

# ESTRUTURA NEURAL PARA ESTIMATIVA DE VELOCIDADE EM MOTORES DE INDUÇÃO TRIFÁSICOS BASEADA EM DADOS EXPERIMENTAIS E SIMULADOS

ALESSANDRO GOEDEL<sup>†</sup>, IVAN N. SILVA<sup>\*</sup>, PAULO J. A. SERNI<sup>‡</sup>, CLAUDIA F. L. N. SOUSA<sup>†</sup>

<sup>†</sup>*Departamento Engenharia Elétrica, Universidade Tecnológica Federal do Paraná (UTFPR-CP)  
Av. Alberto Carazzai, 1640, Cornélio Procópio, PR, CEP 86300-000*

<sup>\*</sup>*Departamento Engenharia Elétrica, Universidade de São Paulo (EESC-USP)  
Rua Trabalhador São Carlense 400, São Carlos, SP, CP 359, CEP 13566-590*

<sup>‡</sup>*Departamento Engenharia Elétrica, Universidade Estadual Paulista (FEB-UNESP)  
Av. Eng. Luiz Edmundo C. Coube 14-01, Bauru, SP, CEP 17033-360*

*E-mails: {agoedtel, cnaves}@utfpr.edu.br,  
insilva@sel.eesc.usp.br, paulojas@feb.unesp.br*

**Abstract**— This work presents an alternative approach to estimate speed in induction motors based on artificial neural network and the measure of primary variables like voltage and current. The use of induction motors is very common in many industrial sectors and plays an important role in the national energetic scene. The methodologies used in control, start up and dimensioning of these motors are based on measure of speed variable. However, the direct measure of this variable compromises the control system and start up of the machine, reducing its robustness and increasing the implementation costs. Simulation results and experimental data are presented to validate the proposed approach.

**Keywords**— Induction motors, artificial neural networks, speed estimation.

**Resumo**— Este trabalho apresenta uma estratégia alternativa para a estimativa de velocidade em motores de indução trifásicos baseada em redes neurais artificiais e utilizando medidas de variáveis primárias como tensão e corrente. O uso de motores de indução trifásicos é uma constante em diversos setores industriais e de grande importância no cenário energético nacional. A maioria das metodologias de controle, acionamento e dimensionamento destes motores é fundamentada nas medidas de velocidade no eixo. Entretanto, a medida direta da velocidade compromete o sistema de controle e acionamento, diminuindo sua robustez e aumentando o custo de implementação. Resultados de simulação e ensaios experimentais são apresentados para validação do método proposto.

**Palavras-chave**— Motores de indução, redes neurais artificiais, estimadores de velocidade.

## 1 Introdução

Os Motores de Indução Trifásicos (MIT) são usados em muitos setores industriais, sendo o principal elemento para converter energia elétrica em mecânica motriz. Suas principais características se fundamentam no baixo custo e robustez.

As aplicações destes motores podem ser divididas em dois grandes grupos: o primeiro grupo é aquele em que o motor trabalha sempre à mesma velocidade, ou seja, uma vez dada sua partida, não há elemento de controle sobre sua velocidade ou regime de operação. O segundo grupo, por sua vez, é aquele onde os processos em que os motores estão acoplados necessitam a aplicação de uma metodologia de controle (escalar ou vetorial). Em ambos os grupos, nas diversas aplicações dos setores produtivos, há a necessidade de conhecer a velocidade no eixo da máquina de indução. A variável em questão pode ser medida diretamente ou estimada.

A velocidade nos eixos dos motores de indução é medida com encoders ópticos, resolvers eletromagnéticos ou tacogeradores baseados em motores de corrente contínua sem escovas.

Entretanto, o uso destes dispositivos eletromecânicos apresenta certa limitação em sua aplicação, tais como o aumento do custo do dispositivo de acionamento, redução da robustez mecânica, baixa imunidade ao ruído, alteração da inércia da máquina, além de exigir especial atenção em ambientes hostis (Vas, 1998).

O uso de técnicas *sensorless* se encontra principalmente em aplicações de alto desempenho como Controle Vetorial (CV) e Controle Direto de Torque (CDT). As principais metodologias empregadas originam-se em estimadores de malha aberta com monitoramento de corrente e tensão do estator, observadores de estado, sistemas de referência com modelos adaptativos e estimadores baseados em sistemas inteligentes, os quais advêm principalmente das Redes Neurais Artificiais (RNA) e lógica fuzzy (Vas, 1998).

Em termos de eficiência energética, no trabalho de El-Ibiary (2003) foi proposto um método alternativo e de baixo custo para determinação da eficiência energética de um motor de indução instalado numa planta industrial. A metodologia proposta pelo autor utiliza medidas de tensão, corrente e potência de entrada, resistência de estator e a velocidade no rotor. Em Damasceno et al. (2002),

os autores sugerem dois métodos para determinação do rendimento do motor. Em ambos os métodos há a necessidade de medida de velocidade no eixo do motor, além da medição de potência elétrica.

Alguns métodos de acionamento de máquinas elétricas, também muito utilizados na indústria, requerem o conhecimento da velocidade do motor de indução para o instante exato da comutação das contadoras a exemplo da metodologia denominada partida estrela-triângulo. Conforme as considerações sobre métodos de partida no manual de um fabricante nacional de motores, espera-se que a velocidade atinja entre 90% e 95% de sua rotação nominal para comutar da posição estrela para triângulo num MIT.

Desta forma, há a necessidade de medir (ou estimar) a velocidade do MIT com o objetivo de determinar o exato, ou aproximado, instante de comutação da chave (Goedtel et al., 2006). Atualmente, esta comutação é feita de forma manual com a intervenção do operador ou através de um circuito temporizador. Entretanto, a imprecisão destes métodos (manual ou temporizado) pode acarretar valores de pico de corrente de linha muito próximos aos verificados na partida direta.

A maioria dos estimadores de velocidade tem sua gênese no modelo matemático do motor de indução aplicado no processo de estimativa de velocidade e necessitam de um conhecimento preciso de todos os parâmetros do motor, incluindo a resistência do estator conforme Vasic et al. (2003). O valor exato da resistência de estator é de crucial importância para a correta operação do dispositivo *sensorless* na região de baixa velocidade do motor. O erro entre o valor da resistência usado no modelo e o valor real é responsável por não apenas pelo erro do estimador de velocidade, mas pela instabilidade no controle.

Diversos pesquisadores propuseram o uso das RNA como estimadores de velocidade a exemplo do trabalho de Kim et al. (2001) entre outros. O trabalho citado, por exemplo, usa dois observadores de fluxo para alimentar a entrada da rede e proceder ao treinamento para adaptação dos pesos sinápticos da estrutura neural em tempo real.

Por outro lado, em Kukulj et al. (2000), há uma comparação entre o controle do motor de corrente contínua usando as redes neurais artificiais, lógica nebulosa e o controle proporcional-integral tradicional. Já em Campbell et al. (2000) e em Campbell e Summer (2002) foi desenvolvido um sistema de acionamento de alto desempenho para motores de indução usando a técnica *sensorless* obtendo boa resposta dinâmica em relação ao conjugado e velocidade. Os resultados deste trabalho foram comparados pelo autor do artigo com a técnica de controle vetorial indireto, onde a principal dificuldade na técnica tradicional é a correta sintonização dos parâmetros do controlador. Melhorias significativas foram conseguidas neste trabalho usando as redes neurais artificiais.

Mais recentemente, o trabalho de Kaijan et al. (2005) propõe o uso das RNA para um estimador de conjugado e Transformada de Park d-q para um controle a laço aberto. Os autores concluem que o desempenho da rede foi superior ao cálculo da transformada por DSP (*Digital Signal Processing*) e ao estimador de conjugado.

A proposta do presente trabalho é o desenvolvimento de um estimador de velocidade usando RNA com treinamento supervisionado. Os dados de treinamento são gerados a partir da simulação do modelo matemático do motor de indução e o treinamento da rede é realizado de forma *off-line*, reduzindo o esforço computacional do dispositivo de controle na aplicação em questão.

De forma a validar a proposta, dados experimentais são apresentados à RNA treinada com dados de simulação. Num segundo instante, a estrutura neural é re-treinada e validada com dados experimentais. Os resultados de generalização de ambas as abordagens são também apresentados.

A organização deste trabalho está como se segue: Na Seção 2 serão apresentados os aspectos da modelagem matemática do motor de indução. Na Seção 3 serão apresentados os princípios associados às RNA. Na Seção 4 serão apresentados os resultados de simulação, bem como a validação da estrutura proposta. Finalmente, na Seção 5 serão apresentadas as conclusões deste trabalho.

## 2 Aspectos da Modelagem do Motor de Indução

O primeiro passo envolvido no treinamento de uma rede neural artificial é compilar o conjunto de padrões de entrada e saída com o objetivo do ajuste dos parâmetros internos da rede (pesos sinápticos). Este procedimento é conhecido como processo de treinamento e deve-se assegurar que a rede é exposta a seqüências de padrões que descrevam de forma satisfatória o comportamento do sistema analisado.

Com o propósito de gerar os padrões de treinamento para estimativa de velocidade do motor de indução, quando em diferentes situações de carga, realizaram-se várias simulações utilizando a ferramenta Matlab/Simulink. O diagrama em blocos da Fig. 1 descreve as entradas e saídas do modelo proposto.




Figura 1. Diagrama em blocos do modelo do MIT.

O modelo do motor de indução usado nas simulações foi desenvolvido em Ong (1997). Devido ao curto intervalo de tempo, o efeito da temperatura não foi considerado nas simulações.

Os parâmetros da máquina como tensão, parâmetros elétricos do rotor e estator, momento de inércia da carga e do rotor, e conjugado de carga são as entradas do modelo. A corrente elétrica, o conjugado eletromagnético e a velocidade do rotor são as saídas do modelo. Estas variáveis serão usadas no processo de treinamento das redes neurais.

A função  $f(\omega)$  representa as diversas cargas que podem ser simuladas. Para o estudo aqui desenvolvido será considerado um tipo de carga; a saber: a linear. Esta carga apresenta um aumento do conjugado de carga com o incremento da velocidade de forma linear, sendo bastante encontrada em aplicações como ventiladores, moinhos de rolos, bombas de pistão e serras para madeira (Dias e Lobosco, 1988).

A Fig. 2 apresenta a sistemática de simulação do MIT para geração dos dados de treinamento. Na região limitada pelas curvas  $C_1$  a  $C_{26}$  é realizada a estimativa de conjugado pela RNA. É importante notar que o mapeamento produz valores diferentes de conjugado (partida e regime permanente) para cada curva, dependendo do valor de tensão usado na alimentação do motor, conforme interseção das curvas de mapeamento e conjugado do motor.




Figura 2. Sistemática de simulação do MIT.

A Tabela 1 apresenta os parâmetros elétricos e mecânicos da máquina de indução utilizados nas simulações.

TABELA 1. Parâmetros do MIT.

Linha Standard – IV Pólos – 60Hz – 220/380V

Potência	1 cv
Resistência de Estator	7,32 $\Omega$
Resistência de Rotor	2,78 $\Omega$
Indutância de Estator	8,95.10 <sup>-3</sup> H
Indutância de Rotor	5,44.10 <sup>-3</sup> H
Indutância de Magnetização	1,41.10 <sup>-3</sup> H
Momento de Inércia do Rotor	2,71.10 <sup>-3</sup> kg.m <sup>2</sup>
Velocidade Síncrona	188,49 rad/s
Escorregamento Nominal	3,8%
Torque Nominal	4,1 Nm

### 3 Estimador de Velocidade Usando RNA

O uso de Redes Neurais Artificiais (RNA) tem se mostrado eficiente na resolução de uma série de problemas de engenharia. Neste trabalho se utiliza a RNA para estimar a velocidade do rotor nas máquinas de indução como ferramenta alternativa aos métodos convencionais. A rede escolhida foi a *perceptron* multicamada com treinamento supervisionado (Haykin, 1999).

A RNA proposta é treinada de forma *offline* utilizando os dados de treinamento levantados a partir da simulação do modelo da máquina. No sentido de verificar a robustez do modelo proposto, dados experimentais são apresentados à estrutura neural previamente treinada. De forma complementar, investiga-se os resultados de generalização numa RNA treinada e testada com dados experimentais.

A estrutura do estimador neural, após ser otimizada, possui cinco neurônios na primeira camada escondida, dez neurônios na segunda camada escondida e um neurônio na camada de saída.

O neurônio artificial com  $y_j(k)$  que é o sinal de saída do  $j$ -ésimo neurônio no instante  $k$ ,  $w_i$  que é o peso associado com o  $i$ -ésimo sinal de entrada e  $X_i$  que é o  $i$ -ésimo sinal de entrada do neurônio, presente na Fig. 3, pode ser modelado matematicamente como segue:

$$v_j(k) = \sum_{i=1}^m X_i \cdot w_i + b \quad (1)$$

$$y_j(k) = \phi_j(v_j(k)) \quad (2)$$

onde:

- $m$  é o número de sinais de entrada do neurônio;
- $b$  é o limiar de cada neurônio;
- $v_j(k)$  é a resposta do  $j$ -ésimo neurônio em  $k$ ;
- $\phi_j(\cdot)$  é a função de ativação do  $j$ -ésimo neurônio.




Figura 3. O neurônio artificial.

Cada neurônio artificial é capaz de, baseado nos sinais de entrada, computar a respectiva saída por intermédio do ajuste de seus pesos. A função de ativação de cada neurônio da primeira camada escondida é a função tangente hiperbólica enquanto a função de ativação do neurônio de saída é a função linear. O processo de ajuste dos pesos da rede ( $w_j$ ), associados ao  $j$ -ésimo neurônio de saída, é feito pelo cálculo do sinal de erro  $e_j(k)$  (entre a resposta desejada e a resposta estimada) em relação à  $k$ -ésima iteração ou  $k$ -ésimo vetor de entrada. Este sinal de erro é calculado da seguinte forma:

$$e_j(k) = d_j(k) - y_j(k) \quad (3)$$

onde  $d_j(k)$  é a resposta desejada do  $j$ -ésimo neurônio de saída. Somando-se todos os erros quadráticos produzidos pelos neurônios de saída da rede em relação à  $k$ -ésima iteração, tem-se:

$$E(k) = \frac{1}{2} \sum_{j=1}^p e_j^2(k) \quad (4)$$

onde  $p$  é número de neurônios da saída. Para uma configuração de pesos ótima,  $E(k)$  é minimizado por intermédio do ajuste dos pesos sinápticos  $w_{ji}$ . Os pesos associados à camada de saída da rede são recalculados usando a seguinte expressão:

$$w_{ji}(k+1) = w_{ji}(k) - \eta \frac{\partial E(k)}{\partial w_{ji}(k)} \quad (5)$$

O peso sináptico  $w_{ji}$  está conectando o  $j$ -ésimo neurônio da camada considerada ao  $i$ -ésimo neurônio da camada anterior, sendo  $\eta$  a constante que determina a taxa de aprendizado do algoritmo de retropropagação. O ajuste dos pesos pertencentes às camadas escondidas é feito de forma análoga. Os passos para o ajuste destes pesos são detalhados na bibliografia consultada (Haykin, 1999).

A estrutura do estimador utilizado é apresentada na Fig. 4. A tensão e corrente de linha de entrada são apresentados à rede após o cálculo do valor eficaz.

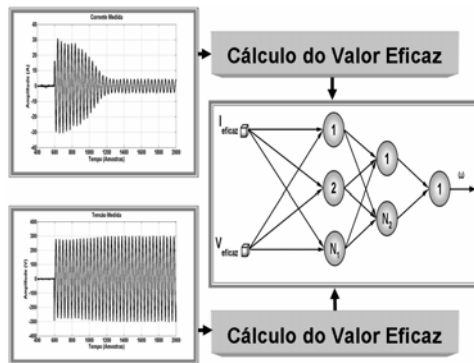


Figura 4. Estrutura de treinamento e teste da RNA.

#### 4 Resultados de Generalização

Os resultados de simulação confirmam o uso das RNA para estimar velocidade dos motores de indução. A investigação deste trabalho segue no sentido de verificar a robustez da estrutura neural proposta quando a esta são apresentados dados experimentais em duas situações; a saber: i) treinamento com dados de simulação e ii) treinamento com dados experimentais.

A bancada de testes é composta por uma máquina de corrente contínua, operando como geradora, conectada a um motor de indução trifásico através de acoplamentos elásticos, sendo que entre as máquinas há um torquímetro girante. A máquina de corrente contínua foi fornecida pela Varimot com potência de 2kW e excitação independente, enquanto que o torquímetro girante utilizado é o modelo MT-103 do fabricante Transtec. O motor de indução foi

fabricado pela WEG e os parâmetros levantados em laboratório são descritos na Tabela 1.

Especial atenção foi tomada para a questão do alinhamento das máquinas visando evitar vibrações que prejudicariam as medidas, em especial, do conjugado de carga.

As tensões e correntes da máquina CC como as da máquina CA foram medidas com sensores Hall do fabricante LEM. O encoder óptico, com saída *push-pull*, 2000 pontos por rotação, foi adquirido do fabricante Kuebler. A Fig. 5 mostra a bancada de testes.



Figura 5. Bancada de testes.

#### 4.1 Resultados de Generalização Utilizando Dados de Testes Experimentais

A RNA é treinada a partir de dados de simulação e os resultados apresentados são obtidos com base nos dados experimentais. A Fig. 6 apresenta os dados de generalização quando o MIT é submetido a um conjugado de carga, em regime permanente, de 2 Nm. A Fig. 7 ilustra o resultado de generalização do MIT quando o mesmo é submetido a um conjugado de carga em regime permanente de 3 Nm.

A Fig. 8 e Fig. 9 seguem as mesmas sistemáticas dos experimentos descritos na Fig. 6 e Fig. 7. Ou seja, aplica-se a partida com o MIT ligado em delta, tendo alimentação de 220V, e faz-se a aquisição dos dados da partida ao regime permanente. Entretanto, o conjugado de carga em regime permanente é de 4 Nm e 5 Nm, respectivamente.




Figura 6. Resultados de generalização com carga de 2 Nm e treinamento com dados de simulação.




Figura 7. Resultados de generalização com carga de 3 Nm e treinamento com dados de simulação.

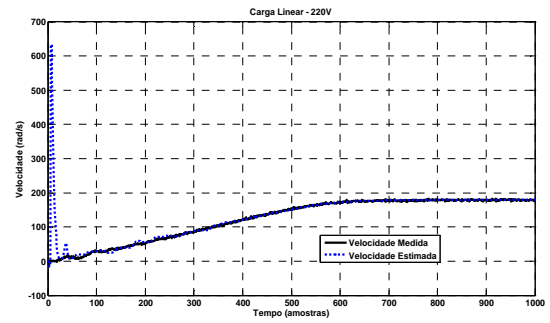


Figura 10. Resultados de generalização com carga de 2 Nm e treinamento com dados experimentais.

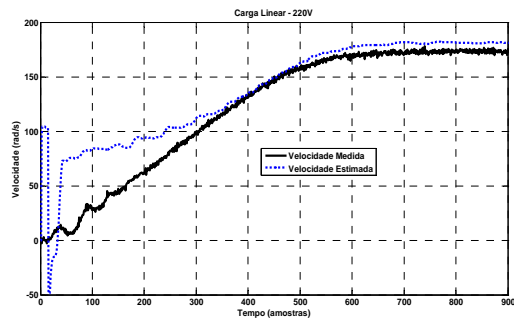


Figura 8. Resultados de generalização com carga de 4 Nm e treinamento com dados de simulação.

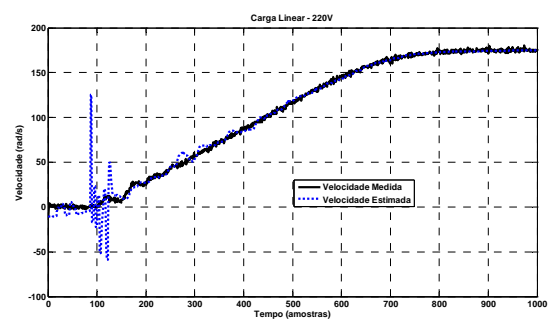


Figura 13. Resultados de generalização com carga de 3 Nm e treinamento com dados experimentais.

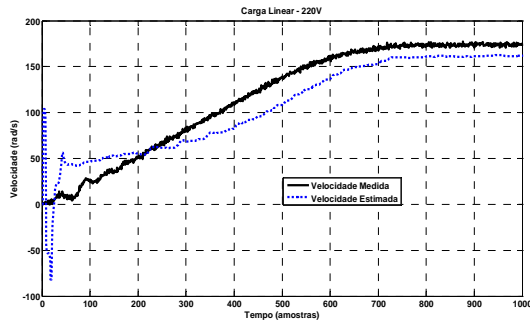


Figura 9. Resultados de generalização com carga de 5 Nm e treinamento com dados de simulação.

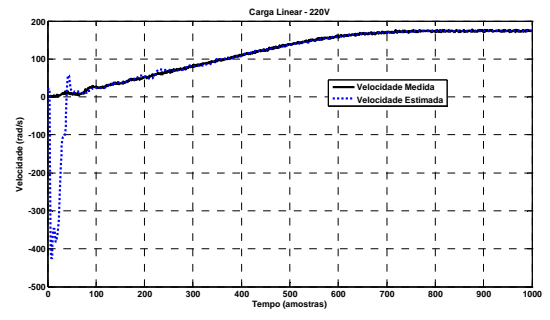


Figura 11. Resultados de generalização com carga de 4 Nm e treinamento com dados experimentais.

Com base nos gráficos apresentados pode-se inferir resultados de generalização em regime permanente muito próximos dos valores medidos pelo encoder óptico. Entretanto, em regime transitório, a diferença entre o valor medido e o estimado é um tanto elevado quando o MIT é submetido a diferentes valores de carga no eixo.

#### 4.2 Resultados de Generalização Utilizando Dados de Treinamento e de Teste Experimentais

Nesta subsecção são apresentados os resultados do re-treinamento da estrutura neural com dados experimentais e sua validação também com o mesmo tipo de dados. Os dados de teste são os mesmos utilizados na Fig. 6 a Fig. 9; quais sejam: tensão de alimentação de 220V e conjugado de carga de 2 Nm, 4 Nm, 5 Nm e 3 Nm conforme apresentado na Fig. 10 a Fig. 13.




Figura 12. Resultados de generalização com carga de 5 Nm e treinamento com dados experimentais.

Os dados de generalização apresentados na Fig. 10 a Fig. 13 demonstram redução substancial do erro no regime transitório e permanente após o treinamento da estrutura neural proposta com dados

experimentais coletados na bancada de testes. Entretanto, o erro na região de baixa velocidade (0 a 20 rad/s) continua alto.

## 5 Conclusão

Neste trabalho é apresentada uma metodologia alternativa em relação às convencionais para estimar a velocidade do motor de indução baseado em redes neurais artificiais com treinamento supervisionado.

A aplicabilidade da metodologia proposta contempla a estimativa de velocidade no regime permanente e transitório. No regime transitório, o erro é reduzido quando a rede é treinada com dados experimentais. Entretanto, a metodologia não se aplica as regiões de muito baixa velocidade (*very low speed*).

De forma complementar, pode-se concluir que o treinamento da estrutura neural deve conter dados que apresentem os diversos aspectos da dinâmica do sistema e sua variação paramétrica ao longo do regime de operação. No caso do MIT, a saturação eletromagnética, o efeito pelicular, as perdas por atrito e ventilação e a variação das resistências de rotor e estator com a temperatura são os principais parâmetros negligenciados na modelagem da máquina. O conceito pode ser estendido para outros sistemas não-lineares e variantes no tempo.

## Agradecimentos

Os autores agradecem o suporte do CNPq (142326/2005-4) e da FAPESP (03/11353-0 e 06/56093-3).

## Referências Bibliográficas

- Campbell, J. A., Summer, M. and Curtis, M. (2000). An improved sensorless vector controlled induction motor drive employing artificial neural networks for stator resistance estimation, *Proceedings of IEE Eighth International Conference on Power Electronics and Variable Speed Drives*, IEE Conf. Publ. No. 475, pp. 274-279.
- Campbell, J. A., Summer, M. (2002). Practical sensorless induction motor drive employing an artificial neural network for online parameter adaptation, *Proceedings of the IEE Electric Power Applications*, Vol.149, pp. 255-260.
- Damasceno, S. M., Cerqueira, J., Lima, A. C., Oliveira, A. (2002). Uma Proposta Para Avaliação do Rendimento de Motores Elétricos de Indução em Chão de Fábrica, *Proceedings of XIV Congresso Brasileiro de Automática* (CBA 2002), pp. 1136-1141.
- Dias, L. P. C., Lobosoco, O. S. (1998). Motores Elétricos: Seleção e Aplicação, vol. I, McGraw-Hill Inc..
- El-Ibiary, Y. (2003). An accurate low-cost method for determining electric motors' efficiency for the purpose of plant energy management. *IEEE Transactions on Industry Applications*, vol. 39, pp. 1205-1210.
- Goedel, A., Silva, I. N. da, Serni, P. J. A., Flauzino, R. A. (2006). Estratégia eficiente para acionamento estrela-triângulo de motores de indução usando redes neurais, *Proceedings of VII IEEE Induscon*, CD-ROM // Artigo EPA-IV\_3.
- Haykin, S. (1999). Neural Networks. McMillan Inc., 1998.
- Kaijan, M. W., Li, H. and Foo S. Y. (2005). Neural network modeling of torque estimation and d-q transformation for induction machine. *Artificial Intelligence*, Vol. 18, pp. 57- 63.
- Kim, H., Park, T. S., Yoo, J. Y. and Park, G. T. (2001). Speed-sensorless vector control of an induction motor using neural network speed estimation. *IEEE Transactions on Industrial Electronics*, Vol. XLVIII, 2001, pp. 609-614.
- Kukulj, D., Kulic, F. and Levi, E. (2000). Design of speed controller for sensorless electric drives based on AI techniques: a comparative study. *Artificial Intelligence in Engineering*, Vol. XIV, pp. 165-174.
- Ong, C. M. (1997). Dynamic Simulation of Electric Machinery Using Matlab/Simulink. Prentice Hall, 1997.
- Vas, P. (1998). Sensorless Vector and Direct Torque Control. Oxford University Press, 1998.
- Vasic, V., Vukosavic, S. N. and Levi, E. (2003). A stator resistance estimation scheme for speed sensorless rotor flux oriented induction motor drives. *IEEE Transactions on Energy Conversion*, Vol. XVIII, pp.476-483.