seguintes seções: A Seção 2 apresenta os aspectos relativos à modelagem térmica do MIT; a Seção 3 descreve as RNAs presentes no método e na Seção 4 é exibido o método preditor proposto neste trabalho. Finalmente, na Seção 5 expõem-se as conclusões deste artigo.

2 Modelagem Térmica da Máquina

Segundo (Avolio, 1992), o modelo térmico do motor de indução trifásico baseia-se na analogia existente entre o comportamento de um circuito elétrico tipo RC alimentado por uma fonte de corrente e o comportamento térmico da máquina. Embora ela seja composta por partes que se diferenciam fisicamente, quando feita a análise do comportamento térmico de somente algumas dessas partes, pode ser utilizada a teoria do aquecimento de um corpo sólido ideal, ocasião em que o calor é dissipado uniformemente por toda sua superfície, conforme a seguinte expressão (Avolio, 1992). Assim tem-se:

$$Q \cdot dt - A \cdot \lambda \cdot \theta \cdot dt = m \cdot c \cdot d\theta \quad (1)$$

onde:

Q é a energia térmica por unidade de tempo (W);

A é a área da superfície do corpo (m^2);

λ é o coeficiente de transmissão de calor do corpo ($\frac{W}{c \cdot m^2}$);

θ é a temperatura do corpo ($^{\circ}C$);

m é a massa do corpo (Kg);

c é o calor específico do material que constitui o corpo ($\frac{W \cdot s}{kg \cdot ^{\circ}C}$).

Assim, através do exposto acima, a obtenção da temperatura na máquina pelo uso do modelo matemático exige conhecer os parâmetros térmicos do motor em análise. Estes parâmetros variam conforme o projeto da máquina. Desta maneira, faz-se necessária a utilização de um procedimento de baixo custo para avaliar a temperatura no motor independente dos parâmetros térmicos da máquina.

3 Redes Neurais Artificiais

Inspiradas no sistema nervoso dos seres vivos e modeladas computacionalmente, as Redes Neurais Artificiais (RNA) são caracterizadas por neurônios artificiais ligados entre si por interconexões, as quais são denominadas *sinapses artificiais* e representadas por vetores ou matrizes de pesos sinápticos.

As RNA's podem ser definidas como um conjunto de unidades de processamento e possuem a capacidade de manutenção e aquisição do conhecimento baseado em informações. Dentre suas principais características estão: adaptação por experiência, capacidade de aprendizado, habilidade de generalização, organização de dados, tolerância a falhas, armazenamento distribuído e facilidade de prototipagem (Silva et al, 2010). Dessa forma existe a possibilidade

do desenvolvimento de modelos capazes de realizar predições sobre o comportamento de um determinado processo, e também executar ações que visam o controle adequado do mesmo.

Junto ao grande avanço tecnológico, os microprocessadores tiveram seu poder computacional aumentado, favorecendo a utilização de redes neurais como uma nova alternativa na solução de problemas complexos em diversas áreas, entre elas a detecção de falhas em máquinas elétricas.

Dessa maneira, propõe-se nesse trabalho a utilização de duas topologias neurais com o objetivo de estimar a temperatura na carcaça do motor.

3.1 Neurônio Artificial

O modelo simplificado do neurônio biológico 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.

O funcionamento de um neurônio descreve-se pela seguinte equação matemática:

$$Y = g \left(\sum_{i=1}^n W_i \cdot X_i + b \right) \quad (2)$$

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.

Diversas topologias de RNA são obtidas com base na estrutura do neurônio artificial, podendo ser classificadas como redes de camada única ou redes multicamadas.

3.2 Redes Multicamadas

Com o objetivo de proteger termicamente o MIT propõe-se a utilização de uma RNA para estimar a temperatura em sua carcaça. Para esta finalidade, Segundo Silva et al. (2010), podem ser usadas a rede *perceptron* multicamadas e a rede de Função Base Radial (*Radial Base Function* - RBF).

Com uma arquitetura *feedforward*, constituída por pelo menos uma camada neural escondida e uma camada neural de saída, as redes *perceptron* de múl-

tiplas camadas (PMC) da Figura 1, possui treinamento realizado de forma supervisionada. De forma adequada à determinada aplicação a rede ajusta seus respectivos pesos sinápticos.

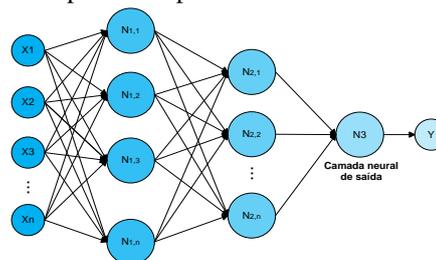


Figura 1 – Estrutura de uma rede neural PMC.

Ao confrontar com as redes PMC, observa-se distinção de estrutura das redes RBF que tipicamente são constituídas por uma camada de entrada, apenas uma camada neural intermediária com função de ativação do tipo gaussiana e uma camada de saída que contém função de ativação do tipo linear, como apresentado na Figura 2 (Silva et al., 2010).

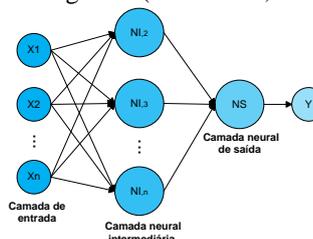


Figura 2 – Estrutura de uma rede neural RBF.

O treinamento da camada intermediária e o treinamento da camada de saída são duas etapas bem distintas que constituem o treinamento da RBF. A fase inicial trata do ajuste dos pesos dos neurônios da primeira camada, adotando um método de aprendizagem dependente apenas das características dos dados da entrada. No momento seguinte a regra delta generalizada é utilizada como critério de aprendizagem, realizando o ajuste dos pesos dos neurônios da última camada (Haykin, 2001).

4 Preditor de Temperatura

A metodologia proposta neste trabalho tem por base o monitoramento de temperatura na carcaça de uma máquina de indução trifásica. Utiliza-se uma placa de condicionamento de sinais para a temperatura e uma placa para o acionamento do motor através da interface com uma placa de aquisição de dados em conjunto com o Software Matlab.

O monitoramento da temperatura é possível mediante utilização de um sensor de temperatura de baixo custo (LM35) inserido estrategicamente na

carcaça do motor e ligado a uma placa de condicionamento de sinais, que recebe o endereçamento externo da placa de aquisição (Drummond et al., 2013). Os dados registrados são tratados e apresentados às duas topologias de rede neural artificial.

O acionamento do motor ocorre de forma automatizada, através de portas do PC, onde são controladas cargas de maior potência que a suportada. Neste caso, é usada uma placa baseada em sistema opto acoplado (4N25), o qual isola o sistema de acionamento do PC.

Para comunicação entre o software Matlab (PC) e a placa de proteção, para acionar e adquirir dados do motor foi utilizada a placa de aquisição de dados produzida pela National Instruments, denominada NI USB-6009.

Com o intuito de automatizar a aquisição de dados, foi utilizado um algoritmo no software Matlab que realiza, automaticamente, diversas tarefas como: acionamento do motor, proteção deste através do monitoramento de temperatura, endereçamento dos sensores, aquisição e armazenamento de dados, monitoramento da temperatura em tempo real, apresentação ao usuário de importantes informações e exportação dos dados registrados.

Tais medidas auxiliam na identificação de falhas no motor, na verificação dos efeitos de problemas de qualidade de energia e atua na proteção térmica, através do sensoriamento da temperatura na carcaça deste.

Na Figura 3 é possível observar o esquema de funcionamento do método de monitoramento e aquisição de dados descrito e a estrutura de ensaios presentes em (Drummond et al., 2013).

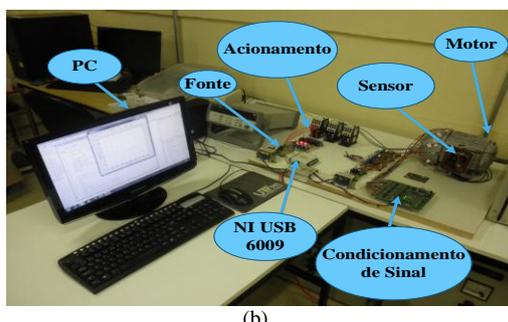
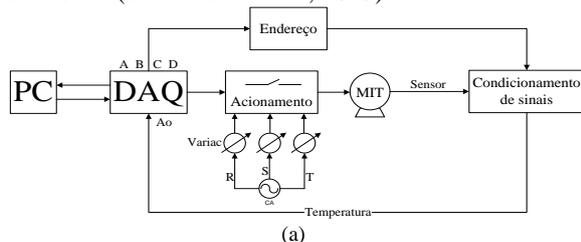


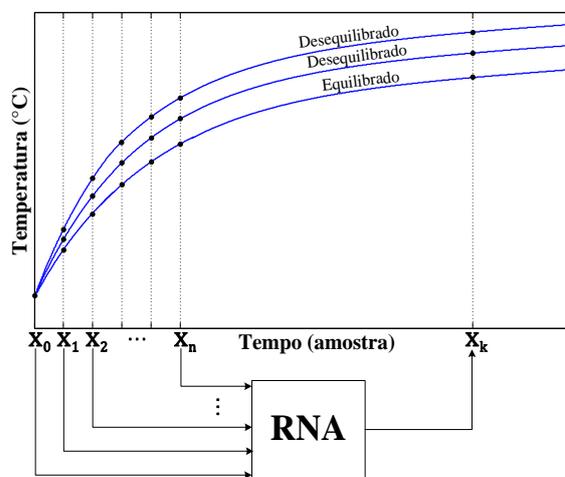
Figura 3 – a) Diagrama do sistema de monitoramento e aquisição de dados; b) Estrutura de ensaios.

A estrutura de ensaios exposta anteriormente permitiu a realização das rotinas de experimentação em laboratório, onde o motor foi submetido a diversas condições de alimentação, com o intuito de analisar o comportamento térmico da carcaça.

Adquiriram-se os dados de temperatura em quatro circunstâncias distintas de alimentação, inicialmente com tensões equilibradas e na sequência desequilíbrios de três, seis e dez por cento em uma fase.

Dentre as treze amostragens executadas, em seis o motor encontrava-se em condições ideais de alimentação, porém nas sete restantes continha desbalanço de tensão. O tempo médio total de cada rotina de aquisição foi de aproximadamente 67 minutos, onde se registrou em média a temperatura a cada 217 milissegundos e 18551 amostras.

Como ilustrado na Figura 4, a curva que caracteriza o aquecimento da carcaça da máquina é matematicamente descrita pela soma de duas exponenciais (Avolio, 1992). A variável “x” representa as amostras no eixo horizontal, “n” é o número de entradas da rede e “k” é a posição da amostra estimada pela rede. No eixo vertical estão as temperaturas aferidas na carcaça do motor.



Nas proximidades da amostra de número dez mil, equivalente a 36 minutos, a temperatura começa a se estabilizar. Tendo em vista tal comportamento, organizou-se uma matriz de 13 linhas e 10000 colunas, sendo que cada linha representa uma situação de alimentação.

Com o objetivo de reduzir o número de entradas da rede dois tratamentos de sinais foram elaborados. No primeiro os 1000 dados (3,6 minutos de operação) iniciais foram subamostrados obtendo como resultado uma matriz 13x50, já no segundo apenas as primeiras 500 amostras (1,8 minutos de operação) originaram uma matriz de mesma dimensão. Cada

matriz foi fragmentada em duas outras, sendo setenta por cento para o treinamento e trinta por cento para a validação. Na divisão garantiu-se a presença de vetores que representam todos os tipos de alimentação tanto para o treinamento quanto para a validação. Os vetores com os valores máximos e mínimos estão presentes no treinamento para assegurar a validação dentro do domínio de treinamento.

Após cumprir as etapas descritas anteriormente, os dados foram submetidos a quatro arquiteturas de rede com duas topologias distintas, as quais são exibidas na Tabela 1.

Tabela 1 – Estrutura das RNAs

Tipo	Rede 1	Rede 2	Rede 3	Rede 4
Arquitetura	PMC	RBF	PMC	RBF
Treinamento	PS	PS	PS	PS
Nº Camadas	2	2	2	2
Neurônios 1ª Camada	5	9	6	9
Neurônios 2ª Camada	1	1	1	1
Algoritmo de treinamento	BP+LM	Auto Organizado/ Regra Delta	BP+LM	Auto Organizado/ Regra Delta
Função de ativação 1ª Camada	Tangente Hiperbólica	Gaussiana	Tangente Hiperbólica	Gaussiana
Função de ativação 2ª camada	Linear	Linear	Linear	Linear

(BP) Backpropagation, (LM) Levenberg Maquardt

Conforme proposto, as redes foram submetidas ao treinamento com uma determinada taxa de aprendizado e como critério de parada o erro quadrático médio (EQM). Estes parâmetros são apresentados na Tabela 2 e foram definidos de forma a encontrar um melhor desempenho de cada rede.

Tabela 2 – Parâmetros das redes

Tipo	Rede 1	Rede 2	Rede 3	Rede 4
Curva de treinamento	9	9	9	9
Curva de validação	4	4	4	4
EQM	$1e^{-2}$	$1e^{-10}$	$1e^{-2}$	$1e^{-10}$
Coef. de aprendizado	0,001	0,001	0,001	0,001
Épocas	36	124270	108	3870810

Os resultados encontrados na fase de validação para as quatro redes estão dispostos na Tabela 3 e na Tabela 4. Na primeira utilizou-se amostras referentes a 3,6 minutos iniciais de aquecimento para estimar a temperatura 32,4 minutos de operação à frente, de forma análoga na segunda com 1,8 minutos de operação prediz-se 16,2 minutos adiante. As condições de

validação de “A” a “H”, bem como o acerto porcentual das redes também estão presentes nas seguintes tabelas.

Tabela 3 – Resultados das redes 1 e 2

Tipo	A	B	C	D
Desequilíbrio de tensão	Não	Sim	Sim	Sim
Tempo de amostragem [min.]	3,6	3,6	3,6	3,6
Instante de predição [min.]	36	36	36	36
Temperatura Real [°C]	52,8743	54,0726	52,7615	57,2517
Temperatura Estimada Rede 1 [°C]	52,9404	54,4211	52,8089	57,5825
Temperatura Estimada Rede 2 [°C]	51,2156	53,6890	53,1286	55,9013
Acerto Rede 1 [%]	99,8750	99,3555	99,9102	99,4222
Acerto Rede 2 [%]	96,8629	99,2906	99,3042	97,6413

Para o primeiro conjunto de dados a Rede 1 estabeleceu um acerto máximo de 99,91% e mínimo de 99,35% necessitando de apenas 36 épocas para atingir o critério de parada, enquanto que a Rede 2 precisou de um número maior de épocas, totalizando 124270 com acerto máximo de 99,30% e mínimo de 96,86%

Tabela 4 – Resultados das redes 3 e 4

Tipo	E	F	G	H
Desequilíbrio de tensão	Não	Sim	Sim	Sim
Tempo de amostragem [min.]	1,8	1,8	1,8	1,8
Instante de predição [min.]	18	18	18	18
Temperatura Real [°C]	47,0726	47,3815	46,4848	50,3190
Temperatura Estimada Rede 3 [°C]	46,9162	47,2086	46,4570	50,1005
Temperatura Estimada Rede 4 [°C]	45,4759	45,9615	46,1364	49,6762
Acerto Rede 3 [%]	99,6677	99,6351	99,9402	99,5658
Acerto Rede 4 [%]	96,6080	97,0030	99,2505	98,7224

Para o segundo grupo de amostras a Rede 3 obteve um acerto mínimo de 99,57% de acerto e máximo de 99,94% demandando 108 épocas para convergir, já a Rede 4 exigiu 3870810 épocas apresentando um mínimo de 96,61% de acerto e máximo de 99,25%.

Em todos os ensaios realizados o motor operou sem carga e partiu em temperatura ambiente, podendo variar em até 4 graus.

5 Conclusão

Neste trabalho é apresentada uma metodologia para monitorar através de estimativa a temperatura na carcaça do MIT de forma não invasiva e de baixo

custo. Apenas um sensor é usado para monitorar o aquecimento na carcaça da máquina e as redes neurais artificiais são usadas para prever o valor da temperatura em momentos futuros.

As amostras coletadas foram condicionadas de duas formas distintas e usadas para o treinamento e validação de quatro redes em duas condições diferenciadas. Todas as redes demonstram-se capazes de estimar temperatura de forma satisfatória. As redes PMC descaram-se perante as RBF pelo fato de convergirem com um número menor de épocas e serem mais precisas.

Os estudos demonstraram a aplicabilidade do sistema para monitorar e prever a temperatura na carcaça do motor. Em uma ou mais das condições citadas na seção 1 deste artigo ou quaisquer outras situações, que submetam o MIT a temperaturas que ultrapassam o seu limite térmico, podem ser detectadas pelo sistema para a proteção da máquina contra esses distúrbios, pois, conforme exposto, as falhas normalmente implicam na elevação de temperatura da carcaça da máquina.

Agradecimentos

Este trabalho conta com o apoio da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná (Processo N° 06/56093-3), do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Processo N°474290/2008-5, 473576/2011-2, 552269/2011-5).

Referências

- Abreu, J. P. G de. and A. E. Emanuel. (2002). Induction Motor Thermal Aging Caused by Voltage Distortion and Imbalance: Loss of Useful Life and Its Estimated Cost. *IEEE Transactions on Industrial Applications*.
- ANEEL-PRODIST. Módulo-8: Qualidade da Energia Elétrica <http://www.aneel.gov.br/arquivos/PDF/Modulo8_Revisao4.pdf>, Acesso em: 04/03/2012.
- Anwari, M.I and A. Hiendro. (2010). New unbalance factor for estimating performance of a threephase induction motor with under- and overvoltage unbalance. *IEEE Transactions on Energy Conversion*, 25(3):619{625.
- Avolio, E. (1992). Uma Contribuição ao Estudo do Comportamento Térmico e do Desempenho Elétrico de Motores de Indução com Rotor em Gaiola. Doutorado, Faculdade de Engenharia Elétrica da Universidade Estadual de Campinas (UNICAMP).
- Bonnett, A. H. and G. C. Soukup. (1992). Causes and analysis of stator and rotor failures in three-phase induction motors. *IEEE Trans. Ind. Appl.*, vol. 28, no. 4, pp. 921–937.
- Bouzid, M., G. Champenois. (2012). New expressions of symmetrical components of the induction motor under stator faults. *Industrial Electronics, IEEE Transactions on*.
- Drummond, T. L., A. Goedel, D. Mizuyama, W. F. Costa. (2013). Método de Avaliação da Temperatura Discreto e Distribuído na Carcaça do Motor de Indução Trifásico Utilizando Sensores de Baixo Custo. Conferência Brasileira sobre Qualidade da Energia Elétrica. (ARTIGO ACEITO).
- ELETROBRÁS-PROCEL.
<<http://www.procelinfo.com.br>>, Acesso em: 11/12/2012.
- Fitzgerald, A. E., C. Kingsley Jr., and S. D. Umans. (2006) Máquinas Elétricas. Bookman Companhia Editora, Porto Alegre, 6 edition.
- Goedel, A. (2007) Estimador de velocidade em motores de indução trifásicos usando redes neurais artificiais. Doutorado, Escola de Engenharia de São Carlos da Universidade de São Paulo (EESC-USP).
- Haramoni, N.; A. S. Paterno; A. Goedel; G. Soares; J. C. C. Silva; H. J. Kalinowski. (2008). Hybrid Wavelength-Time-Domain Interrogation System for Multiplexed Fiber Bragg Sensors Using a Strain-Tuned Erbium-Doped Fiber Laser (Qualis Engenharia IV). *IEEE Sensors*.
- Haykin, S. 2001 *Redes Neurais: Princípios e Prática*. Porto Alegre: Bookman.
- Niewierowicz, T.; Kawecki, L.; Napieralska, E. (2011). Determination of Electromagnetic Losses in Electric Motors Applying Neural Networks. *Latin America Transactions, IEEE (Revista IEEE America Latina)*.
- Oliveira, J. E. A. de. (2011). Modelagem de um Motor de Indução Trifásico Operando com Tensões Desequilibradas por meio de Redes Neurais Artificiais. Mestrado, Unesp Bauru.
- Picazo-Ródenas, M. J., R. Royo, J. Antonino-Daviu, J. Roger-Folch. (2012). Use of Infrared thermography for computation of heating curves and preliminary failure detection in induction motors. *IEEE Transactions on Industrial Applications*.
- Silva, I. N. da, D. H. Spatti, e R. A. Flauzino. (2010). *Redes Neurais Artificiais*. Artiliber, São Paulo, SP.
- Sousa, K. M. (2011). Validação de Modelo Térmico e Elétrico de Motor de Indução Empregando Redes de Bragg em Fibra Ótica”. Mestrado, UTFPR Pato Branco, PR.
- Suetake M., I. N. da Silva, and A. Goedel. (2011). Embedded dsp-based compact fuzzy system and its application for induction-motor v/f speed control. *Industrial Electronics, IEEE Transactions on*.
- Suetake, M. (2012). Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos. *Tese de Doutorado*. São Carlos: Universidade de São Paulo.
- Toliyat, H. A. and G. B. Kliman. (2004). *Handbook of Electric Motors*. New York: Marcel Dekker.
- Wang, Y. J. (2001). Analysis of Effects of Three-Phase Voltage Unbalance on Induction Motors with Emphasis on the Angle of the Complex Voltage Unbalanced Factor,” *IEEE Trans. on Energy Conversion*, vol. 16, no. 3, pp. 270- 275.