

# 1º Congresso Brasileiro de Redes Neurais

Escola Federal de Engenharia de Itajubá  
Itajubá, 24 a 27 de outubro de 1994

## REDES NEURAIS APLICADAS AO ACIONAMENTO DE MOTOR DE INDUÇÃO

Walmir Matos Caminhas, DEE/UFMG      Márcio Luiz Andrade Netto, FEE/UNICAMP  
Pyramo Pires da Costa Jr., DEE/UFMG      Hermano M.F. Tavares, FEE/UNICAMP  
FEE/UNICAMP

E-MAIL: DEPTO@DENSIS.FEE.UNICAMP.BR  
DENSIS - FEE/UNICAMP - Caixa Postal 6101  
13.081-970 - Campinas - SP

### RESUMO

Neste trabalho é estudada a aplicação de redes neurais no acionamento do motor de indução trifásico de rotor em gaiola. A rede neural é utilizada para identificar e compensar as variações da resistência e indutância do rotor da máquina. Tal compensação se faz necessária quando se utiliza a técnica de orientação indireta de campo para o controle de velocidade, que é o caso deste trabalho. Com relação ao treinamento da rede é usado o método de programação não linear de Broyden-Fletcher-Goldfarb-Shanno (BFGS), conjuntamente com o algoritmo de Back-Propagation. Também é proposta uma função, para ativação dos neurônios, quociente de polinômios ordem, que aproxima-se da tangente hiperbólica (com a vantagem de ser calculada em um tempo de processamento cerca de 5 vezes menor). A partir de simulações digitais é feita uma análise do desempenho do acionamento frente às variações dos parâmetros do rotor.

### 1 - INTRODUÇÃO

Quando se aplicam as técnicas de controle vetorial o motor de indução, a velocidade variável, apresenta melhor desempenho que um motor corrente contínua de mesma potência (Bose, 1986). Um dos métodos de controle vetorial mais popular é o de orientação indireta de campo. Em tal

método a determinação da posição do vetor fluxo rotórico é feita pela integração da soma de duas grandezas: a velocidade elétrica do rotor e a velocidade de escorregamento. Esta última requer em seu cálculo o valor exato da constante de tempo elétrica do circuito de rotor. Portanto, este método é sensível às variações dos parâmetros que compõem esta constante de tempo, e tais variações devem ser compensadas de modo a se preservar a qualidade do desempenho do acionamento. Este trabalho apresenta uma técnica de identificação e compensação destas variações, baseada em redes neurais (Zuben, 1993). Através de simulações digitais é feita uma análise do desempenho do sistema de acionamento (composto pelo inversor PWM de corrente, motor de indução e carga mecânica) frente às variações da constante de tempo elétrica do rotor.

### 2 - DESCRIÇÃO DO SISTEMA

O diagrama de blocos da figura 1 ilustra o método indireto de orientação de campo, aplicado ao acionamento de um motor de indução alimentado por um inversor de corrente (Bose, 1986).

O cálculo do valor da velocidade de escorregamento de referência,  $\omega_s^*$ , é função das referências da constante de tempo elétrica do rotor,  $T_r$ , e das correntes  $I_{ds}^{*(e)}$  e  $I_{qs}^{*(e)}$ . A operação é feita pelo bloco denominado "calcula  $\omega_s^*$ " e é

baseada no modelo do motor de indução com campo orientado (Bose, 1986). É a velocidade de escorregamento de referência que irá promover a orientação de campo na máquina. A posição angular do vetor fluxo rotórico,  $\rho$ , é usada para obter as correntes de referência do estator. Estas correntes de referência uma vez comparadas com as correntes reais (medidas) fornecem os sinais de comando do inversor de corrente transistorizado (controle por valores extremos ou histerese de corrente).

Como visto no diagrama da figura, no método de controle vetorial por orientação indireta de campo, a posição do vetor fluxo rotórico é determinada a partir do valor da velocidade de escorregamento. Esta velocidade requer no seu cálculo o valor da constante de tempo de circuito de rotor,  $T_r$ . Como os parâmetros que compõem esta constante de tempo variam, o método indireto de orientação de campo é sensível à estas variações. A resistência de rotor varia com a temperatura e frequência e a indutância varia com a saturação magnética. Com um valor incorreto da velocidade de escorregamento, resultado de um valor de  $T_r$  incorreto no calculador de escorregamento, o desacoplamento entre conjugado e fluxo não é conseguido (Bose, 1986).

Para garantir o desacoplamento entre o fluxo e o conjugado eletromagnético, torna-se necessária a implementação de um método de compensar as variações da constante de tempo rotórica. Vários métodos que se denominam "métodos de identificação da constante de tempo de rotor" têm sido propostos ultimamente (Caminhas e outros, 1990). A maioria deles é baseada na comparação entre grandezas que contém informação da amplitude do fluxo rotórico, tais como potência reativa, força eletromotriz e outras, estimadas através das variáveis de controle e as estimadas através das grandezas reais medidas no motor (correntes e tensões). Desta comparação resulta um sinal de erro que promove a devida correção na constante de tempo de referência do circuito de rotor. Zuben (1993) propôs um método alternativo que é a utilização de redes neurais para este fim. Esta idéia é a explorada neste trabalho.

A partir das correntes  $i_{qs}^{(e)}$ ,  $i_{ds}^{(e)}$  e  $\omega_r$ , que são as entradas, a rede neural fornece na saída o valor da constante de tempo rotórica,  $T_r$ , que será utilizado pelo bloco "calcula  $\omega_s^*$ ", da figura 1. As correntes  $i_{qs}^{(e)}$  e  $i_{ds}^{(e)}$  são obtidas a partir de  $I_{as}$ ,  $I_{bs}$  e  $I_{cs}$  após a transformação de ABC para  $dq0^\circ$ .




Fig. 1 - Diagrama de blocos do método indireto orientação de campo

3 - O TREINAMENTO DA REDE

A topologia da rede usada, em camadas, é mostrada na figura 2. Para simplificar o desenho, não foram mostradas todas as conexões entre os neurônios de saída e os de entrada. O treinamento consiste em ajustar os pesos sinápticos de modo a obter o menor erro quadrático. O erro é usado para atualizar estes pesos.




Fig. 2 - Topologia da rede neural utilizada

Seja  $d_k$  o valor desejado, o erro quadrático é dado por:

$$E = \frac{1}{2} \left( \sum_{k=1}^l (d_k - y_{3k})^2 \right) \tag{1}$$

onde

$$y_{3k} = f(w_{2jk}, w_{1ij}, w_{3ki})$$

A rede utilizada neste trabalho possui 3 entradas ( $n=3$ ), 15 neurônios na camada escondida ( $m=15$ ) e 1 saída ( $l=1$ ).

O treinamento consiste em:

$$\begin{aligned} \text{Min. } E &= E(\tilde{x}) \\ \text{s. a.} \\ \text{(P)} \quad \tilde{x} &\in \mathcal{R}^p \\ p &= n.m + m.l + l.n \end{aligned} \tag{2}$$

onde

$$\tilde{x} = \begin{pmatrix} \tilde{x}_{W_2} \\ \tilde{x}_{W_1} \\ \tilde{x}_{W_3} \end{pmatrix}$$

e

$$\tilde{x}_{W_2} = \begin{pmatrix} w_{2,11} \\ \vdots \\ w_{2,kl} \\ \vdots \\ w_{2,ml} \end{pmatrix}; \quad \tilde{x}_{W_1} = \begin{pmatrix} w_{1,1j} \\ \vdots \\ w_{1,lm} \end{pmatrix}; \quad \tilde{x}_{W_3} = \begin{pmatrix} w_{3,11} \\ \vdots \\ w_{3,ln} \end{pmatrix}$$

Como a função erro  $E(\tilde{x})$  é não linear, (P) é um Problema de Programação Não Linear Irrestrito.

3.1 - A Programação Não Linear

A programação não linear caracteriza-se por não possuir um método geral de resolução dos seus problemas. São muitos algoritmos e quase sempre voltados para problemas específicos, presos à características diversas tais como continuidade, diferenciabilidade de primeira e/ou de segunda ordem, e outras. Uma outra particularidade é a inexistência de critérios absolutos para comparação entre os algoritmos existentes (Mateus, 1986).

Neste trabalho é utilizado o método de **Broyden-Fletcher-Goldfarb-Shanno (BFGS)** para resolver o problema (P), (Mahey, 1986). Este método é intermediário entre a simplicidade do método de Gradiente e a rapidez do método de Newton. Substitui o cálculo da hessiana no método de Newton, por um processo iterativo finito, utilizando apenas derivadas de primeira ordem.

No método BFGS a direção de busca  $\tilde{h}^k$  é calculada por:

$$\tilde{h}^k = -(\tilde{D}^k)^{-1} \cdot \tilde{\nabla} E(\tilde{x}^k) \tag{3}$$

onde

$$\tilde{D}^{k+1} = \tilde{D}^k + \frac{\Delta \tilde{g} \cdot \Delta \tilde{g}^T}{\Delta \tilde{x}^T \cdot \Delta \tilde{x}} - \frac{\tilde{D}^k \cdot \Delta \tilde{x} \cdot \Delta \tilde{x}^T \cdot \tilde{D}^k}{\Delta \tilde{x}^T \cdot \tilde{D}^k \cdot \Delta \tilde{x}}$$

sendo

$$\Delta \tilde{x} = \tilde{x}^{k+1} - \tilde{x}^k$$

$$\Delta \tilde{g} = \tilde{\nabla} E(\tilde{x}^{k+1}) - \tilde{\nabla} E(\tilde{x}^k)$$

A matriz  $\tilde{D}^0$  (condição inicial) pode ser qualquer matriz definida positiva, normalmente toma-se como igual a matriz identidade.

A convergência exige  $\tilde{D}^k$  definida positiva, para assegurar o decrescimento da função erro, ou seja, que  $E(\tilde{x}^{k+1}) < E(\tilde{x}^k)$ . Para garantir isto, entre várias alternativas, escolhemos uma proposta por Powell, que consiste em substituir  $\Delta \tilde{g}$  por  $\Delta \tilde{g}'$  (Saldanha, 1992).

$$\Delta \tilde{g}' = \theta \cdot \Delta \tilde{g} + (1 - \theta) \cdot \tilde{D}^k \Delta \tilde{x} \quad (4)$$

onde

$$\theta = \begin{cases} 1 & \text{se } \Delta \tilde{x}^T \cdot \Delta \tilde{g} \geq 0, 2 \cdot \Delta \tilde{x}^T \cdot \tilde{D}^k \cdot \Delta \tilde{x} \\ \frac{0,8 \cdot \Delta \tilde{x}^T \cdot \tilde{D}^k \cdot \Delta \tilde{x}}{\Delta \tilde{x}^T \cdot \tilde{D}^k \cdot \Delta \tilde{x} - \Delta \tilde{x}^T \cdot \Delta \tilde{g}} & \text{c.c.} \end{cases}$$

Deve-se notar que, para  $\theta \neq 1$ , temos  $\Delta \tilde{g} \neq \Delta \tilde{g}'$ .

Calculada a matriz  $\tilde{D}^k$ , seguramente definida positiva e simétrica, pode-se obter a direção  $\tilde{h}^k$  por (5). Para tanto pode-se usar método de fatoração de Choleski, com número de operações (da ordem  $O(n^2)$ ) que é mais eficiente que a inversão  $\tilde{D}^k$  (Mahey, 1987).

$$\tilde{D}^k \cdot \tilde{h}^k = -\tilde{\nabla} E(\tilde{x}^k) \quad (5)$$

### 3.2 - O Algoritmo de treinamento

Para atualizar os pesos sinápticos da rede, foi utilizado o algoritmo de "Back-Propagation" conjuntamente com o método BFGS. O gradiente do erro quadrático com relação aos pesos é dado por:

$$\tilde{\nabla} E = \begin{pmatrix} \tilde{\nabla} E_{\tilde{w}_2} \\ \tilde{\nabla} E_{\tilde{w}_1} \\ \tilde{\nabla} E_{\tilde{w}_3} \end{pmatrix} \quad (6)$$

sendo que o cálculo das componentes dos vetores é feito de acordo com algoritmo de "Back-Propagation" (Widrow & Lehr, 1990; Kosko, 1991)

### 3.3 - A função de Ativação

Para a implementação prática da técnica aqui estudada, um fator bastante importante é o tempo de processamento da rede neural. Grande parte deste tempo é gasto no cálculo da função de ativação dos neurônios, que normalmente é utilizada a tangente hiperbólica ( $\tanh(\gamma x)$ ). Com objetivo de tentar reduzir este tempo, a tangente hiperbólica foi aproximada pela função:

$$f(x) = \begin{cases} \frac{a-b}{a+b} & \text{se } |x| \geq \beta \\ 1 & \text{se } x > \beta \\ -1 & \text{se } x < -\beta \end{cases} \quad (7)$$

onde

$$\begin{cases} a = (x + \beta)^2 \\ b = (x - \beta)^2 \end{cases}$$

Mostra-se sem dificuldade que esta função é de classe  $C^1$ .

A equação (7) mostra que para calcular o valor de  $f(x)$  são necessárias três operações de multiplicação/divisão e quatro de soma/subtração, quando o valor absoluto do argumento é menor que  $\beta$  e somente uma multiplicação se for maior. Neste termos tem-se uma função cujo tempo de processamento é da ordem de cinco vezes menor que o tempo de cálculo da tangente hiperbólica, função bastante utilizada em redes neurais, e com resultados praticamente iguais, para os casos analisados. Um estudo comparativo entre as duas funções é mostrado nas figuras 3 e 4. Na figura 3 são mostradas as curvas da tangente hiperbólica (com  $\gamma=2.2$ ) e de  $f(x)$  (com  $\beta=2$ ). Já na figura 4 é mostrada a comparação entre os tempos de processamento das duas funções, no cálculo de N pontos funcionais.




Fig. 3 - Tangente Hiperbólica e  $f(x)$ .




Fig. 4 - Gráfico do tempo de processamento da Tangente hiperbólica e  $f(x)$

#### 4 - RESULTADOS DE SIMULAÇÕES

Para simulação foram usados dados de um motor de 2 C.V., cujos parâmetros são mostrados a seguir. O programa de simulação resolve as equações diferenciais pelo método de Runge Kutta de quarta ordem. O período de integração usado foi de 20  $\mu$ s e o de amostragem, para malha de controle de velocidade foi de 2 ms. Já o período de amostragem para o cálculo de  $T_r$  foi de 40 ms.

Dados da Máquina de Indução utilizada nas simulações:

- Potência = 2 HP
- Resistência do estator = 1,5  $\Omega$
- Resistência do rotor = 1,6  $\Omega$
- Indutância própria do estator = 0,108 H
- Indutância própria do rotor = 0,115 H
- Indutância mútua estator/rotor = 0,098 H
- Momento de inércia = 0,016  $\text{kg.m}^2$
- Número de pólos = 4

Uma vez treinada, a rede foi usada para identificação da constante de tempo elétrica do rotor. A figura 5 mostra as curvas das constante de tempo real e a estimada pela rede em função do tempo. Como mostrado a rede consegue identificar  $T_r$  com um erro muito pequeno, isto faz com que o sistema não perca o desacoplamento entre o fluxo rotórico e o conjugado eletromagnético, fato que fica evidenciado (figura 6) pela curva do fluxo rotórico de eixo "q", para o sistema com compensação, (FqrCc), permanecendo praticamente em zero. Nesta figura apresentamos também este mesmo fluxo, sem compensação, FqrSc, deixando claro o acoplamento entre fluxo e conjugado. A amplitude do fluxo rotórico assume um valor que é praticamente o nominal quando é feita a compensação, figura 7. Isto mostra o bom desempenho da estratégia de identificação adotada.




Fig. 5 - Gráfico da constante de tempo elétrica do rotor identificada ( em p.u.) em função do Tempo (ms).




Fig. 6 - Fluxo rotórico de eixo "q" (em mWb) em função do Tempo (ms)




Fig. 7 - Amplitude do fluxo rotórico (em mWb) em função do Tempo (ms)

## 5 - CONCLUSÃO

Neste trabalho foi visto que um erro no valor adotado para a constante de tempo elétrica do rotor de referência influencia tanto no comportamento dinâmico quanto no regime permanente da máquina. Com o objetivo de solucionar o problema foi analisado um método de identificação e compensação de Tr, baseado em **Redes Neurais**. Foram utilizados o algoritmo de "Back-Propagation" conjuntamente com o método BFGS para o treinamento da rede. Foi proposta uma função tipo polinomial para ativação dos neurônios da rede. Os resultados obtidos mostram o bom desempenho da estratégia aqui apresentada na identificação e compensação de Tr.

## 8 - REFERÊNCIAS BIBLIOGRÁFICAS

- Bose, B.K. (1986). "Power Electronics A.C. Drives", Prentice Hall.
- Caminhas, W.M.; Menezes, B.R.; Tribuzi, A.R.; Silva, S.R. (1990). "Influência, Identificação e Compensação das Variações dos Parâmetros do Motor de Indução no Controle Vetorial Indireto". In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 8, 1990, Belém-Pará. Anais Belém: Editora Sociedade Brasileira de Automática, p. 936-941.
- Kosko, B. (1992). "Neural Networks and Fuzzy Systems." Prentice Hall
- Mahey, P. (1987). "Programação Não-Linear: Introdução à Teoria e aos Métodos". Editora Campus Ltda.

Mateus, G.R.; Luna, H.P.L. (1986). "Programação Não Linear." V Escola de Computação- Belo Horizonte, MG-Brasil.

Nordin, K.B.; Novotny, D.W.; Zinger, D.S. (1985). "The Influence of Motor Parameter Deviations in Feedforward Field Orientation Drives Systems". IEEE Trans. on Industry Applications, Vol.1A - 21, No 4, pp 1009 - 1015.

Okuyama, T.; Nagase, H.; Kubota, Y.; Horiuchi, H.; Miyazaki, K.; Ibori, S. (1983). "High Performance A.C. Motor Speed Control System Using GTO Converters". Anais do IPEC pp 720-731, Tokyo - Japão.

Saldanha, R.R. (1992). "Optimisation en Electromagnétisme par Application Conjointe des Méthodes de Programmation Non Linéaire et de la Méthode des Eléments Finis.". Tese de Doutorado - De L'Institut National Polytechnique de Grenoble, França.

Zuben, F.J.V. (1993). "Redes Neurais Aplicadas ao Controle de Máquinas de Indução.". Dissertação de Mestrado, Curso de Pós-Graduação em Engenharia Elétrica da UNICAMP/SP.

Widrow, B.; Lehr, M.A. (1990). "30 Year of Adaptive Neural Networks: Perceptron, Medaline, and Backpropagation.". Proceedings of the IEEE. Vol. 78, No. 9, pp 1415-1442.