

COMPARATIVO ENTRE AS REDES PMC E RBF PARA ESTIMAR VELOCIDADE EM MOTORES DE INDUÇÃO TRIFÁSICOS

CLAYTON LUIZ GRACIOLA*, ALESSANDRO GOEDEL*, PAULO BRONIERA JUNIOR*, THIAGO DA SILVA TAKAOKA*

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

Emails: claytongraciola@gmail.com, agoedel@utfpr.edu.br, paulobroj@hotmail.com, thiagotakaoka@hotmail.com

Abstract— This paper propose the development of an intelligent system applied to estimate induction motor speed connected directly on the power supply. The work is a comparative study between two artificial neural networks to estimate the motor speed at steady state by using a Multilayer Perceptron and also Radial Basis Functions. Data was obtained through computer simulations and also experimental tests performed on a test bench.

Keywords— Artificial Neural Network, Three-Phase Induction Motor, Speed Estimator, Multilayer Perceptron, Radial Basis Functions

Resumo— Este artigo propõe o desenvolvimento de um sistema inteligente aplicado na estimativa de velocidade do motor de indução trifásico ligado diretamente a rede elétrica. O trabalho faz um estudo comparativo entre duas redes neurais artificiais para estimar a velocidade de um motor de indução em regime permanente, uma rede Perceptron Multicamadas e uma rede de Funções de Base Radial. A base de dados utilizada para o desenvolvimento do trabalho será obtida através de simulações computacionais e experimentos realizados em uma bancada de teste.

Palavras-chave— Redes Neurais Artificiais, Motores de Indução Trifásicos, Estimador de Velocidade, Perceptron Multicamadas, Funções de Base Radial

1 Introdução

O Motor de Indução Trifásico (MIT) é a máquina mais utilizada no setor industrial, pois o mesmo possui diversas vantagens sobre os demais tipos de motores, tais como o baixo custo de aquisição, a facilidade de transporte e comando, a construção simples, a versatilidade e a robustez.

Devido a sua ampla utilização no setor industrial, o motor de indução tem uma relevância considerável no panorama energético, tornando-o assim um elemento importante para estudo. Pesquisas recentes estão relacionadas a melhoria da eficiência energética, dimensionamento adequado, técnicas de controle preciso, manutenção preditiva e qualidade de energia (Suetake, 2008). Em Lu et al. (2008) a velocidade do eixo do motor é necessária para determinar a eficiência do conjunto motor-carga.

Os motores de indução podem ser acionados de duas maneiras: a primeira quando o motor é conectado diretamente a rede elétrica e a segunda quando o motor é acionado através de inversores de frequência. Para ambos os grupos, nas diversas aplicações dos setores produtivos, há a necessidade de conhecer a velocidade no eixo da máquina, seja na forma de medida direta ou estimada (Santos et al., 2011).

A medida da velocidade nos eixos dos motores de indução é normalmente realizada através de dispositivos eletromecânicos como *encoders* ópti-

cos, *resolvers* eletromagnéticos ou tacogeradores. Entretanto, o uso destes dispositivos apresenta certas limitações em suas aplicações, tais como o aumento do custo do dispositivo de partida, redução da robustez mecânica, baixa imunidade ao ruído, alteração do momento de inércia da máquina, além de exigir especial atenção em ambientes hostis (Vas, 1998).

Visto as limitações encontradas na utilização de sensores de velocidade, têm aumentado as pesquisas para encontrar técnicas para estimar a velocidade do eixo de motores utilizando apenas medida de grandezas elétricas. Essas técnicas chamadas de *sensorless* destacam-se pela utilização do modelo matemático do motor, através da resolução de equações diferenciais, além das técnicas que utilizam Sistemas Inteligentes (SI), como as Redes Neurais Artificiais (RNA) e da lógica nebulosa.

Em Yang et al. (2007) um método para estimativa de velocidade para motores conectados diretamente a rede elétrica é proposto utilizando uma rede neural recorrente que utiliza a corrente eficaz do motor como entrada.

A utilização de lógica nebulosa ou *Fuzzy* para essa mesma finalidade pode ser encontrada em Minotti (2008) onde resultados de simulação são apresentados e comparados com outras técnicas inteligentes.

Este trabalho tem como objetivo comparar duas topologias de redes neurais artificiais, uma PMC e uma RBF as quais são aplicadas na es-

timativa de velocidade em regime permanente do rotor de um motor de indução trifásico ligado diretamente a rede elétrica. Diferentes condições de torque de carga foram abordadas para treinamento e validação das redes.

A organização do trabalho segue da seguinte forma: Na Seção 2 os aspectos da modelagem matemática do motor de indução são abordados. Na Seção 3 são apresentados os princípios relacionados às RNA. Na Seção 4 os aspectos referentes a metodologia utilizada para o desenvolvimento das estruturas neurais é descrita os resultados de simulação e experimentais são mostrados. Finalmente na Seção 5 são apresentadas as conclusões deste trabalho.

2 Motor de Indução Trifásico

A modelagem matemática do motor de indução trifásico utilizado nas simulações é apresentada conforme o equacionamento visto em Ong (1998). As variáveis referentes ao estator são seguidas do índice s e as referentes ao rotor são seguidas do índice r .

$$V_{as} = i_{as}r_s + \frac{d\lambda_{as}}{dt} \quad (1)$$

$$V_{bs} = i_{bs}r_s + \frac{d\lambda_{bs}}{dt} \quad (2)$$

$$V_{cs} = i_{cs}r_s + \frac{d\lambda_{cs}}{dt} \quad (3)$$

onde:

V_{as}, V_{bs}, V_{cs} são as tensões trifásicas do estator em *Volts*;

i_{as}, i_{bs}, i_{cs} são as correntes trifásicas do estator em *Ampère*;

$\lambda_{as}, \lambda_{bs}, \lambda_{cs}$ são os fluxos trifásicos do estator em *Weber*;

r_s é a resistência do estator em *Ohms*;

Da mesma forma as equações são utilizadas para descrever o comportamento do rotor.

$$V_{ar} = i_{ar}r_r + \frac{d\lambda_{ar}}{dt} \quad (4)$$

$$V_{br} = i_{br}r_r + \frac{d\lambda_{br}}{dt} \quad (5)$$

$$V_{cr} = i_{cr}r_r + \frac{d\lambda_{cr}}{dt} \quad (6)$$

As equações de fluxo concatenado entre os enrolamentos de rotor e estator são representadas na forma matricial como segue:

$$\begin{bmatrix} \lambda_s^{abc} \\ \lambda_r^{abc} \end{bmatrix} = \begin{bmatrix} L_{ss}^{abc} & L_{sr}^{abc} \\ L_{rs}^{abc} & L_{rr}^{abc} \end{bmatrix} \cdot \begin{bmatrix} i_s^{abc} \\ i_r^{abc} \end{bmatrix} \quad (7)$$

onde:

λ_s^{abc} é o fluxo concatenado do estator em *Weber*;

λ_r^{abc} é o fluxo concatenado do rotor em *Weber*;

i_s^{abc} é a corrente do estator em *Ampère*;

i_r^{abc} é a corrente do rotor em *Ampère*;

As matrizes de indutância mútua e de indutância própria são descritas pelas seguintes equações:

$$L_{ss}^{abc} = \begin{bmatrix} L_{ls} + L_{ss} & L_{sm} & L_{sm} \\ L_{sm} & L_{ls} + L_{ss} & L_{sm} \\ L_{sm} & L_{sm} & L_{ls} + L_{ss} \end{bmatrix} \quad (8)$$

$$L_{rr}^{abc} = \begin{bmatrix} L_{lr} + L_{rr} & L_{rm} & L_{rm} \\ L_{rm} & L_{lr} + L_{rr} & L_{rm} \\ L_{rm} & L_{rm} & L_{lr} + L_{rr} \end{bmatrix} \quad (9)$$

$$L_{rs}^{abc} = \begin{bmatrix} \cos(\theta_r) & \cos(\theta_r + 2\pi) & \cos(\theta_r - 2\pi) \\ \cos(\theta_r - 2\pi) & \cos(\theta_r) & \cos(\theta_r + 2\pi) \\ \cos(\theta_r + 2\pi) & \cos(\theta_r - 2\pi) & \cos(\theta_r) \end{bmatrix} \quad (10)$$

$$L_{sr}^{abc} = [L_{rs}^{abc}]^T \quad (11)$$

onde:

L_{ls} é a indutância de dispersão do estator em *Henry*;

L_{lr} é a indutância de dispersão do rotor em *Henry*;

L_{ss} é a indutância própria do estator em *Henry*;

L_{rr} é a indutância própria do rotor em *Henry*;

L_{sm} é a indutância mútua do estator em *Henry*;

L_{rm} é a indutância mútua do rotor em *Henry*;

L_{sr} é a indutância mútua entre estator e rotor em *Henry*;

N_s é o número de espiras do estator;

N_r é o número de espiras do rotor;

θ_r é a posição angular do rotor;

Desconsiderando as perdas no ferro, pode-se expressar estas indutâncias em termo do número de espiras do rotor e estator e a permeância do *gap* de ar existente no entreferro. As relações entre as indutâncias são expressas por:

$$L_{ss} = N_s^2 \cdot P_g \quad (12)$$

$$L_{sm} = N_s^2 \cdot P_g \cdot \cos\left(\frac{2\pi}{3}\right) \quad (13)$$

$$L_{sr} = N_s \cdot N_r \cdot N_g \quad (14)$$

$$L_{rr} = N_r^2 \cdot P_g \quad (15)$$

onde P_g é a permeância magnética.

A transformação de coordenadas é utilizada para referenciar as variáveis do modelo descrito no sistema original para outro sistema de coordenadas de referência. Para facilitar o cálculo transitório as transformadas de Park (“ $qd0$ ”) e Clark (“ $\alpha\beta0$ ”) são utilizadas transformando equações diferenciais variantes no tempo em equações de indutância constante. Esse processo é baseado no princípio da similaridade eletromagnética. O fluxo magnético produzido pelo entreferro, as correntes de estator e rotor obtidas com o sistema adotado como de referência, têm o mesmo comportamento que para o sistema original de coordenadas. Então o torque eletromagnético expresso em termos de fluxo concatenado e correntes nos eixos d e q é descrito na equação 16.

$$T_{em} = \frac{3p}{2} (\lambda_{qs} i_{ds} - \lambda_{ds} i_{qs}) \quad (16)$$

onde:

T_{em} é o torque eletromagnético em N.m;

p é o número de par de pólos;

λ_{qs} é o fluxo concatenado do estator no eixo q em Webber;

λ_{ds} é o fluxo concatenado do estator no eixo d em Webber;

i_{qs} é a corrente do estator no eixo q em Ampère;

i_{ds} é a corrente do estator no eixo d em Ampère;

O fluxo concatenado λ_{ds} e λ_{qs} são obtidos através das equações 17 e 18.

$$\lambda_{ds} = (L_{ls} + L_m) i_{ds} + L_m i_{dr}' \quad (17)$$

$$\lambda_{qs} = (L_{ls} + L_m) i_{qs} + L_m i_{qr}' \quad (18)$$

As correntes i_{dr}' e i_{qr}' são as correntes de rotor referenciadas ao lado do estator, como visto nas equações 19 e 20.

$$i_{dr}' = \frac{N_r}{N_s} i_{dr} \quad (19)$$

$$i_{qr}' = \frac{N_r}{N_s} i_{qr} \quad (20)$$

onde:

i_{qr}' é a corrente de rotor no eixo q em Ampère;

i_{dr}' é a corrente de rotor no eixo d em Ampère;

A velocidade no eixo do motor de indução considera a diferença entre o torque eletromagnético e o torque de carga. Esta diferença é definida como o torque de aceleração.

$$J \frac{d\omega_r}{dt} = T_{em} - T_l \quad (21)$$

onde:

J é o momento de inércia em kg/m^2 ;

ω_r é a velocidade do rotor em rad/s ;

T_l é o torque de carga no eixo do motor em N.m;

Após o equacionamento do motor e utilizando os parâmetros para uma máquina de 1 cv utilizados em Goedel (2007) (Tabela 1), tem-se os subsídios necessário para proceder a simulação do modelo em ambiente computacional.

Tabela 1: Parâmetros do MIT

Linha Standard – IV Pólos – 60Hz – 220/380V	
Potência	1 CV
Resistência do Estator	7,32 Ω
Resistência do Rotor	2,78 Ω
Indutância de Dispersão do Estator	8,95 mH
Indutância de Dispersão do Rotor	5,44 mH
Indutância de Magnetização	1,41 mH
Corrente Nominal do Estator	3,02 A
Momento de Inércia do Rotor	2,72.10 ⁻³ kg.m ²
Velocidade Síncrona	188,49 rad/s
Escorregamento Nominal	3,8 %
Torque Nominal	4,11 N.m

3 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são modelos computacionais inspirados no sistema nervoso dos seres vivos, tendo a capacidade de aquisição e manutenção do conhecimento. Elas podem ser definidas como um conjunto de unidades de processamento, os quais são interligados por um grande número de interconexões chamadas de sinapses artificiais (Silva et al., 2010).

As aplicações que envolvem redes neurais se destacam pois mostram-se capazes de realizar a predição sobre o comportamento de um processo, classificação de padrões, controle de processos, aproximador universal de funções entre outras.

A unidade básica de processamento de uma rede neural artificial é chamada de neurônio artificial. Este neurônio é associado a uma ou mais entradas ($x_1, x_2... x_n$) e uma saída (y). Cada uma das entradas fica associado um peso ($w_1, w_2...w_n$) que pondera de forma quantitativa cada entrada em relação à saída. O produto da entrada pelos pesos determina a primeira operação matemática de um neurônio artificial, na sequência somam-se todos estes produtos juntamente com um limiar de ativação do neurônio (b). O resultado desta soma (v) passa uma função de ativação ($g(\cdot)$) que faz a correspondência do somatório anterior com a saída (y) limitando a amplitude do sinal de saída.

A equação matemática que descreve o funcionamento de um neurônio é expressa por:

$$y_k(i) = g \left(\sum_{i=1}^n w_i \cdot x_i + b_k \right) \quad (22)$$

onde:

n é o número de entradas do neurônio;

w_i é o peso associado com a i -ésima entrada;

b_k é o limiar associado ao k -ésimo neurônio;

w_i é a i -ésima entrada do neurônio;

$g(\cdot)$ é a função de ativação do neurônio;

$y_k(i)$ é a saída do neurônio do k -ésimo neurônio em relação à amostra i ;

3.1 Rede Perceptron Multicamadas

As redes do tipo Perceptron de Múltiplas Camadas (PMC) são caracterizadas por possuir no mínimo uma camada intermediária, sendo ela situada entre a camada de entrada e a camada de saída. As aplicações das redes PMC são encontradas em diversas áreas do conhecimento, sendo uma das arquiteturas mais versáteis quanto à aplicabilidade.

O fluxo de informações na estrutura de uma PMC se inicia na camada de entrada, percorre as camadas intermediárias existentes e é então finalizado na camada neural de saída. Uma ilustração de uma rede do tipo PMC é mostrada na Figura 1.

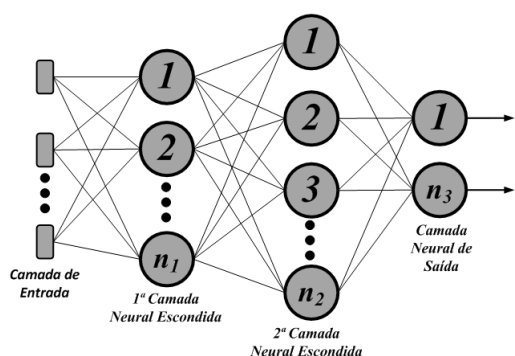


Figura 1: Ilustração de uma PMC

O treinamento de uma PMC é a fase em que seus pesos sinápticos são ajustados. O algoritmo de treinamento utilizado é o de retropropagação do erro (*backpropagation*) e é aplicado para o ajuste dos pesos, conhecido também como regra Delta generalizada.

Esse algoritmo é realizado em duas fases: a primeira chamada de *forward*, onde os sinais de uma amostra de treinamento são inseridos na rede e propagados por cada camada produzindo suas respectivas saídas e em seguida comparados com as respectivas respostas desejadas para o cálculo do erro. Na segunda fase, também chamada de *backward* ou propagação reversa, os ajustes dos pesos sinápticos e dos limiares de cada neurônio da rede são executados.

O erro utilizado para ajuste dos pesos é calculado através da saída $y_k(i)$ conforme a equação 23, e comparada com a saída desejada.

$$e_k(i) = d_k(i) - y_k(i) \quad (23)$$

$d_k(i)$ é a saída desejada do k -ésimo neurônio em relação à amostra i .

$e_k(i)$ é erro calculado do k -ésimo neurônio em relação à amostra i .

A função de erro quadrático é utilizada para medir o desempenho local da rede e é mostrada na equação 24.

$$E(i) = \frac{1}{2} \sum_{k=1}^m (e_k(i))^2 \quad (24)$$

m é o número de neurônios da rede .

$E(i)$ é o erro quadrático obtido para a amostra i .

Assumindo um conjunto de treinamento de p amostras, a evolução do desempenho global do algoritmo *backpropagation* é feita através da avaliação do “erro quadrático médio”, conforme visto em (Silva et al., 2010).

$$E_M = \frac{1}{p} \sum_{k=1}^p E(i) \quad (25)$$

O objetivo do processo de aprendizagem, utilizando o algoritmo *backpropagation*, consiste em ajustar as matrizes de pesos referentes a primeira e segunda camada da rede a fim de minimizar a função E_M .

3.2 Rede de Funções de Base Radial

As redes RBF podem ser utilizadas em praticamente todos os problemas que uma PMC é capaz de resolver, tanto como aproximador de funções quanto classificador de padrões (Silva et al., 2010).

A estrutura de uma RBF difere pelo fato delas possuírem apenas uma camada intermediária, enquanto as PMC podem ser compostas por diversas camadas escondidas. Uma ilustração da estrutura típica de uma RBF é mostrada na Figura 2.

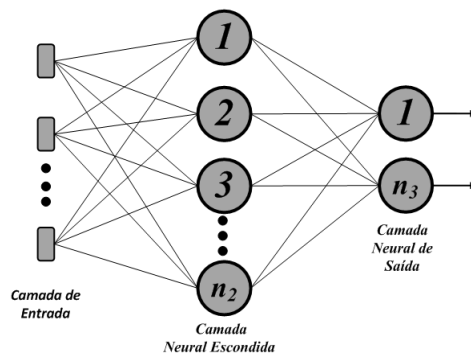


Figura 2: Ilustração de uma RBF

As funções de ativação da camada intermediária de uma RBF são necessariamente do tipo gaussiana, enquanto na camada de saída são do tipo linear.

O funcionamento das redes RBF é bem similar a uma PMC, a arquitetura é *feedforward* de camadas múltiplas e o treinamento é feito da maneira supervisionada. Porém o treinamento de uma RBF é constituído de duas fases bem distintas entre si.

O primeiro estágio, onde é feito o ajuste de pesos da camada intermediária, adota um método de aprendizagem auto-organizado (não-supervisionado). Neste estágio é feito as alocações das funções de base radial, sendo dependente apenas das características dos dados de entrada.

O segundo estágio consiste no ajuste dos pesos da camada de saída, sendo utilizado a regra delta generalizada. Esta é similar ao critério de aprendizagem utilizado no ajuste dos pesos de uma PMC (Silva et al., 2010).

Em comparação, uma rede PMC requer um número menor de parâmetros que uma rede RBF para obter um mesmo grau de precisão para um mapeamento de entrada-saída não-linear (Haykin, 2001).

3.3 Rede de Entradas Atrasadas no Tempo

Nas aplicações de redes neurais em problemas envolvendo sistemas dinâmicos, duas configurações de RNA surgem como alternativas para a aplicação deste trabalho. As topologias são as redes com entradas atrasadas no tempo (*TDNN - time delay neural network*) e as redes com saídas recorrentes às entradas.

As redes de entradas atrasadas no tempo são enquadradas dentro da arquitetura *feedforward*, inexistindo qualquer realimentação das saídas de neurônios de camadas posteriores em direção a primeira camada.

Neste trabalho serão consideradas também topologias de redes com entradas atrasadas no tempo, no caso, uma PMC e um RBF, cada uma com uma entrada em tempo real e uma outra com atraso.

4 Estimador Neural de Velocidade

Para o desenvolvimento dos estimadores propostos neste trabalho foram utilizados dados obtidos através de simulações computacionais e dados experimentais obtidos através de uma bancada de ensaios de máquinas elétricas.

Na etapa de simulação foi utilizado o modelo desenvolvido no Matlab/Simulink para proporcionar os dados das correntes de estator e velocidade. Nos ensaios o MIT, cujo parâmetros estão mostrados na Tabela 1, foi alimentado com tensões equilibradas e nominal, para várias faixas de torque de carga que foram de 1 a 6 N.m. A Figura 3 mostra um diagrama de blocos que exemplifica a simulação do modelo.




Figura 3: Modelo do motor de indução

Os dados simulados foram utilizados no treinamento das quatro estruturas diferentes de RNA, todas necessitando de apenas uma entrada de corrente para estimar a velocidade do MIT. Foram utilizadas uma PMC, uma PMC com uma entrada atrasada de uma amostra, uma RBF e uma RBF com uma entrada atrasada também de uma amostra. Todas as estruturas neurais contêm uma camada escondida com 5 neurônios e um neurônio na camada de saída. Nas PMC a função de ativação na camada intermediária foi a tangente hiperbólica e a linear na camada de saída.

Outras quatro topologias idênticas de RNA foram estudadas, sendo a principal diferença em relação as anteriores, o uso de dados experimentais obtidos na bancada de ensaios mostrado na Figura 4.



Figura 4: Bancada de ensaio de máquinas

O funcionamento da bancada de testes consiste em acoplar o motor de indução trifásico a um Gerador de Corrente Contínua (GCC). A variação da tensão de campo do GCC, através de uma fonte de corrente contínua, possibilita a variação no torque de carga do MIT em operação. A energia gerada pelo GCC no processo é dissipada em uma carga resistiva ligada a armadura da máquina. Um tacogerador é responsável por medir a velocidade do MIT e o torquímetro mensura o torque no eixo. As correntes e tensões são medidas através de sensores de efeito Hall.

Para o treinamento das redes, tanto com dados de simulação e tanto com dados experimentais, foram utilizados 75% dos dados no treinamento e 25% dos dados na validação das topologias.

Os resultados envolvendo as redes PMC, RBF, PMC com uma entrada atrasada e RBF com uma entrada atrasada e treinadas com os dados obtidos em simulação são mostrados na Figura 5.

Para as quatro redes o erro relativo médio (ERM) obtido foi relativamente baixo para os dados simulados. As redes PMC tiveram um melhor desempenho que as RBF, sendo um ERM de 0,0465% para a rede PMC, e de 0,0619% para a rede RBF. Comparando as redes com uma entrada atrasada, a PMC também teve ERM menor, sendo de 0,0247% para a PMC com uma entrada atrasada, e um ERM de 0,0463% para a RBF com uma entrada atrasada. É possível perceber que as

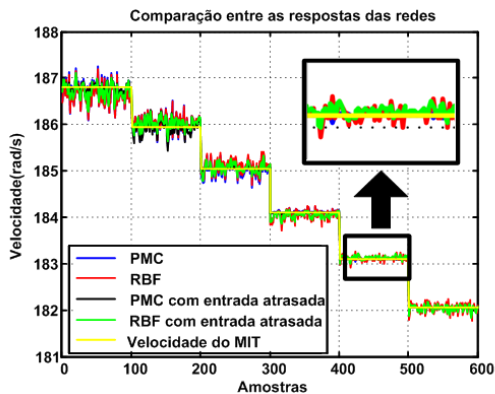


Figura 5: Resultados com dados de Simulação.

redes que utilizaram uma entrada atrasada obtiveram melhor desempenho.

Os resultados obtidos com as quatro redes treinadas com valores experimentais são mostrados na Figura 6. Da mesma forma que para os

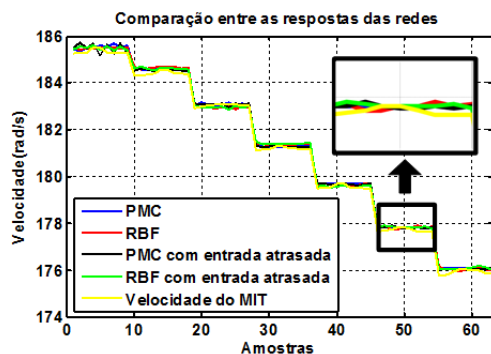


Figura 6: Resultados com dados Experimentais.

resultados obtidos com simulação as redes PMC obtiveram melhor resposta que as RBF, considerando as topologias sem entrada atrasada, o ERM para a rede PMC foi de 0,076% e para RBF foi de 0,0849%. Para as redes com uma entrada atrasada o ERM foi de 0,0733% para a PMC e de 0,0846% para a RBF.

5 Conclusões

Este trabalho apresentou diferentes topologias neurais para estimar a velocidade de um motor de indução trifásico conectado diretamente a rede, utilizando apenas um sensor de corrente.

As RNA demonstraram um bom desempenho para o domínio na qual foram treinadas. As redes PMC obtiveram um ERM menor que as redes RBF. Em comparação as diferentes arquiteturas utilizadas, as redes com uma entrada atrasada obtiveram um erro mais baixo em relação as demais.

O estudo mostra a possibilidade de se usar uma RNA com apenas uma entrada de corrente para estimar a velocidade do MIT, com resultados satisfatório, mesmo com diferentes torques de

carga aplicados e com o motor alimentado equilibradamente.

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

- Goedtel, A. (2007). *Estimador Neural de Velocidade para Motores de Indução Trifásico*, PhD thesis, Escola de Engenharia de São Carlos - Universidade de São Paulo, São Carlos-SP.
- Haykin, S. (2001). *Redes Neurais Princípios e Prática*, Bookman, Porto Alegre, RS.
- Lu, B., Durocher, D. and Stemper, P. (2008). Online and nonintrusive continuous motor energy and condition monitoring in process industries, *Pulp and Paper Industry Technical Conference, 2008. PPIC 2008. Conference Record of 2008 54th Annual*, pp. 18–26.
- Minotti, C. (2008). *Estimador fuzzy de velocidade para motores de indução trifásicos usando abordagem sensorless*, Master's thesis, Universidade de São Paulo, São Carlos-SP.
- Ong, C. M. (1998). *Dynamic simulation of electric machinery: using MATLAB/SIMULINK*, Prentice Hall, Upper Saddle River, NJ-USA.
- Santos, T. H., Goedtel, A., Silva, S. A. O. and Suetake, M. (2011). A neural speed estimator in three-phase induction motors powered by a driver with scalar control, *Brazilian Power Electronics Conference (COBEP) 1*: 44–49.
- Silva, I. N., Spatti, D. H. and Flauzino, R. A. (2010). *Artificial Neural Networks: engineering and applied sciences (in Portuguese)*, 1 edn, Artliber, São Paulo, SP.
- Suetake, M. (2008). *Implementação de sistemas inteligentes em processadores digitais para controle de máquinas elétricas rotativas*, Master's thesis, Universidade de São Paulo, São Carlos-SP.
- Vas, P. (1998). *Sensorless vector and direct torque control*, Oxford University Press, USA.
- Yang, J., Wang, L., Xu, D. and Xue, B. (2007). Sensorless speed estimation for line-connected induction motor based on recurrent multilayer neural network, *IEEE International Conference on Automation and Logistics* pp. 2013–2018.