

ESTIMAÇÃO DE TORQUE DE MOTOR DE INDUÇÃO POR MEIO DE REDES NEURAIS ARTIFICIAIS

Francisco A. S. Picanço¹, Emanuel B. de A. Cajueiro¹, Lazaro E. B. Silva²

¹ SENAI CIMATEC- Avenida Orlando Gomes, 1845- Piatã, 41650010, Salvador, Bahia, Brasil.

email: - chicopicanco@yahoo.com.br - emanuelbenicio@gmail.com

² PPGEE, UFBA- Rua Aristides Novis n.02, 4º andar, sala 23 Federação Salvador, Bahia, Brasil

email: -lazaro.brito@uol.com.br

RESUMO

Neste artigo, a estimação do comportamento do torque de um motor de indução trifásico(MIT) é obtida. utilizou-se uma rede neural artificial tipo Perceptron, disposta em multicamadas, que devidamente treinada por retropropagação, a partir do modelo do circuito elétrico, variação de escorregamento e valor eficaz da corrente de estator forneceu na saída o torque desejado. A fonte de dados empregada no estudo dispõe de um vetor de características simuladas a partir do modelo clássico do motor de indução parâmetros obtidos por meio de testes experimentais de rotor travado e sem carga acoplada. O treinamento da rede utilizou o algoritmo Levenberg Marquardt , o que contribuiu para uma convergência do erro médio quadrático na ordem de 10^{-5} , em cerca de pouco mais de 4 minutos e 595 interações. Com a rede neural treinada, um vetor de dados simulados foi aplicado a entrada desta, resultando valores estimados de torque eletromecânico na saída. Os resultados obtidos, com a metodologia proposta, revelaram uma alternativa no estudo e identificação de motores trifásicos, visto que, comparando se os valores simulados e os valores estimados pela rede, o erro médio observado ficou dentro da faixa de valores esperada.

Palavras-chaves: estimação de torque; motor de indução; redes neurais artificiais.

ABSTRACT

In this paper, the estimation of the three phase induction machines torque behavior is obtained. The methodology used an artificial neural network type Perceptron, arranged in multilayers, that properly trained by backpropagation, from the electrical circuit model, slip variation and effective value of the stator current supplied in output the desired torque. The source of data used in the study arranged a simulated feature vector from the classic model parameters induction motor obtained through experimental testing with locked rotor and no load. The network training used the Levenberg Marquardt algorithm, which contributed to a convergence of the mean square error in the order of 10^{-5} , at about just over 4 minutes and 595 interactions. With the trained neural network, a simulated data vector was applied to the input of this resulting estimate of electromechanical torque on output. The results obtained with the proposed methodology, revealed an alternative in the study and identification of three phase induction machines, since comparing the simulated values and the values estimated by the network, the observed average error was within the expected value range.

Keywords: torque estimation; induction machines; artificial neural networks.

1. INTRODUÇÃO

Os motores de indução trifásicos são equipamentos eletromecânicos com grande aplicação em processos industriais que necessitam de movimentação e transporte de cargas e produtos. Por meio do fenômeno físico da indução eletromagnética, estes equipamentos podem converter energia elétrica em mecânica com robustez, simplicidade e custo, relativamente baixo, comparado com outros equipamentos industriais.

A busca pelo uso eficiente da energia elétrica tem provocado estudos sobre a melhoria dos processos industriais. Neste contexto os motores de indução trifásicos representam um dos objetos de estudo. No caso particular dos motores, o estudo envolve a análise das equações do modelo dinâmico, mais precisamente a determinação de parâmetros como corrente por fase, resistência de estator e torque eletromagnético [1].

No estudo de técnicas de identificação dos parâmetros dos motores elétricos de indução tipo gaiola de esquilo, [2] apresenta uma proposta baseada no modelo de estado estacionário da corrente de fase e potência de entrada, em função do escorregamento, utilizando um algoritmo não linear de identificação. Tratando especificamente do torque, [3] apresenta uma abordagem de identificação baseada em sistemas *fuzzy*. A proposta deste trabalho consistiu na utilização de sistemas *fuzzy* como uma alternativa aos métodos tradicionais para levantamento do

10 e 11 de setembro de 2015 / Salvador, Bahia, Brasil

comportamento de carga e, em processos de controle, onde há a necessidade de conhecimento do comportamento do conjugado aplicado ao eixo do motor.

O torque é uma grandeza física associada ao movimento de rotação que, no caso de motores, está relacionada ao rotor, em razão da força eletromagnética provocada pela interação deste com o estator [4]. Já as redes neurais artificiais (RNAs) são estruturas matemáticas, na maioria das vezes concebidas por meio de algoritmos computacionais, que encontram aplicações no reconhecimento e classificação de padrões, geralmente não lineares [5]. Conforme comenta [6], a modelagem matemática ou identificação utilizando RNAs é uma linha de pesquisa que tem provocado entusiasmo entre os pesquisadores. Contudo, grande parte dos estudos envolvendo RNAs e o torque eletromecânico dedicam-se ao reconhecimento de padrões de operação e classificação falhas, conforme pode ser observado no trabalho de [1]. Diante disso, este trabalho apresenta uma alternativa no estudo do torque eletromecânico de motores de indução triásico, utilizando RNAs como elemento de identificação deste torque, a partir da característica de escorregamento e da corrente eficaz do estator do motor, obtido por meio do modelo dinâmico do motor.

2. Modelo Dinâmico do Motor

O estudo do funcionamento, em regime permanente, do motor de indução triásico, tipo gaiola de esquilo, pode ser realizado com o auxílio do circuito equivalente apresentado na Figura 1.

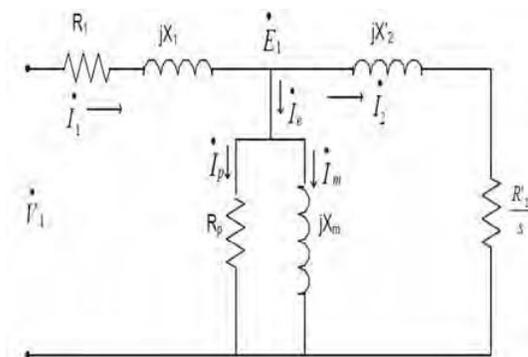


Figura 1. Circuito equivalente do motor

Neste circuito as grandezas são apresentadas na forma de fasores nos quais as magnitudes representam os valores eficazes das seguintes grandezas:

- V_1 - tensão eficaz por fase aplicada no estator;
- jX_1 - reatância de dispersão do estator;
- R_1 - resistência elétrica do estator;
- I_1 - corrente elétrica no enrolamento do estator;
- E_1 - tensão de excitação do motor;
- I_e - corrente de excitação do motor;
- I_m - corrente de magnetização do motor;
- R_p - resistência de perdas no ferro do motor;
- I_p - corrente de perdas no ferro no motor;
- X_m - reatância de magnetização;
- I_2 - corrente no rotor referida ao estator;
- X_2' - reatância de dispersão do rotor referida ao estator;
- R_2' - resistência do rotor referida ao estator;
- S - escorregamento do motor.

Para o circuito equivalente ilustrado na Figura 1 é comum colocar uma resistência em paralelo com a reatância de magnetização com a finalidade de representar as perdas no ferro da máquina. Essas perdas são relativas ao fluxo magnético principal da máquina, que produz a força eletromotriz do estator [4]. A partir do circuito equivalente é possível obter relações matemáticas que podem determinar o comportamento do motor em diferentes condições de operação. Duas dessas relações são representadas pelas equações da corrente do rotor e o torque eletromagnético expressas a seguir como sugere [2]:

$$I(s) = V_1 \sqrt{\frac{\alpha^2 + \beta^2}{\gamma^2 + \theta^2}} \quad (1)$$

$$T(s) = 3V_1^2 \frac{p R_p 2R_2' / s}{\omega \gamma^2 + \theta^2} \quad (2)$$

Nas quais

$$\alpha = \frac{R'_2}{s} + R_p \left(1 + \frac{x_2^2}{x_m} \right) \quad (3)$$

$$\beta = \frac{x_p x_2'}{s x_m} - x_2' \quad (4)$$

$$\gamma = x_1 \left(\frac{x_p x_2'}{s x_m} - x_2' \right) + R_1 \left(\frac{R'_2}{s} + R_p \left(1 + \frac{x_2'}{x_m} \right) \right) \quad (5)$$

$$\theta = x_1 \begin{pmatrix} \frac{R'_2}{s} + R_p \left(1 + \frac{x_2'}{x_m} \right) \\ - R_1 \left(\frac{x_p x_2'}{s x_m} - x_2' \right) \end{pmatrix} + R_p x_2' \quad (6)$$

É possível observar que as equações (1) e (2) dependem do escorregamento do motor. O escorregamento representa a diferença entre a velocidade de rotação do rotor e a velocidade síncrona da máquina, e pode variar de 1 até zero, indicando desde o estado do rotor trancado até o estado do rotor operado sem carga na velocidade nominal. A equação (2) em especial apresenta uma dependência da relação entre a quantidade de polos " p " do motor e a velocidade angular " ω " do rotor. Contudo as funções apresentadas envolvem relações de não linearidade na descrição do estado de regime permanente do motor de indução.

3. ESTIMADOR DE TORQUE NEURAL

O elemento básico de processamento do estimador é o neurônio artificial que é apresentado na Figura 2:

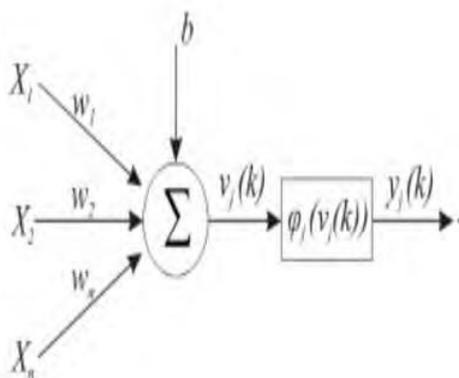


Figura 2. Modelo de Neurônio Artificial

A função matemática de saída desse elemento básico pode ser expressa por:

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

Na qual:

$$v_j(k) = \sum_{i=1}^n x_i w_i + b \quad (8)$$

E os seus parâmetros são descritos por:

- n - número de entradas do neurônio artificial;
- X_i - é a i -ésima entrada do neurônio;
- w_i - peso associado a i -ésima entrada;
- b - é o bias associado ao neurônio;
- ϕ_j - é a função de ativação do neurônio;
- y_j - é a saída do neurônio.

Dessa forma, cada neurônio processa informações presentes em sua entrada e, por meio da função de ativação, fornece um sinal de saída. As funções de ativação são não lineares como as função tangente hiperbólica e sigmoide mas podem ser usadas a função linear ou a linear com saturação. A associação de neurônios de forma que a informação de saída de um alimenta as entradas dos demais, constitui a rede neural artificial. O erro produzido na saída do n -ésimo neurônio artificial, provocado pelo n -ésimo vetor de entrada, e utilizado para ajustar os pesos sinápticos da rede. o erro pode ser calculado pela seguinte equação:

$$E_j = y_j(n) - y_{est_j}(n) \quad (9)$$

Na qual $y_j(n)$ representa o valor desejado na saída da rede e $y_{est_j}(n)$ e o valor estimado obtido na saída da rede. A soma de todos os erros quadráticos, produzidos por cada neurônio de saída, produz uma função de erro que deve ser minimizada por meio do ajuste dos pesos da rede em cada interação. Nesse sentido [7] sugeriram a elaboração do algoritmo de retropropagação para minimização do erro pelo ajuste dos pesos da rede. Neste trabalho foi concebida uma RNA para a estimação do torque do motor de indução, a partir do valor eficaz da corrente no estator e a variação do escorregamento.

4-MATERIAIS E MÉTODOS

A rede utilizada foi do tipo Perceptron Multicamada, (uma camada de entrada com dois neurônios, duas camadas intermediárias com 33 neurônios cada uma e uma camada de saída com um neurônio), com arquitetura feedforward. Os neurônios das camadas intermediárias possuíam função de ativação do tipo tangente sigmoide; já o neurônio de saída possuía função de ativação tipo linear. A escolha do número de camadas da RNA, bem como a quantidade de neurônios que fizeram parte de sua composição, foi feita de forma empírica. Contudo, elementos como tipo de algoritmo de treinamento e funções de ativação dos neurônios seguiram recomendações presentes na literatura como em [5].

A RNA foi implementada em um algoritmo desenvolvido no MATLAB®. Nesse algoritmo foram utilizados dados de testes experimentais de rotor travado e sem carga acoplada, de um motor trifásico 220VAC, 60Hz e 1,5k apresentados em [2]. Esses dados podem ser observados na Tabela 1 a seguir:

Tabela 1. Tabela de dados

	Parâmetros do Motor(Ω)
Rr	3,84
Xr	6,789
Xs	1,658
Rs	1,93
Xm	38,7

Com as informações apresentadas na Tabela 1 e com as equações (1) e (2) foram gerados 123 dados de corrente e torque eletromagnético, respectivamente, a partir da variação do escorregamento desde a condição do rotor girando sem carga acoplada, até a condição de rotor travado. Do total de dados citados, 103 foram aplicados ao treinamento da RNA e 20 aplicados a simulação.

5. RESULTADOS E SIMULAÇÕES

V WORKSHOP DE PESQUISA TECNOLOGIA E INOVAÇÃO (PTI)
I SIMPÓSIO INTERNACIONAL DE INOVAÇÃO E TECNOLOGIA (SIINTEC)

10 e 11 de setembro de 2015 / Salvador, Bahia, Brasil

O desempenho da RNA pode ser apreciado na Figura 3 a seguir:

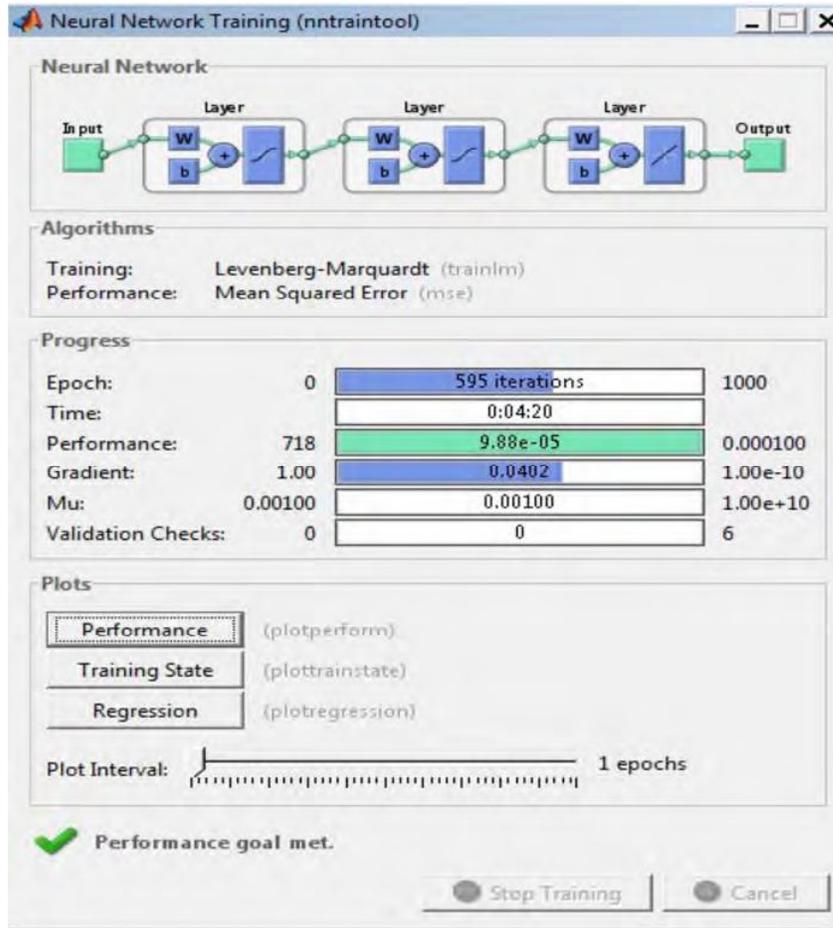


Figura 3. Treinamento da RNA

Conforme é ilustrado na Figura 3, o treinamento da RNA ocorreu durante 4 minutos e vinte segundos, totalizando 595 interações. Durante as interações,

- o algoritmo de retropropagação de treinamento, chamado de Levenberg Marquardt, buscava minimizar o erro entre o valor da saída esperada e o valor da saída estimada, por cada neurônio da rede.
- o erro médio quadrático durante o treinamento chegou ao valor de $9,88 \times 10^{-5}$; e o gradiente alcançado foi de 0,0402 com um momento de 0.00100. Na Figura 4 é possível verificar o comportamento do treinamento a partir da relação entre o erro quadrático médio e o numero de interações.

V WORKSHOP DE PESQUISA TECNOLOGIA E INOVAÇÃO (PTI)
I SIMPÓSIO INTERNACIONAL DE INOVAÇÃO E TECNOLOGIA (SIINTEC)

10 e 11 de setembro de 2015 / Salvador, Bahia, Brasil

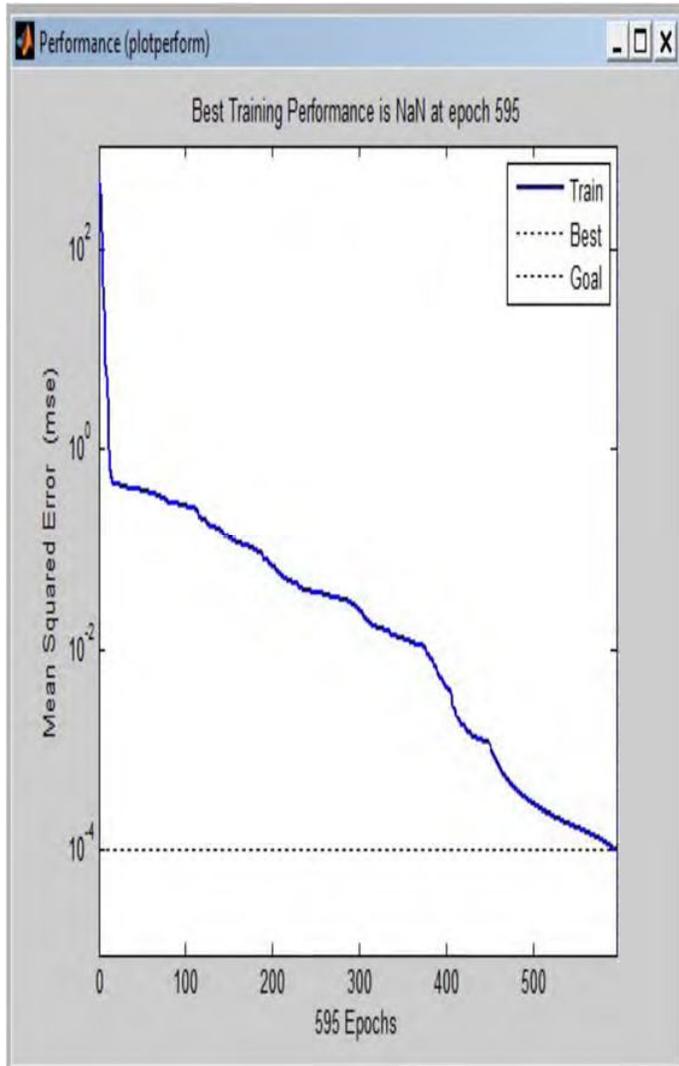


Figura 4. Comportamento do treinamento

Após a etapa de treinamento a RNA foi submetida a um conjunto de vinte dados para simulação apresentados na Tabela 2 apresentada a seguir:

Tabela 2. Dados para simulação de rede treinada

Corrente (A)	Escorregamento	Torque $\left(\frac{N \times m}{rad / s}\right)$
-----------------	----------------	---

5,4625	0,0181	2,6883
7,2240	0,0667	10,9946
7,6630	0,0991	14,2943
9,4946	0,1558	22,1279
11,8717	0,1882	25,7802
12,7171	0,2206	28,3722
113,9955	0,2611	29,5791
15,7211	0,3421	32,1177
16,3823	0,3178	30,8945
17,4287	0,3502	32,6818
18,2484	0,4069	33,0481
19,0431	0,4555	33,9831
20,0178	0,4393	34,4865
21,5610	0,5770	34,4677
22,3830	0,6742	31,4161
23,6255	0,7552	29,7345
24,4352	0,8362	29,2934
24,7510	0,9739	26,3467
25,0342	0,9334	25,6813
25,2285	0,9982	25,7751

A aplicação dos dados de escorregamento e corrente, observados na Tabela 2, RNA treinada resultou em um vetor de saída, cujos elementos foram comparados com os valores do vetor de torque utilizado para simulação de desempenho da rede. Calculando-se o erro médio quadrático o número encontrado foi $23,166 \times 10^{-5}$.

6. CONCLUSÕES

A partir do modelo do circuito elétrico do motor de indução trifásico e de parâmetros obtidos por meio dos testes de rotor trancado e sem carga acoplada, a rede neural artificial, desenvolvida e treinada em um algoritmo no MATLAB @, foi capaz estimar o valor do torque eletromagnético de um motor depois de ser submetida a uma amostra de valores de escorregamento e corrente de estator. Durante a fase de elaboração e treinamento da RNA, observou-se que o aumento do número de neurônio nas camadas intermediárias interfere no tempo de processamento da rede: quanto mais neurônios maior o tempo de processamento. Já a convergência da rede tem relação com a correta modelagem do sistema adotado para estudo, e por conseguinte, com os dados fornecidos a rede para treinamento e simulação. Apesar do erro quadrático médio, tanto na etapa de treinamento como na etapa de simulação, tender para valores na ordem de 10^{-5} abaixo do esperado que foi 10^{-4} , foi observada divergência entre

os valores absolutos encontrados. Este fato ocorreu porque 4 valores estimados pela rede apresentaram erro superior a 10^{-4} o que comprometeu o erro quadrático médio calculado.

Em linhas gerais, os resultados obtidos, com a metodologia proposta, revelam uma alternativa no estudo e identificação de motores trifásicos.

7. REFERÊNCIAS

¹ REIS, A. J. S. Reconhecimento de Padrões de Falhas em Motores em Motores Trifásicos Utilizando Redes Neurais. Dissertação (Mestrado em Engenharia Elétrica) -Universidade Federal do Rio Grande do Norte, Natal, **2010**.

² LIMA, A. M. N.; JACOBINA, C. B.; FILHO, E. B. d. S. Nonlinear parameter estimation of steadystate induction machine models. IEEE Transaction on Industrial Electronics, v. 44, n. 3, p. 390–397, June **1997**.

³ SILVA, S. F. d. Identificação de Torque de Carga em Motores de Indução Usando Abordagem Baseada em Sistemas Fuzzy. Dissertação (Mestrado em Engenharia Elétrica) - Escola de Engenharia da Universidade de São Paulo, São Carlos, **2007**.

⁴ FITZGERALD, A. E.; JUNIOR, C. K.; UMANS, S. D. Máquinas Elétricas. 6th. ed. [S.l.]: Bookman, **2006**.

⁵ HAYKIN, S. S. Redes Neurais: princípios e práticas. 2th. ed. [S.l.]: Bookman Companhia Ed, **2001**.

⁶ CERQUEIRA, J. d. J. F. Identificação de Sistemas Dinâmicos Utilizando Redes Neurais Artificiais: Uma aplicação a Manipuladores Robóticos. Dissertação (Doutorado em Engenharia Elétrica) -Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas, Campinas, **2001**.

⁷ RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Parallel Distributed Processing: Exploration in The Microstructure of Cognition. [S.l.]: Cambridge, **1986**.