

UMA ABORDAGEM NEURAL APLICADA NO CONTROLE ESCALAR DO MOTOR DE INDUÇÃO TRIFÁSICO

TIAGO HENRIQUE DOS SANTOS*, ALESSANDRO GOEDEL*, SERGIO AUGUSTO OLIVEIRA DA SILVA*, CLAYTON LUIZ GRACIOLA*, PAULO BRONIERA JUNIOR*

* *Universidade Tecnológica Federal do Paraná - UTFPR*
Programa de Pós-Graduação em Engenharia Elétrica - PPGEE-CP
Av. Alberto Carazzini, 1640
Cornélio Procópio, PR, Brasil

Emails: tiago.santos@ifpr.edu.br, agoedel@utfpr.edu.br, augus@utfpr.edu.br, claytongraciola@gmail.com, paulobrj@gmail.com

Abstract— This work proposes an artificial neural network approach to estimate the induction motor speed applied in a slip-control. The induction motor speed is the important quantity in an industrial process. However, the direct measurement of speed compromises the driver system and control, besides increasing the implementation cost. The proposed strategy estimates the induction motor speed when it is driven by inverter with scalar-control. Simulation results are presented to validate the performance of the proposed method under motor load torque and speed reference point variations.

Keywords— Artificial Neural Network, Three-Phase Induction Motor, Speed Estimator, Intelligent Systems, Slip Control

Resumo— Este trabalho propõe uma abordagem baseada em redes neurais artificiais para estimar a velocidade do motor de indução aplicado em um controle escalar. A medida de velocidade de motores de indução têm grande importância nos mais diversos setores industriais. Contudo, a medida direta da velocidade diminui a robustez comprometendo o sistema de acionamento e controle bem como o aumento do custo de implementação. A proposta deste trabalho consiste em apresentar uma metodologia para estimar a velocidade a velocidade do motor de indução acionado por um inversor fonte de tensão com modulação vetorial-espacial aplicado ao controle escalar da máquina com controle escalar. Resultados de simulação são apresentados para validar o método proposto com o motor submetido a variações de velocidade e torque de carga.

Palavras-chave— Redes Neurais Artificiais, Motores de Indução Trifásicos, Estimador de Velocidade, Sistemas Inteligentes, Controle Escalar

1 Introdução

Motores de Indução Trifásicos (MIT) são usados em muitos setores industriais, sendo o principal elemento de conversão de energia elétrica em mecânica motriz. As estratégias de controle em malha fechada destas máquinas necessitam de acionamento baseado na medida direta ou estimada da velocidade.

A velocidade no eixo do motor de indução é comumente medida com encoders ópticos, resolvers eletromagnéticos ou tacogeradores. Entretanto, o uso destes dispositivos apresentam certas limitações em suas aplicações, tais como o aumento do custo do dispositivo de acionamento, redução da robustez mecânica, baixa imunidade ao ruído, alteração do momento de inércia da máquina, além de exigir cuidados especiais em ambientes hostis (Vas, 1998).

O uso destas metodologias é encontrado principalmente em acionamentos de alto desempenho como no Controle Vetorial (CV) e Controle Direto de Torque (CDT). As principais estratégias de controle *sensorless* têm como base os 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).

A maioria dos estimadores de velocidade tem origem no modelo matemático do motor de indução, onde é necessário o conhecimento preciso dos parâmetros elétricos e mecânicos do motor (Vasic et al., 2003).

Os estimadores de velocidade baseados em Observadores de Estado (OE) necessitam do valor preciso dos parâmetros da máquina para a correta operação do dispositivo *sensorless* nas regiões de baixa velocidade do MIT (Bose, 2002). Este método requer um esforço computacional maior, desde que o algoritmo que estima a velocidade necessita a resolução de equações diferenciais.

Recentemente, alguns trabalhos têm utilizado as RNAs como um método alternativo de estimação de parâmetros e velocidade de máquinas (Marei et al., 2009; Yuksel and Mehmet, 2011; Jevremovic et al., 2010; Gadoue et al., 2009). Em Marei et al. (2009) um estimador neural, tendo como saída a velocidade e a resistência rotórica de um MIT, utilizando uma rede ADALINE é apresentado. Nesta proposta a corrente e a tensão do estator da máquina são medidas no eixo de coordenadas estacionária trifásica.

Após a transformação do eixo *abc* para o eixo de coordenadas estacionária bifásica $\alpha\beta$, os sinais

são utilizados para estimar a corrente, o fluxo e a derivada do fluxo do rotor, sendo essas as variáveis de entrada da RNA. Para a validação do estimador neural de velocidade, aplica-se este em diversas estratégias de controle do MIT, como o controle escalar e o controle vetorial.

Um preditor neural de velocidade de um MIT utilizando uma rede Perceptron de Múltiplas Camadas (PMC) é apresentado em Yuksel and Mehmet (2011). As entradas desse estimador utilizam os dados de corrente e tensão do estator no eixo de coordenadas síncrona trifásica dq0. O conjunto de dados de treinamento e validação são adquiridos com a máquina de 2 pólos, 50Hz, operando em regime permanente e com variação de velocidade entre 500 a 1000 Revoluções Por Minuto (RPM).

Em Jevremovic et al. (2010) um modelo de referência adaptativo é utilizado para estimar a velocidade do MIT. O ajuste dos parâmetros do modelo de referência é realizado visando o cancelamento do erro entre a potência reativa de magnetização no rotor e a estimada pelo modelo adaptativo.

A aplicação de uma RNA na estimação do fluxo magnético do entreferro de um MIT pela aquisição da tensão e corrente do estator é apresentada em Gadoue et al. (2009). Neste trabalho, a RNA é treinada para operar com um observador do fluxo magnético do rotor, onde este é usado como referência para correção de um Modelo de Referência de Sistema Adaptativo (MRSA). O erro gerado entre o fluxo do rotor de referência dado pela RNA e o MRSA é processado por um controlador Proporcional Integral (PI), que por sua vez, tem como saída a ação de controle a velocidade estimada, usada para adaptação do MRSA.

A proposta deste trabalho consiste no desenvolvimento de um estimador neural de velocidade aplicado ao controle por escorregamento do MIT. É utilizado um inversor fonte de tensão com modulação vetorial-espacial aplicado a estratégia de controle escalar com realimentação de velocidade. Uma RNA é utilizada para estimar a velocidade em todo domínio. Os dados de entrada do estimador, como corrente e tensão são utilizados no treinamento e validação da RNA. Os dados de treinamento são gerados através de simulação matemática do modelo do MIT. A modulação utilizada para acionamento do inversor é a modulação por largura de pulsos por vetores espaciais (*Space Vector Pulse Width Modulation (SVPWM)*) e a RNA é treinada de maneira *offline* através dos dados obtidos em simulação. Para a validação da proposta, resultados de simulação são comparados entre o estimador proposto e a velocidade medida diretamente pelo modelo.

Este trabalho está organizado da seguinte forma: Seção 2 apresenta aspectos relativos a modelagem matemática do motor de indução com controle escalar aplicado. Na Seção 3 a metodolo-

gia de tratamento de dados é apresentada. Seção 4 princípios associados as RNA são apresentados. Seção 5 mostra os resultados de simulação e validação computacional da estrutura e na Seção 6 as conclusões deste trabalho são apresentadas.

2 Aspectos de Modelagem, Acionamento e Controle do Motor de Indução Trifásico

O primeiro passo para o treinamento supervisionado de uma RNA é elaborar o banco de dados de entrada, os quais são utilizados para o ajuste dos parâmetros internos da rede. Neste procedimento, a RNA deve ser exposta a um conjunto de dados que descreve satisfatoriamente o comportamento do sistema (Goedtel et al., 2010).

Para geração dos dados de treinamento do motor de indução, diversas simulações foram executadas utilizando o *software* Matlab/Simulink em diferentes velocidades de operação. A Figura 1 mostra o diagrama de blocos que descreve o modelo utilizado para obter as entradas e saídas. O MIT é acionado por um inversor com modulação (SVPWM). A estratégia de controle adotada é baseada no controle escalar (V/f).

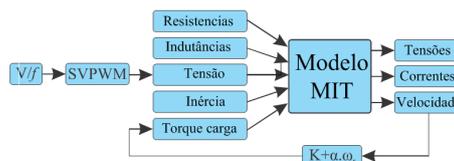


Figura 1: Diagrama de blocos do modelo.

2.1 Aspectos do modelo do MIT

O modelo do motor de indução utilizado nas simulações foi desenvolvido em Ong (1998) e Krause et al. (2002) e os parâmetros da máquinas são obtidos através do fabricante do motor (WEG), com 4 pólos, 220/380V, IP55, 1cv, 3,02 A, $R_s = 7,32 \Omega$, $R_r = 2,78 \Omega$, $L_s = 8,95 mH$, $L_r = 5,44 mH$, $L_m = 0,41 H$, $J = 2,72.10^{-3} kg.m^2$, $T_l = 4,1 Nm$.

A tensão, corrente e a velocidade de rotor são as grandezas utilizadas pelas RNA no processo de treinamento. Neste trabalho, cargas lineares, as quais são principalmente encontradas em ventiladores, laminadores, bombas e serras, são acopladas ao eixo do motor para validação da proposta. Estas cargas são caracterizadas por apresentar uma relação linear entre torque de carga e velocidade (Goedtel et al., 2007).

2.2 Acionamento do MIT

O SVPWM tem sido amplamente utilizada em acionamento de inversores. Esta técnica possui algumas vantagens, tais como redução no número de

comutações, menor conteúdo harmônico, e maior índice de modulação (Pinheiro et al., 2002). Neste trabalho, o estudo do SVPWM é baseado no modelo descrito em Broeck et al. (1988).

2.3 Controle por escorregamento

O método proposto para controle de velocidade do MIT consiste em manter a tensão-frequência (V/f) constante, mantendo assim um valor constante de fluxo no entreferro que garante o funcionamento do motor. Caso a tensão não tenha uma relação apropriada com a frequência, a máquina pode operar na região de saturação ou enfraquecimento de campo (Suetake et al., 2011). A velocidade síncrona é dada pela equação 1.

$$\omega_s = \frac{\omega_e}{P_p} \quad (1)$$

onde ω_s é a velocidade angular síncrona do campo girante (rad/s), ω_e é a velocidade angular da fmm (rad/s) e P_p é o número de par de pólos.

O controle escalar é aplicado para alterar a velocidade de operação do MIT através da variação da amplitude da tensão e da frequência de alimentação, de forma a manter o torque constante em regime permanente. Assim, o fluxo eletromagnético do MIT é mantido constante.

O fluxo produzido pode ser calculado através da relação entre a tensão e a frequência, dada pela equação 2.

$$\Phi_m \cong \frac{V_p}{f} \cong K_v \quad (2)$$

onde o Φ_m é o máximo fluxo do entreferro (Weber), K_v é a constante de proporcionalidade entre a tensão de pico por fase V_p e a frequência da tensão f .

A constante K_v calculada na equação 2 não leva em consideração a ondulação da tensão do barramento cc e as perdas no cobre do estator. Entretanto, em baixa velocidade de operação, essas perdas tem efeito relevante no desempenho do controle, reduzindo o torque eletromagnético da máquina (Krishnan, 2002). Para minimizar a queda de tensão na resistência estatórica R_s , uma tensão é adicionada na relação (V/f), denominada V_{boost} e dada em na equação 3.

$$V_{boost} = R_s \cdot i_s \quad V \quad (3)$$

onde i_s é a corrente nominal do estator. Ressalta-se que a variação de temperatura não é considerada neste equacionamento.

Aplicando os parâmetros da máquina, V_{boost} é calculado através da equação 4.

$$V_{boost} = 7.32 \cdot 3.02 = 22.1 \quad V \quad (4)$$

Então, o novo ganho K_v é determinado pela equação 5.

$$K_v = \frac{V_p - V_{boost}}{f} = \frac{180 - 22.1}{60} = 2.63 \quad (5)$$

O diagrama em blocos do controle escalar com regulação de escorregamento está mostrado na Figura 2. Neste caso, o erro calculado entre a velocidade de comando (f^*) e a velocidade medida (f_r) gera o sinal de comando de velocidade de escorregamento (f_{s^*}) através de um controlador PI. A velocidade de escorregamento é somada à velocidade atual, que por sua vez, resulta na velocidade de comando para (f_{e^*}) o controle escalar, que por sua vez, calcula os sinais de referência V^* e θ^* para a algoritmo de modulação (Bose, 2002).

Neste método de controle, a velocidade de escorregamento, a tensão V_{boost} e a referência de velocidade são variáveis, que são calculados de acordo com as características do MIT.

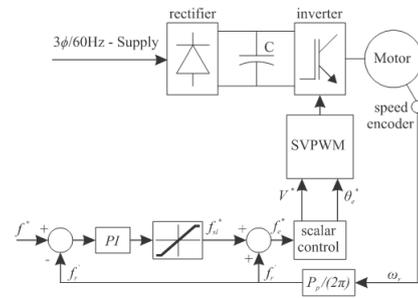


Figura 2: Diagrama de blocos do controle em malha fechada.

3 Processamento dos dados

Em aplicações onde é necessário o controle de velocidade, o MIT é normalmente acionado através de um inversor de tensão trifásico.

Após a aquisição dos dados, existe a necessidade de processamento dos sinais, afim de obter característica de velocidade do MIT em função da corrente e tensão.

As tensões fornecidas pelo inversor possuem um alto nível de ruído devido ao chaveamento. Para contornar esse efeito utilizou-se um filtro passa-baixas (FPB) com frequência de corte de 600 HZ antes de ser processada por um sistema *Phase Locked Loop* (PLL).

Para se obter os padrões de entrada em função da velocidade do rotor, os sinais de tensão e corrente são transformados para o eixo de coordenadas síncrona $dq0$. O diagrama de blocos da Figura 3 apresenta o esquema de tratamento dos sinais de tensão e corrente.

O sistema PLL utilizado neste trabalho é baseado no algoritmo p-PLL monofásico descrito em Silva et al. (2009).

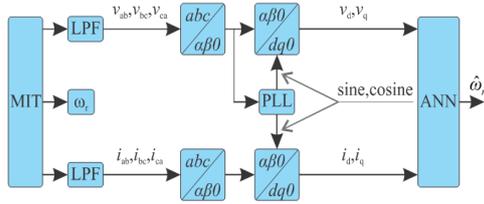


Figura 3: Diagrama de blocos do processamento de sinais.

4 Estimador Neural de Velocidade

O elemento base de uma rede neural é o neurônio artificial, o qual também é conhecido como elemento principal de processamento, como é mostrado na Figura 4.

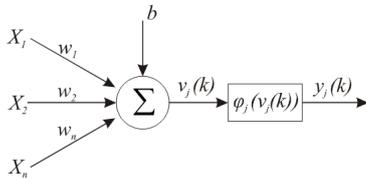


Figura 4: Representação do neurônio artificial.

O modelo do neurônio artificial ilustrado na Figura 4 pode ser modelado matematicamente pelas equações 6 e 7.

$$v_j(k) = \sum_{i=1}^n X_i \cdot w_i + b \quad (6)$$

$$y_j(k) = \varphi_j(v_j(k)) \quad (7)$$

onde:

- n é o número de entradas do neurônio;
- X_i é a i -ésima entrada do neurônio;
- w_i é o peso associado com a i -ésima entrada;
- b é o limiar associado ao neurônio;
- φ_j é a função de ativação do neurônio;
- $y_j(k)$ é a saída do neurônio.

Cada neurônio artificial computa os sinais de entrada à saída. As funções de ativação não lineares são normalmente usadas, tais como a função logística e a tangente hiperbólica. O erro produzido pelo k -ésimo neurônio de saída quando a ele é apresentado o i -ésimo vetor de entrada relacionado com os pesos (w_k) do k -ésimo neurônio é usado para o ajuste dos pesos sinápticos. Este erro é calculado pela equação 8.

$$e_j(k) = d_j(k) - y_j(k) \quad (8)$$

onde $d_k(i)$ é a saída desejada do k -ésimo neurônio de saída.

Com a soma de todos os erros quadráticos produzidos por todos os neurônios de saída da rede em relação à i -ésima iteração, tem-se a equação 9.

$$E(k) = \frac{1}{2} \sum_{j=1}^p e_j^2(k) \quad (9)$$

onde p é o número de neurônios de saída.

Para uma configuração ótima dos pesos sinápticos, $E(i)$ é minimizado pelo ajuste dos pesos $w_{k,j}$. Os pesos associados à camada de saída da rede são ajustados conforme a equação 10.

$$E_m = \frac{1}{N} \sum_{k=1}^N E(k) \quad (10)$$

O objetivo do algoritmo de retro-propagação é minimizar $E(k)$ e E_m através do ajuste de w_i e b .

Este trabalho tem o propósito de estimar a velocidade do motor de indução através do controle escalar utilizando um RNA para estimar a velocidade. O propósito é utilizar uma RNA com aproximador universal de funções.

A Perceptron Multicamadas (PMC) possui arquitetura *feedforward*, com treinamento supervisionado. Então, a rede tem seus pesos ajustados para uma aplicação específica.

Neste trabalho uma rede perceptron multicamadas com atraso nas entradas (TDNN) como mostrada em Haykin (2001). Para cada entradas foram usadas quatro amostras atrasadas no formato $x(t), x(t-1), x(t-2), x(t-3), x(t-4)$.

A TDNN é treinada da forma *offline*, utilizando dados gerados em simulação e tratados na sequência. O dados tratados utilizados foram gerados com sistema operando com controle escalar em laço-aberto. O estimador proposto neste trabalho tem uma estrutura mostrada na Figura 5 e os parâmetros da RNA mostrados na Tabela 1.

Para otimizar o treinamento da RNA, um treinamento por reforço foi aplicado em regiões de baixa velocidade.

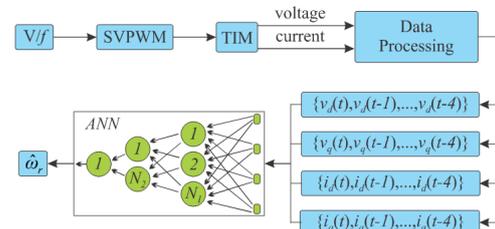


Figura 5: Estrutura de treinamento da RNA.

5 Resultados de Generalização

A RNA foi treinada com dados de simulação computacional para um MIT operando com controle escalar em vários pontos de operação.

Tabela 1: Parâmetros da RNA

Arquitetura	TDNN PMC
Ordem do Atraso	4
Tipo de Treinamento	Supervisionado
Número de Camadas	3
Neurônios da 1ª camada	6
Neurônios da 2ª camada	21
Algoritmo de Treinamento	Levenberg-Marquardt
Taxa de Aprendizagem	$5 \cdot 10^{-2}$
Épocas	3000
ERM objetivo	$1 \cdot 10^{-2}$
F. ativação da camada escondida	Tangente Hiperbólica
F. ativação da camada de saída	Linear

O processo de validação foi desenvolvido afim de utilizar a velocidade estimada (w_r) na realimentação do controle em malha-fechada. As maiores e menores frequências de escorregamento foram limitadas em 10 Hz e -10 Hz respectivamente.

Pelo fato da dinâmica mecânica do motor predominar perante a dinâmica elétrica, apenas as equações mecânicas foram levadas em consideração para o ajuste dos controlador PI (Broeck et al., 1988). A dinâmica do sistema controlado, para uma entrada de tensão/frequência é descrita em Liaw and Lin (1994), e os ganhos do PI foram ajustados usando uma magem de fase de 90° e uma frequência de corte de 3 kHz. Contudo, o ajuste fino dos ganhos foram obtidos empiricamente através de testes.

A Tabela 2 mostra os três pontos de simulação com torque e velocidade variável.

Tabela 2: Parâmetros do MIT

Nº Simulação	Frequência (Hz)		Torque de carga (Nm)	
	Inicial	Final	Inicial	Final
1	37		4,4	2,4
2	10	25	1,1	2,7
3	52	20	4,4	1,7

Para as simulações foram consideradas torque de carga linear como na equação 11.

$$T_l = k_t + \alpha \cdot \omega_r \quad (11)$$

Na equação 11, T_l é o torque de carga, k_t é a constante de torque de carga inicial em N.m, α é a constante de relação torque/velocidade dada por N.m/rad/s e ω_r é a velocidade do MIT. Em todas as simulações, é considerado um k_t , com valor de 0,1 Nm e uma carga com momento de inércia de $5,42 \cdot 10^{-3} \text{ kg.m}^2$.

A Figura 6 mostra os resultados de simulação 1, com realimentação através do estimador.

Considerando degrau de torque de carga, o comportamento do sistema com a velocidade do ponto de operação aplicado na simulação 2 e 3 é mostrado. Os resultados são mostrados nas Figuras 7 e 8 com estimador de velocidade na realimentação.

A Tabela 3 mostra o erro relativo médio (ERM) entre velocidade estimada e real e o erro em regime do controle de velocidade. Os resultados

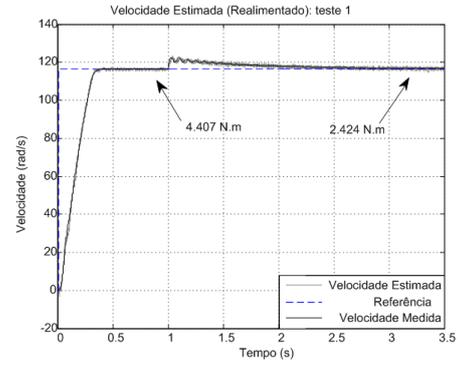


Figura 6: Estimador de Velocidade na realimentação para simulação 1.

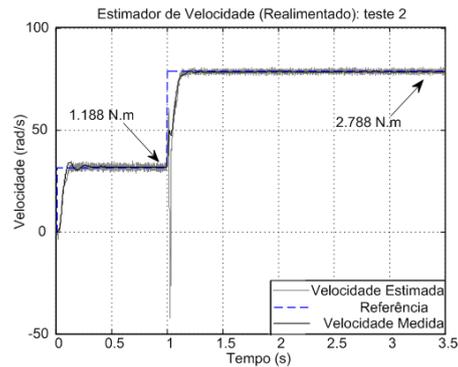


Figura 7: Estimador de Velocidade na realimentação para simulação 2.

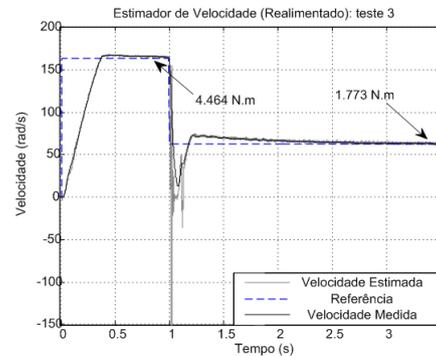


Figura 8: Estimador de Velocidade na realimentação para simulação 3.

de simulação demonstram a habilidade da RNA de estimar a velocidade do MIT do transitório ao regime permanente com controle escalar mesmo em regiões de baixa velocidade.

Tabela 3: ERM para o estimador de velocidade

Nº Simulação	ERM Estimador	ERM Controle
1	0,67 %	0,47 %
2	2,17 %	0,73 %
3	4,21 %	1,59 %

6 Conclusão

Este trabalho propõe uma metodologia alternativa para estimar a velocidade do motor de indução mesmo acionado por um inversor com controle de velocidade por escorregamento, baseado em uma rede TDNN com treinamento supervisionado.

A metodologia foi aplicada para estimar a velocidade do motor durante transitório e regime permanente, compreendendo vários pontos de operação com controle de escorregamento. Em cada simulação foi aplicado diferentes torques de carga com o MIT operando em regime e com diferentes referências de velocidade de operação para demonstrar a robustez do método proposto. Os resultados de simulação apresentados possuem baixo erro relativo médio para os vários pontos de operação. Todavia, a proposta pode ser aplicada a outros métodos de controle ou com outros tipos de motores utilizando o método proposto.

Agradecimentos

Ao suporte financeiro da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná (Processo No 06/56093-3) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Processo No 474290/2008-5, 473576/2011-2, 552269/2011-5).

Referências

- Bose, B. K. (2002). *Modern power Electronics and AC Drives*, Prentice Hall, USA.
- Broeck, H., Skudelny, H.-C. and Stanke, G. (1988). Analysis and realization of a pulsewidth modulator based on voltage space vectors, *IEEE Transactions on Industry Applications* **24**(1): 142–150.
- Gadoue, S., Giaouris, D. and Finch, J. (2009). Sensorless control of induction motor drives at very low and zero speeds using neural network flux observers, *IEEE Transactions on Industrial Electronics* **56**(8): 3029–3039.
- Goedtel, A., da Silva, I. N. and Serni, P. J. A. (2007). Load torque identification in induction motor using neural networks technique, *Electric Power Systems Research* **77**(1): 35 – 45.
- Goedtel, A., Graciola, C., Silva, S., Nascimento, C. and Suetake, M. (2010). A comparative study for single and multilayer neural networks applied to speed estimation in induction motors, *XIX International Conference on Electrical Machines (ICEM)* **1**: 1–6.
- Haykin, S. (2001). *Redes Neurais Princípios e Prática*, Bookman, Porto Alegre, RS.
- Jevremovic, V. R., Vasic, V., Marcetic, D. and Jeftenic, B. (2010). Speed-sensorless control of induction motor based on reactive power with rotor time constant identification, *Electric Power Applications, IET* **4**(6): 462–473.
- Krause, P. C., Wasynczuk, O. and Sudhoff, S. D. (2002). *Analysis of electric machinery and drives systems*, 2 edn, Piscataway, New Jersey.
- Krishnan, R. (2002). *Electric Motor Drives: Modeling, Analysis, and Control*, Prentice Hall.
- Liaw, G.-M. and Lin, F.-J. (1994). A robust speed controller for induction motor drives, *IEEE Transactions on Industrial Electronics* **41**(3): 308–315.
- Marei, M. I., Shaaban, M. F. and El-Sattar, A. A. (2009). A speed estimator unit for induction motor based on adaptive linear combiner, *Energy Conversion and Management* **50**(7): 1664–1670.
- Ong, C. M. (1998). *Dynamic simulation of electric machinery: using MATLAB/SIMULINK*, Prentice Hall, Upper Saddle River, NJ-USA.
- Pinheiro, H., Botteron, F., Rech, C., Schuch, L., Camargo, R. F., Hey, H., Grundling, H. and Pinheiro, J. (2002). Space vector modulation for voltage-source inverters: a unified approach, *IECON 02 [28th Annual Conference of the Industrial Electronics Society]*, Vol. 1, pp. 23–29.
- Silva, S., Campanhol, L., Goedtel, A., Nascimento, C. and Paiao, D. (2009). A comparative analysis of p-PLL algorithms for single-phase utility connected systems, *13th European Conference on Power Electronics and Applications*, pp. 1–10.
- Suetake, M., da Silva, I. and Goedtel, A. (2011). Embedded dsp-based compact fuzzy system and its application for induction-motor speed control, *IEEE Transactions on Industrial Electronics*, **58**(3): 750–760.
- Vas, P. (1998). *Sensorless vector and direct torque control*, Oxford University Press, USA.
- Vasic, V., Vukosavic, S. and Levi, E. (2003). A stator resistance estimation scheme for speed sensorless rotor flux oriented induction motor drives, *IEEE Transactions on Energy Conversion* **18**(4): 476–483.
- Yuksel, O. and Mehmet, D. (2011). Speed estimation of vector controlled squirrel cage asynchronous motor with artificial neural networks, *Energy Conversion and Management* **52**(1): 675 – 686.