

Estimativa de velocidade de motores de indução trifásicos do domínio do tempo, utilizando uma rede neural *MLP* treinada pelo algoritmo backpropagation

Marcos F.S.V.D'Angelo

Yuri J. Kimo

Resumo

O presente trabalho propõe uma metodologia para monitorar a velocidade de um motor de indução utilizando técnicas de inteligência artificial. Devido a grande quantidade de motores de indução na área industrial, e tendo em vista que estes sustentam os processos industriais, deve-se fazer uma avaliação mais qualitativa das condições de operação destes equipamentos. O trabalho faz uma proposta para a avaliação do estado atual da velocidade do motor de indução. A utilização de redes neurais (mais precisamente a rede neural MLP, treinada pelo algoritmo backpropagation), como ferramenta da inteligência artificial para a avaliação do estado da velocidade do motor de indução, possibilita a generalização e extensão de monitorização de outros parâmetros. O trabalho foi realizado através de simulações e apresenta um estudo de caso no qual são mostrados os resultados da simulação.

Palavras-chave: máquina de indução, redes neurais, velocidade, backpropagation

Abstract

The present work proposes a methodology to monitor the speed of a induction machine trough techniques of artificial intelligence. Due to great amount of those equipment in the industrial area, and having in mind that they are the basis of the industrial processes, it should be made a more qualitative evaluation of the operational conditions of those equipment's. The work makes a proposal for the evaluation of the current induction engine's speed actual state. The use of neural nets (more precisely the neural network MLP, trained by backpropagation algorithm) as tool of the artificial intelligence for the evaluation of the induction engine's speed actual state makes possible the generalization and extension of monitoring of other parameters. The work was accomplished through simulations and it presents a study case in which the simulation results are shown.

Key-words: $\frac{3}{4}$ induction machine, neural network, speed, backpropagation algorithm

1. INTRODUÇÃO

O motor de indução ou assíncrono de corrente alternada tem sido o motor preferido da indústria desde o princípio do uso da energia elétrica em corrente alternada. Ele alcançou e manteve sua posição em virtude de sua robustez, simplicidade e baixo custo. A linha padrão de motores de indução inclui o popular motor de gaiola de esquilo e o versátil motor de anéis, além de variações destes motores básicos como os para aplicação em dupla velocidade, de velocidade variável, para pontes rolantes, prensas e outras aplicações. As aplicações de motores de indução alimentados por inversores de frequência (acionamento com velocidade variável) têm apresentado um crescimento significativo nos últimos anos. A evolução tecnológica da eletrônica com o desenvolvimento de semicondutores (transistores, tiristores etc) cada vez mais rápidos, aliada a controles e interfaces (usuário/máquina) sofisticados e principalmente de custos menores, têm tornado este tipo de aplicação uma realidade irreversível.

O principal objetivo deste trabalho foi o desenvolvimento de um sistema de estimativa de velocidade de motores de indução, com o objetivo de substituir tacômetros em plantas de controle de velocidade ou de controle vetorial de motores de indução, visto que estes equipamentos possuem custos elevados.

2. O MODELO DA MÁQUINA DE INDUÇÃO

O modelo utilizado para simulação foi desenvolvido em variáveis “dq”, veja KRAUSE(1995), e representa as equações do circuito equivalente do motor de indução.

A transformação das tensões de variáveis naturais para variáveis “dq”, em uma referência arbitrária, como representado no diagrama fasorial da FIG. 1, é obtida pelo conjunto de equações (1,2,3 e 4).

$$\begin{aligned}
 V_{ds} = \frac{3}{2} * (V_a * \cos(\theta_s) \\
 + V_b * \cos(\theta_s - \frac{2\pi}{3}) \\
 + V_c * \cos(\theta_s - \frac{2\pi}{3}))
 \end{aligned} \tag{1}$$

$$\begin{aligned}
 V_{qs} = \frac{3}{2} * (V_a * \sin(\theta_s) \\
 + V_b * \sin(\theta_s - \frac{2\pi}{3}) \\
 + V_c * \sin(\theta_s - \frac{2\pi}{3}))
 \end{aligned} \tag{2}$$

$$V_{dr} = 0 \tag{3}$$

$$V_{qr} = 0 \tag{4}$$

onde Θ é o ângulo entre a fase "a" do estator e o eixo "d".

A seguir, é apresentado o conjunto de equações de estado de enlace de fluxo, de corrente, de conjugado eletromagnético e de velocidade que descreve o comportamento dinâmico do motor de indução.

$$p \begin{bmatrix} \lambda_{ds} \\ \lambda_{qs} \\ \lambda_{dr} \\ \lambda_{qr} \end{bmatrix} = \begin{bmatrix} 0 & \omega & 0 & 0 \\ \omega & 0 & 0 & 0 \\ 0 & 0 & 0 & (\omega - \omega_r) \\ 0 & 0 & (\omega - \omega_r) & 0 \end{bmatrix} * \begin{bmatrix} \lambda_{ds} \\ \lambda_{qs} \\ \lambda_{dr} \\ \lambda_{qr} \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} V_{ds} - R_s * I_{ds} \\ V_{qs} - R_s * I_{qs} \\ V_{dr} - R_r * I_{dr} \\ V_{qr} - R_r * I_{qr} \end{bmatrix} \quad (5)$$

Figura1. Diagrama fasorial representativo do modelo "abc" e "dq"

onde:

V_{ds} -> Tensão no eixo direito do estator

V_{qs} -> Tensão no eixo em quadratura do estator

V_{qr} -> Tensão no eixo em quadratura do rotor

V_{dr} -> Tensão no eixo do direto do rotor

V_a -> Tensão na fase "a" do estator

V_b -> Tensão na fase "b" do estator

V_c -> Tensão na fase "c" do estator

$\hat{\lambda}_{ds}$ -> fluxo no eixo do estator

$\hat{\lambda}_{qs}$ -> fluxo no eixo em quadratura do estator

$\hat{\lambda}_{dr}$ -> fluxo no eixo direto do rotor

$\hat{\lambda}_{qr}$ ->fluxo no eixo em quadratura do rotor

ω -> velocidade do campo girante

$$I_{qs} = \left(\frac{L_r}{L_r * L_s - M^2} * \lambda_{qs} \right. \\ \left. - \frac{M}{L_r * L_s - M^2} * \lambda_{qr} \right)$$

$$I_{dr} = \left(\frac{L_s}{L_r * L_s - M^2} * \lambda_{dr} \right. \\ \left. - \frac{M}{L_r * L_s - M^2} * \lambda_{ds} \right)$$

$$I_{qr} = \left(\frac{L_s}{L_r * L_s - M^2} * \lambda_{qr} \right. \\ \left. - \frac{M}{L_r * L_s - M^2} * \lambda_{qs} \right) \quad (9)$$

$$T_e = \frac{3}{2} * \frac{P}{2} * (\lambda_{ds} * I_{qs} - \lambda_{qs} * I_{ds}) \quad (10)$$

$$\omega_r = \int \frac{(T_e - T_l)}{J} dt \quad (11)$$

ω_r -> velocidade no eixo do rotor

I_{ds} -> Corrente do eixo direto do estator

I_{qs} -> Corrente do eixo em quadratura do estator

I_{dr} -> Corrente do eixo direto do rotor

(7) I_{qr} -> Corrente do eixo em quadratura do rotor

T_e -> Conjugado eletromagnético produzido pelo motor

T_l -> Conjugado da carga do eixo do motor

L_s -> Indutância própria do estator

L_r -> Indutância própria do rotor

M -> Indutância de magnetização

R_s -> Resistência do estator

R_r -> Resistência do rotor

(8) P -> Número de pólos

J -> Momento de Inércia do Motor

p -> símbolo de derivada

3. REDE NEURAL MLP

Em uma rede neural de múltiplas camadas são identificadas a camada de entrada, as camadas intermediárias e a camada de saída, como mostrado na FIG. 2. O treinamento supervisionado da rede MLP, utilizando o algoritmo *backpropagation* consiste em dois passos. No primeiro, um padrão é apresentado às unidades da camada de entrada e, a partir desta camada, as unidades calculam sua resposta que é produzida na camada de saída, onde o erro é calculado. No segundo passo, este erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados, utilizando a regra delta generalizada, veja FREEMAN(1992), KOVÁCS(1996), BRAGA(2000), WIDROW(1991) e WERBOS(1991).

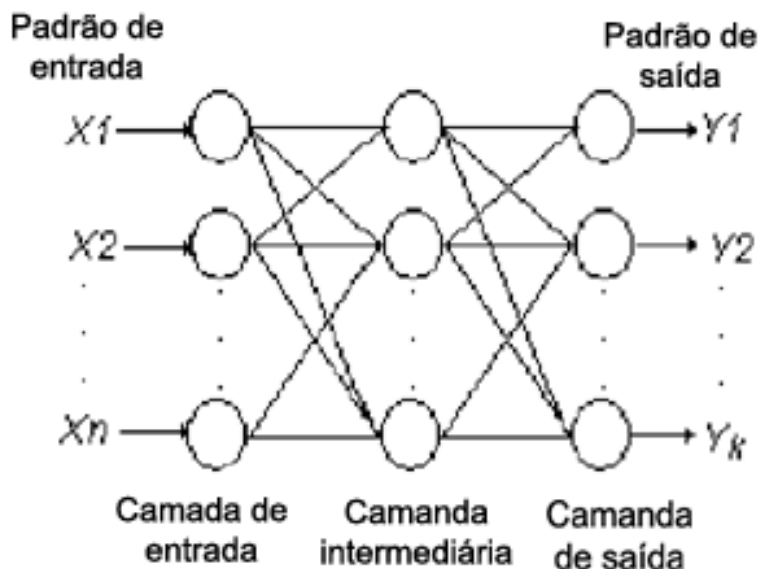


Figura 2. Esquema ilustrativo de uma rede MLP

As etapas de treinamento do algoritmo *backpropagation* são:

- Inicialização dos pesos com valores dentro de determinado intervalo;
- Apresentação dos vetores de entrada com as respectivas saídas desejadas
- cálculo da saída feito através da equação (12).

$$Y_{p,j} = \sum_{i=0}^{n-1} W_{ij} \theta_{pi} \quad (12)$$

Onde " W_{ij} " é o peso que parte da unidade "i" para a unidade "j", " θ_{pi} " é a saída produzida pela rede para o padrão "p" na conexão do i-ésimo neurônio, sendo que na camada inicial, " θ_{pi} " é igual ao padrão de entrada.

- A adaptação dos pesos de ligação, começando pela camada de saída, conforme equação (13).

$$W_{ij}(k+1) = W_{ij}(k) + \eta \delta_{pj} \theta_{pi} \quad (13)$$

Onde " W_{ij} " é o peso que parte da unidade "i" para unidade "j" no passo "k", "h" é a taxa de aprendizado e "dpj" é o erro para o padrão "p" na unidade "j". Para camada de saída a solução é simples, visto que o erro é bem definido. Para as camadas intermediárias, o erro é definido como função do erro da camada de saída.

A função de ativação utilizada na rede neural MLP foi a função tangente hiperbólica, dada pela equação (14).

$$f(net) = \frac{1 - e^{-knet}}{1 + e^{-knet}} \quad (14)$$

4. IMPLEMENTAÇÃO

Na FIG. 3 está ilustrado o sistema em estudo. A sua implementação foi feita através de simulação digital, utilizando-se o conjunto de equações 1 a 12, nas quais as variáveis foram discretizadas, com o objetivo de melhor armazenar o conjunto de vetores a ser utilizado no treinamento da rede neural.

As entradas da rede neural artificial foram as correntes do eixo direto e do eixo em quadratura do estator, sendo todas elas normalizadas de modo a trabalhar em valores por unidade, possibilitando a implementação do sistema em outros motores com faixas de potência diferentes da qual a rede neural foi treinada, e também para que o treinamento da rede neural obtivesse êxito, devido à função de ativação da rede neural limitar a saída entre o intervalo [-1,1].

A configuração da rede neural utilizada foi:

- três camadas;
- dois neurônios na camada de entrada, 3 neurônios na camada intermediária e um neurônio na camada de saída;
- Taxa de aprendizado igual a 0,4;
- A função de ativação utilizada foi tangente hiperbólica com k igual a 2.

Estes valores foram escolhidos após várias tentativas de se escolher uma configuração de rede neural que poderia convergir. Este estudo foi feito variando-se o valor da taxa de aprendizado, o valor de k da função de ativação e a configuração da rede neural até que se alcançou estes valores, os quais foram satisfatórios.

Os parâmetros do motor de indução utilizados para simulação são descritos na tabela 1.

Foi utilizado o software Matlab, marca registrada da The MathWorks Inc., para realizar as simulações.

Análise dos Resultados

Os resultados foram obtidos com o treinamento de um total de 402 (quatrocentos e dois) padrões de entrada. Estes padrões foram retirados de simulações do motor de indução com operação a vazio, com plena carga e no transitório de partida.

A curva de velocidade dada pelo estimador matemático é mostrada na FIG. 4 e a curva de velocidade dada pela rede neural é mostrada pela FIG. 5, na qual pode-se notar alguma diferença mesmo antes de se fazer a comparação dos resultados obtidos pelos dois estimadores, como mostrada na FIG. 6. Esta diferença ocorreu devido ao treinamento da rede neural não ter sido completo, isto ocorre geralmente quando temos padrões de entrada bem próximos uns dos outros, do ponto de vista de distância euclidiana, e com padrões de saída com uma distância euclidiana elevada, ou vice-versa. Porém esta diferença ocorre no estado de transitório de partida do motor de indução, o qual é um estado que não afeta o funcionamento do sistema.

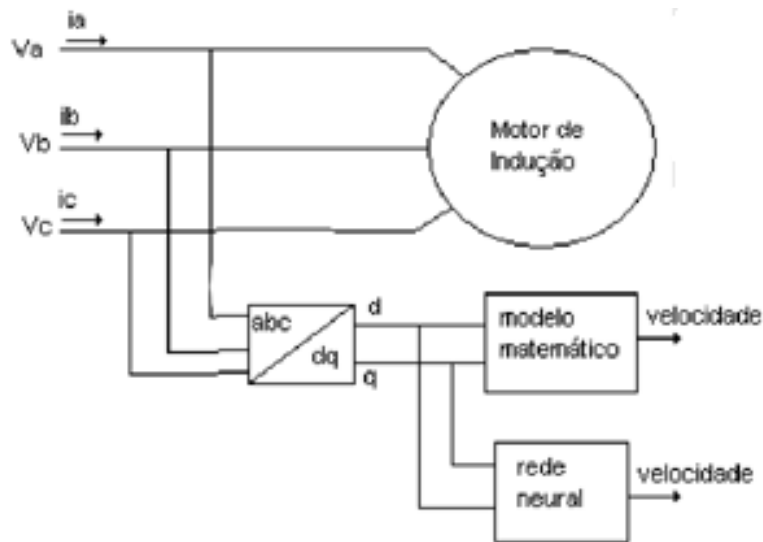


Figura 3. Disposição do sistema simulado

PARÂMETROS	SÍMBOLO	VALOR
Resistência do Estator	R_s	0.435Ω
Resistência do Rotor	R_r	0.816Ω
Indutância do Estator	L_s	0.002Ω
Indutância do Rotor	L_r	0.002 H
Indutância de Magnetização	M	0.0693 H
Momento de Inércia	J	0.089 Kg.m^2
Potência Nominal		3 Hp
Número de pólos	P	2
Conjugado Nominal		12 N.m

Tabela 1. Parâmetros do motor de indução

5. CONCLUSÕES

A metodologia proposta mostrou-se satisfatória do ponto de vista de comparação com os resultados obtidos pelo estimador matemático. A estimação da velocidade, utilizando redes neurais artificiais vem a substituir o modelo não linear de equações diferenciais em plantas de controle de velocidade em malha fechada, fazendo com que o modelo seja extremamente simplificado. A partir dos resultados que foram obtidos na estimativa da velocidade, utilizando as mesmas entradas na rede neural, conclui-se que pode ser feita a mesma estimação para o fluxo, na qual viria a ser um substituto para as equações de controle vetorial em malha fechada, simplificando em extremo o controle vetorial de um motor de indução.




Figura 4. Velocidade obtida pelo estimador matemático




Figura 5. Velocidade obtida pelo estimador neural




Figura 6. Comparação entre os resultados obtidos pelos estimadores matemático e neural

Referências Bibliográficas

BRAGA, A.,P., CARVALHO,A.,P.,L.,F. E LUDER-MIR,T.,B.. *Redes Neurais Artificiais* : Teoria e Aplicações. Rio de Janeiro : LTC - Livros Técnicos e Científicos, 2000, 262p. I. FREEMAN,J.,A., SKAPURA,D.,M., *Neural Networks: Algorithms, and Programming Techniques*, Addison-Wesley Publishing Company, julho/1992, 402p.

KOVÁCS,Z.,L.. *Redes Neurais Artificiais: Fundamentos e Aplicações*.2.ed.São Paulo: Editora Collegium Cognitio, 1996, 175p.

KRAUSE,P.,C., WASYNCZUK,O., SUDHOFF,S.,D.. *Analysis of Electric Machinery*. New York: IEEE Pres, 1995, 564p.

WERBOS, P.,J.. Backpropagation Through Time: What It Does and How to Do It. In: LAU,C.. *Neural Networks: Theoretical Foundations and Analysis*. New York: IEEE Press, 1991, pp.74-90.

WIDROW, B. and LEHR, M., A.. 30 Years of Adaptive Neural Networks: Perceptron, Madaline and Backpropagation. In: LAU,C.. *Neural Networks: Theoretical Foundations and Analysis*. New York: IEEE Press, 1991, pp.74-90.

* Professor do Departamento de Ciência da Computação da Universidade Estadual de Montes Claros. E-mail: marcos_dangelo@unimontes.br

** Bacharel em Sistema de Informação pela Unimontes.