

APLICAÇÃO DE SISTEMAS FUZZY EM MOTORES DE INDUÇÃO PARA IDENTIFICAÇÃO DE TORQUE DE CARGA

SÉRGIO F. DA SILVA^{*}, IVAN N. SILVA^{*}, ALESSANDRO GOEDEL[#], CRISTIANO MINOTTI^{*}

^{*}Laboratório de Automação Inteligente de Processos e Sistemas, Departamento de Engenharia Elétrica, Escola de Engenharia de São Carlos - USP

Av. Trabalhador São-carlense, 400 - Centro - CEP 13566-590, São Carlos - SP

[#]UTFPR, Cornélio Procopio - PR

E-mails: {ferreira, insilva, cminotti}@sel.eesc.usp.br, agoedel@utfpr.edu.br

Abstract— The three phase induction motors are widely used in all industrial sectors. The selection procedure of the motor for a particular application is sometimes inaccurate due to the lack of complete knowledge about the load connected to the its shaft. The proposal of this work consists of using fuzzy system as an alternative tool to the classical methods for extraction of the load behavior and, in control process, where the knowledge of torque behavior applied to the motor shaft are need, focusing several types of loads found in industries. Simulation results are presented to validate the proposal of this work. is a wide range of applications of fuzzy logic in electrical machines. This paper presents a load torque estimation based on fuzzy logic that works with several kinds of loads found in industry and ample range voltage for induction motors. Simulation results are also presented to validate the proposed approach.

Keywords— Induction motors, systems of fuzzy inferences, identification of systems, torque estimation, ANFIS.

Resumo— Os motores de indução trifásicos são largamente usados em vários setores da indústria. O dimensionamento da potência adequada de um motor de indução assíncrono trifásico, em função do comportamento das cargas acopladas ao eixo, continua em alguns casos impreciso pela falta de conhecimento mais completo do comportamento das cargas. A proposta deste trabalho consiste na utilização de sistemas *fuzzy* como uma alternativa aos métodos tradicionais para levantamento do comportamento de carga e, em processos de controle, onde há a necessidade de conhecimento do comportamento do conjugado aplicado ao eixo do motor, enfocando diversos tipos de cargas encontradas em indústrias. Resultados de simulações são apresentados para validar a proposta deste trabalho.

Palavras-chave— Motor de indução, sistema de inferência *fuzzy*, identificação de sistemas, estimativa de torque, ANFIS.

1 Introdução

A medição do torque é de grande importância em aplicações industriais. As principais técnicas para medida do torque utilizam torquímetros girantes ou células de carga. Os torquímetros girantes são acoplados entre o eixo da máquina e do motor e medem conjugado de carga. As células de carga, por sua vez, medem conjugado eletromagnético. Mas, tais métodos são invasivos e de difícil implementação em sistemas que já estão sendo operados (Cerqueira et al., 2006).

O ajuste da velocidade baseado em controle vetorial e controle direto do torque tem conquistado grande popularidade em aplicações de alta performance (R.D.Lorenz, T.A.Lipo e D.W.Novotny, 1994). Os medidores de sinais dessas variáveis, como sensor de fluxo, velocidade e torque são caros, então o controle de MIT (Motor de Indução Trifásico) por técnicas *sensorless* tem recebido bastante atenção (K.Ohnishi, N.Matsui e Y.Hori, 1994).

A variação da temperatura gerada na máquina ao longo do seu regime de operação produz alteração significativa dos parâmetros do modelo. Logo, quando são utilizados estimadores baseados nos modelos da máquina, como observadores de *Luenberger*, Modelo de Referência Adaptativo (MRAS) e filtro de *Kalman*, há um desvio entre o valor estimado e o valor real da variável estimada; a saber: fluxo eletromagnético, torque e velocidade.

Este desvio ocasiona a deterioração do algoritmo de controle o qual foi sintonizado para a situação de início de operação (a frio) ou em regime permanente (a quente). A lógica *fuzzy*, por sua vez, não depende do modelo e dos parâmetros da máquina. Então, é possível mapear a relação entrada/saída de uma determinada variável considerando a dinâmica da máquina em estudo, seja em regime transitório ou em regime permanente.

Na técnica de controle direto de torque (DTC – *Direct Torque Control*) é requerido o conhecimento da amplitude e posicionamento angular do fluxo a ser controlado, adicionando informações relacionadas com a velocidade angular em aplicações de controle de velocidades. No entanto, o não conhecimento do torque de carga e das incertezas relacionadas às resistências do estator/rotor por causa das condições de operação constitui o maior desafio para performance de um sistema, conforme relatado em (Barut, Bogosyan e Gokasan, 2004).

Neste artigo, a estimativa de conjugado de carga de motores de indução tem três objetivos principais. O primeiro, e mais importante, é prover informações sobre a carga contribuindo para o correto dimensionamento do motor em determinada aplicação. O segundo objetivo é prover dados relativos ao comportamento da carga no eixo de forma a determinar a eficiência e performance da conversão de energia (El-Ibiary, 2003). Em terceiro lugar, a estimativa de conjugado aplicada nos eixos dos motores de indução é de fundamental importância para o desenvolvimento de técnicas eficientes de controle do motor

de indução no regime transitório e permanente (Vas, 1999; El-Ibiary, 2003).

Desta forma, a estimativa do torque de carga aplicado ao eixo do MIT tem recebido grande interesse no meio científico, tanto para ser aplicado em controle como para o dimensionamento de um motor de indução para uma dada aplicação. Em (Cerqueira et al., 2006) é proposta uma abordagem um pouco evasiva, pois necessita apenas da medição da corrente e da tensão elétrica para a sua computação. A aplicabilidade é assegurada para sistemas com dinâmica lenta como, por exemplo, sistemas de elevação artificial de petróleo do tipo cavidades progressivas.

O objetivo é apresentar um estimador que opere em uma ampla faixa de tensão de alimentação da máquina e quando a mesma é submetida a diferentes regimes de carga. A metodologia proposta busca não ser um processo muito invasivo para o motor de indução, pois requer apenas o conhecimento da tensão eficaz, da corrente eficaz e da velocidade no eixo para estimar o torque de carga aplicado ao motor.

Este trabalho é dividido conforme se segue. Na Seção 2 é apresentado alguns fundamentos de sistema fuzzy. Na Seção 3 é apresentada a estrutura do sistema fuzzy para identificação do torque de carga. Na Seção 4, têm-se as simulações e resultados do trabalho. Na Seção 5 as conclusões desse trabalho são apresentadas.

2 Sistemas fuzzy

A Lógica *fuzzy* foi desenvolvida por L. A. Zadeh em 1965 para representar o conhecimento incerto ou impreciso. Consiste de meios aproximados mais efetivos de descrever o comportamento de sistemas que são muito complexos, mal definidos ou não facilmente de se analisar matematicamente (Yager e P. filev, 1994; Jain, 1999).

O processo de inferência *fuzzy* pode ser dividido em três etapas: etapa de *fuzzificação*; regras e inferências; e *defuzzificação* como mostra a Figura 1.




Figura 1. Diagrama do processo de inferência *fuzzy*.

No bloco FUZZIFICAÇÃO da Fig. 1, as entradas não nebulosas são apresentadas ao sistema por intermédio de medições ou observações de dados, os quais são considerados como sendo o conjunto de dados de entrada do sistema. Em REGRAS, estas podem ser fornecidas por especialistas, em forma de sentenças lingüísticas, e se constituem em um

aspecto fundamental no desempenho de um sistema de inferência *fuzzy*. Desta forma, o sistema de inferência terá um desempenho confiável somente se as regras que definem a estratégia forem consistentes. Mas, neste trabalho, tais regras são geradas pelo sistema ANFIS (Seção 3) do *Matlab*. Na INFERÊNCIA ocorrem as operações com conjuntos *fuzzy*. Na DEFUZZIFICAÇÃO, por intermédio do conjunto nebuloso de saída adquirido mediante o processo de inferência, é efetuada a interpretação dessa informação para saídas precisas, ou seja, dados não *fuzzy*.

O processo de inferência se caracteriza principalmente na geração das regras *fuzzy*, ajuste e definições dos conjuntos *fuzzy* correspondentes às variáveis de entrada e saídas, pois o desempenho do sistema de inferência dependerá do número de conjuntos e de sua forma (função de pertinência) adotados.

No processo de geração das regras, estas podem ser fornecidas por especialistas, em forma de sentenças lingüísticas. Elas assumem um aspecto fundamental no desempenho do sistema de inferência *fuzzy*, pois dessas se pode determinar, por intermédio do processo de inferência, o comportamento das variáveis de saídas do sistema. Entretanto, a extração de um conjunto de regras fornecidas por um especialista pode não ser uma tarefa fácil por mais que os mesmos conheçam profundamente o problema abordado. Assim, uma outra alternativa empregada, ao invés do uso de especialistas para a definição do conjunto de regras, é a utilização de métodos mais automáticos de extração de regras.

Tanto as regras como a sintonia das funções de pertinências dos conjuntos podem ser feitas de forma manual, mas são comumente utilizados métodos automáticos para ambos. A integração entre sistemas de inferências *fuzzy* e técnicas de aprendizagem de redes neurais artificiais tem se mostrado adequada para essa finalidade. O ANFIS é uma dessas abordagens e foi utilizada nesse trabalho para a sintonia das funções de pertinência.

3 Sistemas ANFIS

O *Adaptive Neuro-Fuzzy Inference System (ANFIS)* ou sistema de inferência *neuro-fuzzy* adaptativo é baseado em técnicas de aprendizagem. Através das informações contidas no conjunto de dados este sistema é capaz de ajustar os parâmetros da função de pertinência de tal forma que permita o sistema de inferência *fuzzy* associado mapear adequadamente o relacionamento entrada-saída do conjunto de dados. O ANFIS é baseado no modelo de inferência de *Takagi-Sugeno*.

No modelo de *Takagi-Sugeno* uma regra de inferência R_i é dada da seguinte forma:

$$R_i : \text{Se Entrada 1 é } x_1 \text{ e Entrada 2 é } x_2 \\ \text{Então Saída é } y_i = a_i \cdot x_1 + b_i \cdot x_2 + c_i$$

sendo que o resultado final é obtido pela média ponderada de todos os resultados de saída, considerando os graus de pertinência de cada regra R_i ativada, conforme:

$$y = \frac{\sum_{i=1}^N \mu_i \cdot y_i}{\sum_{i=1}^N y_i} \quad (1)$$

onde y é a saída final, N representa o total de regras ativadas, e μ_i é o grau de pertinência em relação à contribuição de cada regra ativada.

Como mencionado anteriormente são utilizados três variáveis de entrada ao sistema de inferência *fuzzy* para a estimativa do torque (tensão, corrente, velocidade).

Portanto, a sintonização do sistema *fuzzy* é obtida por meio do *ANFIS*, desta forma para cada variável de entrada são utilizadas nove funções de pertinência, sendo as mesmas do tipo gaussianas. Desse modo, gera-se então 729 regras no sistema *fuzzy*.

Neste trabalho a faixa de tensão são divididas em faixas discretas, abrangendo uma variação de $\pm 10\%$. Consegue-se desta forma atingir dois objetivos, ou seja, simular pequenas variações de tensão no motor devido a alta corrente de partida e dividir a estrutura *fuzzy* em vários sistemas *fuzzy* menores, tendo então maior precisão na generalização das respostas por faixa de tensão e, conseqüentemente, maior modularidade na estrutura computacional. As faixas de tensões são divididas da seguinte forma: 200 V a 210V, 211 V a 220 V, 221 V a 230 V e finalmente de 231 V a 240 V, sendo que seus universo de discurso variam de zero ao valor final de cada faixa de tensão. Assim, para cada faixa de tensão foi gerado um sistema *fuzzy*. Assim, para cada carga se tem um total de 4 sistemas *fuzzy*.

A Figura 2 ilustra as funções de pertinências para a tensão que corresponde às faixas de tensões entre 200 – 210V.




Figura 2. Função de pertinência para variável linguística “tensão”.

O significado da terminologia adotado para cada função de pertinência das variáveis de entrada são: Mi (Mínimo), MP (Muito Pequeno), PP (Pouco Pequeno), P (Pequeno), Me (Médio), G (Grande), PG (Pouco Grande), MG (Muito Grande) e Ma (Máximo).

Para todas as variáveis de entrada são adotados o mesmo número e tipo de funções de pertinência e a mesma terminologia.

A Tabela 1 ilustra os universos de discursos para as variáveis linguísticas corrente e velocidade, sendo que tais universos de discursos para essas variáveis são os mesmos tanto para as cargas quadráticas como para as lineares e inversas.

Tabela 1. Universo de discurso para as variáveis linguísticas: velocidade e corrente.

Faixa de Tensão	Universo de Discurso	
	Velocidade	Corrente
200 – 210	0 – 187.6	0 – 18.07
211 – 220	0 – 187.7	0 – 19.38
221 – 230	0 – 187.8	0 – 20.25
231 – 240	0 – 187.8	0 – 21.12

4 Simulações e resultados

Todo o modelamento do motor de indução utilizado neste trabalho foi desenvolvido usando as ferramentas computacionais do *Matlab/Simulink* (ONG, 1997).

Os parâmetros do motor de indução simulados são apresentados na Tabela 2.

Tabela 2. Parâmetros do motor de indução.

Motor Linha Standard – 4 Pólos – 60Hz – 220/380V	
Potência (1 CV)	745,69 (W)
Resistência do Estator na Partida	10,17 (Ω)
Resistência do Estator em Regime	12,40 (Ω)
Resistência do Rotor na Partida	5,80 (Ω)
Resistência do Rotor em Regime	6,95 (Ω)
Indutância do Estator na Partida	$1,77 \times 10^{-2}$ (H)
Indutância do Estator no Regime	$2,05 \times 10^{-2}$ (H)
Indutância do Rotor na Partida	$1,10 \times 10^{-2}$ (H)
Indutância do Rotor no Regime	$4,84 \times 10^{-2}$ (H)
Indutância de Magnetização na Partida	0,606 (H)
Indutância de Magnetização no Regime	0,546 (H)
Momento de Inércia do Rotor	$2,71 \times 10^{-3}$ (kg.m ²)
Velocidade Síncrona Mecânica	188,49 (rad/s)
Torque Nominal	4,1 (Nm)

Para a estimativa do conjugado foram analisadas três tipos de cargas; a saber: as cargas lineares, as cargas quadráticas e as inversas.

Na simulação do motor de indução foram geradas 6 curvas de torque de carga que simulam da partida ao regime permanente, considerando cada tensão. Deste modo, na primeira faixa de tensão (200-210V), tem-se um total de 66 curvas, sendo que, 34 dessas foram utilizadas para o treinamento do sistema *fuzzy*, e as demais para teste de validação.

4.1 Cargas Lineares

A Figura 3 representa o resultado da generalização para carga linear com conjugado inicial em 0,2 Nm e em regime permanente em 2 Nm. A estimativa obteve um erro relativo médio de 2,6% e um desvio padrão de 3,9%. O objetivo do valor desse perfil de tensão é simular uma subtensão no motor de indução, visando testar o modelo proposto por esse trabalho.

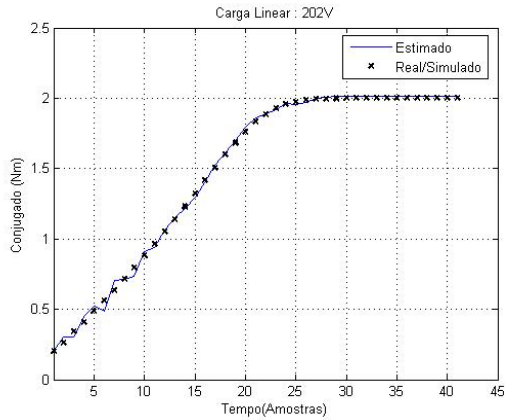


Figura 3. MIT submetido a conjugado resistente linear alimentado com 202 V.

A Figura 4 ilustra o resultado de simulação de uma carga que, em regime permanente, atinge 6 Nm. Esta estimativa obteve um erro relativo médio de 0,81% com um desvio padrão de 2,2%.

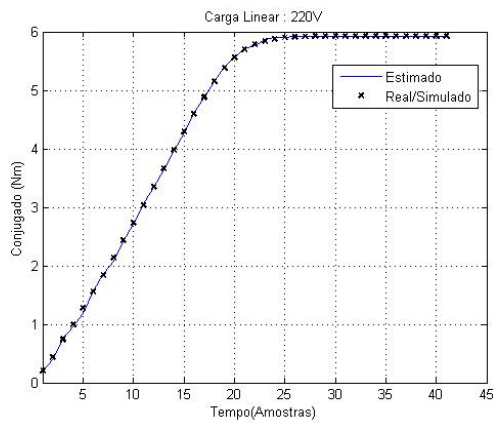


Figura 4. MIT submetido a conjugado resistente linear alimentado com 220 V.

A Figura 5 ilustra os resultados de simulação de uma carga linear submetida a uma tensão de 238V, sendo que essa carga em regime permanente atinge um conjugado de 4 Nm. A estimativa obteve um erro relativo médio de 0,24% e um desvio padrão de 0,29%. O motor foi submetido a essa elevada tensão para simular uma sobretensão, sendo então possível analisar o comportamento do estimador proposto.




Figura 5. MIT submetido a conjugado resistente linear alimentado com 238 V.

Na Tabela 3 são apresentados os resultados para a estimativa do conjugado de torque ilustrando alguns valores do erro relativo médio, desvio padrão, tensão e conjugado nominal para as simulações das cargas lineares.

Tabela 3. Desempenho do estimador para conjugado linear.

Tensão (Volts)	Conjugado (Nm)	Erro Relativo Médio (%)	Desvio Padrão (%)
201	2	2,50	4,30
212	3	0,88	1,45
215	4	0,69	1,04
224	6	0,40	0,74
235	1	1,68	1,82

4.2 Cargas Quadráticas

A Figura 6 mostra o resultado da generalização para esta carga com conjugado inicial em 0,2 Nm e em regime permanente em 1 Nm. O torque de carga foi estimado com um erro relativo médio de 2,5% com desvio padrão de 3,1%. O objetivo do valor dessa tensão é simular um subtensão no motor de indução visando testar o modelo proposto por esse trabalho.




Figura 6. MIT submetido a conjugado resistente quadrático alimentado com 205 V.

A Figura 7 ilustra uma carga que, em regime permanente, atinge 6 Nm. Esta estimativa obteve um erro relativo médio de 1,29% com um desvio padrão de 2,93%. Essa simulação ilustra a comparação do sistema entre dois tipos de cargas, submetido ao mesmo motor com os mesmos parâmetros (Fig. 4 e Fig. 7).

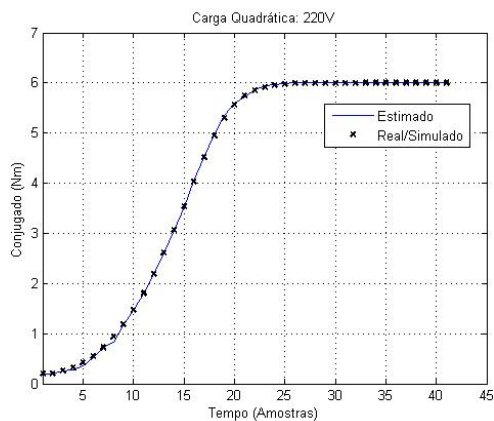


Figura 7. MIT submetido a conjugado resistente quadrático alimentado com 220 V.

A Figura 8 ilustra os resultados da carga a uma tensão de 238V, sendo que a mesma em regime permanente atinge um conjugado de 4 Nm. A estimativa obteve um erro relativo médio de 0,25% e um desvio padrão de 0,41%. Essa simulação ilustra a comparação do sistema entre dois tipos de cargas, submetido ao mesmo motor com os mesmos parâmetros, sendo que o mesmo está submetido a uma sobretensão (Fig. 4 e Fig. 7).

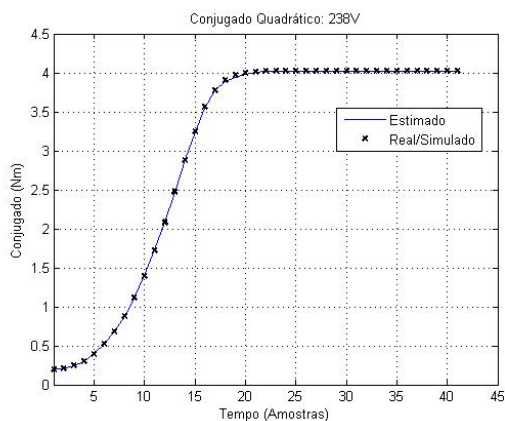


Figura 8. MIT submetido a conjugado resistente quadrático alimentado com 238 V.

A Tabela 4 mostra alguns valores do erro relativo médio, desvio padrão, tensão e conjugado nominal para as simulações das cargas quadráticas, caracterizando a capacidade de generalização do sistema *fuzzy* empregado para a estimativa do torque.

Tabela 4. Desempenho do estimador para conjugado quadrático.

Tensão	Conjugado (Nm)	Erro Médio (%)	Desvio Padrão (%)
206	2	1,47	2,01
213	3	0,75	1,01
233	1	0,84	0,83
240	3	0,32	0,49

4.3 Cargas Inversas

A Figura 9 mostra o resultado da generalização para a carga inversa com conjugado inicial em 0,2 Nm e em regime permanente em 5 Nm, submetido a uma tensão de 209 Volts. O torque de carga foi estimado com um erro relativo médio de 1,29% com desvio padrão de 5,29%. O objetivo do valor dessa tensão é simular uma subtensão no motor de indução para testar o modelo proposto por esse trabalho.




Figura 9. MIT submetido a conjugado resistente inverso alimentado com 209 V.

A Figura 10 ilustra o resultado de simulação de uma carga inversa submetida a uma tensão de 220 Volts, que em regime permanente atinge 6 Nm. A estimativa obteve um erro relativo médio de 1,27% com um desvio padrão de 1,99%. A simulação ilustra a comparação do sistema entre vários tipos de cargas submetidas ao mesmo motor com os mesmos parâmetros (Fig. 4, Fig. 7, Fig. 10).




Figura 10. MIT submetido a conjugado resistente inverso alimentado com 220 V.

A Figura 11 ilustra os resultados de simulação de uma carga inversa submetida a uma tensão de 230 V, sendo que a mesma em regime permanente atinge um conjugado de 3 Nm. O torque de carga foi estimado com um erro relativo médio de 2,17% em relação ao torque desejado, tendo um desvio padrão de 3,67%. O motor foi submetido a essa elevada tensão para simular uma sobretensão, sendo então possível analisar o comportamento do estimador proposto.

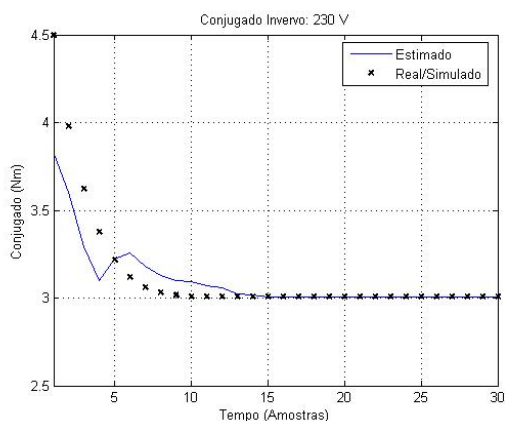


Figura 11. MIT submetido a conjugado resistente inverso alimentado com 230 V.

Na Tabela 5 são apresentados alguns dos resultados obtidos para a estimativa do conjugado de torque, ilustrando alguns valores do erro relativo médio, desvio padrão, tensão e conjugado nominal para as simulações das cargas inversas.

Tabela 5. Desempenho do estimador para conjugado inverso.

Tensão	Conjugado (Nm)	Erro Médio (%)	Desvio Padrão (%)
200	2	2,28	3,15
213	3	1,25	2,36
224	5	1,37	3,26
233	2	1,92	3,41
240	4	1,71	3,08

5 Conclusão

Este trabalho apresenta uma técnica baseada na utilização de sistemas *fuzzy* para estimativa de conjugado resistente aplicado nos motores de indução. O modelo proposto pode ser usado como uma alternativa aos métodos tradicionais para levantamento do comportamento de carga e em processos de controle, onde há a necessidade de conhecimento do comportamento do conjugado aplicado ao eixo do motor. Os resul-

tados de simulação demonstram que é possível estimar o conjugado usando um sistema de inferência *fuzzy*.

6 Agradecimentos

Os autores desse trabalho agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP – Processo FAPESP No. 06/56093-3) por propiciar o desenvolvimento do trabalho aqui descrito.

Referências Bibliográficas

- Barut, M., S. Bogosyan e M. Gokasan (2004). "Speed sensorless direct torque control of IMs with rotor resistance estimation." *ELSEVIER - Energy Conversion and Management*: 335-349.
- Cerqueira, J. J. F., A. Oliveira, A. S. Rebouças, et al. (2006). "Metodologia para Estimação de Torque em Motores de Indução Polifásicos." *Congresso Brasileiro de Automática*: 2927-2932.
- El-Ibiary, Y. (2003). "An accurate low-cost method for determining electric efficiency for the purpose of plant energy management." *IEEE Transactions on Industry Applications* **39**: 1205-1210.
- Jain, L. C. (1999). "Guest editorial special section on fusion of neural nets, fuzzy systems and genetic algorithms in industrial applications." *Industrial Electronics, IEEE Transactions on* **46**(6): 1049-1050.
- K. Ohnishi, N. Matsui e Y. Hori (1994). "Estimation, Identification and Sensorless Control in Motion Control." *Proceedings of the IEEE* **82**(Special Issue on Power Electronics and Motion Control): 1253-1265.
- ONG, C.-M. (1997). *Dynamic Simulation of Electric Machinery Using Matlab/Simulink*, Prentice Hall.
- R.D. Lorenz, T.A. Lipo e D.W. Novotny (1994). "Motion Control With Induction Motors." *Proceeding of the IEEE* **82**(Special Issue on Power Electronics and Motion Control): 1215-1240.
- Vas, P. (1999). *Artificial Intelligence Based Electrical Machines and Drives*, Oxford University Press.
- Yager, R. R. e D. P. Filev (1994). *Essentials of Fuzzy Modeling and Control*. Canada, John Wiley & Sons, Inc.