

ESTRATÉGIA DE ESTIMAÇÃO DE FLUXO ESTATÓRICO PARA MOTORES DE INDUÇÃO UTILIZANDO REDES NEURAIIS

VICTOR P. B. AGUIAR, RICARDO S. T. PONTES, RODRIGO C. CIARLINI

Laboratório de Eficiência Energética em Sistemas Motrizes-LAMOTRIZ, Departamento de Engenharia Elétrica, Universidade Federal do Ceará

Caixa Postal 6001, 60455-760, Fortaleza, CE, BRASIL

E-mails: victor@dee.ufc.br, ricthe@dee.ufc.br, rodrigociarlini@dee.ufc.br

ARTHUR P. S. BRAGA, JOSÉ C. T. CAMPOS

Grupo de Processamento em Automação e Robótica-GPAR, Departamento de Engenharia Elétrica, Universidade Federal do Ceará

Caixa Postal 6001, 60455-760 Fortaleza, CE, BRASIL

E-mails: arthurp@dee.ufc.br, teles@ufc.br

Abstract— Due to the importance of the stator flux to torque vector control and speed control, the paper aims estimating using it an artificial neural network with simple training and reduced number of inputs for the same outputs. Simulations done with considered estimator present promising results. The performance is demonstrated for a set of constant supply frequencies values presented in this paper.

Keywords— Estimating, Neural Network, Stator Flux, Induction Motor, Vector Control.

Resumo— Devido à importância do fluxo magnético do estator para o controle vetorial de velocidade e conjugado, o trabalho pretende estimá-lo a partir de uma rede neural artificial, usando treinamento simples e com número reduzido de entradas para as mesmas saídas. Simulações realizadas com o estimador proposto apresentam bons resultados cujo desempenho é demonstrado para um conjunto de valores de frequência de alimentação constante apresentados neste trabalho.

Palavras-chave— Estimção, Rede Neural, Fluxo do Estator, Motor de Indução, Controle Vetorial.

1 Introdução

Motores de indução trifásicos são máquinas elétricas usadas em abundância na indústria, principal setor econômico de países desenvolvidos e em desenvolvimento (SANTOS, 2003, BEN, 2006). Esses motores são estudados em vários aspectos, dentre estes, seus princípios físicos, sua facilidade de projeto e construção, balanço energético da máquina e aspectos de operação (FITZGERALD, 1952, DEL TORO, 1994).

Na linha de aspectos de operação, dois são mais relevantes: variação de velocidade e controle de conjugado da máquina (LIPO, 1996, SIMÕES, 1995). A partir do controle desses dois aspectos, é possível o uso do motor de indução para as mais variadas características de cargas, especificamente, cargas especiais, que podem trabalhar em baixas velocidades e mantendo valores nominais de conjugado.

Dentro dos aspectos de controle, um dos mais importantes é a correta estimção do fluxo magnético do estator, que corresponde a uma aproximação correta do valor de conjugado eletromagnético desenvolvido pela máquina (LIPO, 1996, SIMÕES, 1995).

Considerando os aspectos apresentados é possível obter uma estratégia de estimção de fluxo que satisfaça requisitos de controle para aplicações específicas e para isso o processo de estimção deve ser analisado. Dentre os estimadores conhecidos, adotaremos a estimção por Rede Neural Artificial, mediante a possibilidade de trabalhar com um processo de arquitetura facilmente implementável e sem processamento numérico.

Redes Neurais Artificiais, RNA, são consideradas aproximadores universais de funções, conforme Haykin (1999), tornando essa técnica interessante para o projeto de um estimador de fluxo estatórico ao realizar a aproximação de curvas temporais que reprodusam, a partir do treinamento da RNA, a dinâmica do fluxo estatórico.

2 Técnica de Estimção de Fluxo do Estator

Na busca por um controle do conjugado eletromagnético sem a necessidade de sensores para conhecer o sinal temporal de fluxo do rotor, faz-se necessário estimar o fluxo do estator a partir das correntes e tensões terminais. A Figura 1 mostra o sistema de controle de um motor de indução trifásico, utilizando a técnica de estimção de fluxo estatórico.

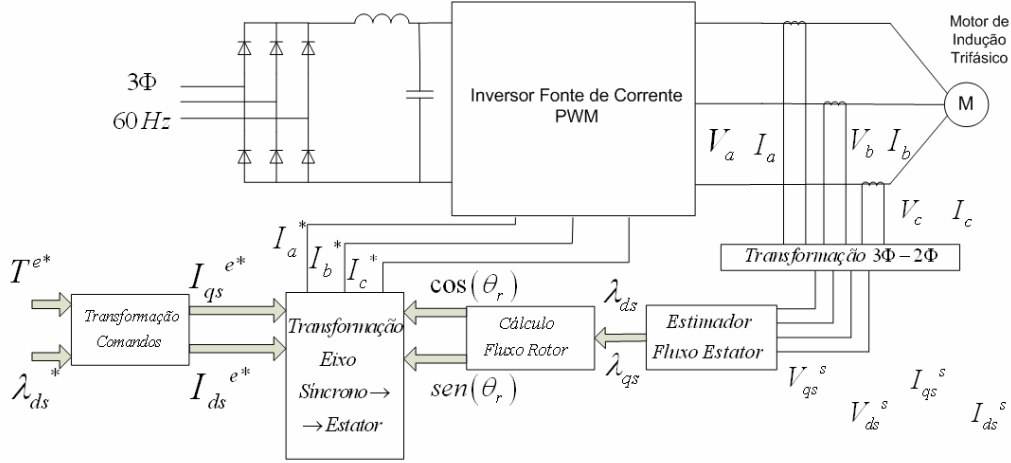


Figura 1. Diagrama de blocos do controle vetorial do motor de indução com estimação do fluxo estatórico.

Baseado no modelo do motor de indução trifásico, simétrico e equilibrado apresentado por Krause (1986), a teoria dos eixos de referência (KRAUSE, 1986) e Bose (2002), as equações (1) e (2) são suficientes para a estimação dos fluxos do estator; e com as equações (3) a (6) é possível estimar o fluxo do rotor e, conseqüentemente, a posição do rotor.

$$\lambda_{ds}^s = \int (v_{ds}^s - r_s \cdot i_{ds}^s) dt \quad (1)$$

$$\lambda_{qs}^s = \int (v_{qs}^s - r_s \cdot i_{qs}^s) dt \quad (2)$$

$$\lambda_{qm}^s = \lambda_{qs}^s - L_{ls} \cdot i_{qs}^s \quad (3)$$

$$\lambda_{dm}^s = \lambda_{ds}^s - L_{ls} \cdot i_{ds}^s \quad (4)$$

$$\lambda_{qr}^s = \frac{L_r}{L_m} \cdot \lambda_{qm}^s - L_{lr} \cdot i_{qs}^s \quad (5)$$

$$\lambda_{dr}^s = \frac{L_r}{L_m} \cdot \lambda_{dm}^s - L_{lr} \cdot i_{ds}^s \quad (6)$$

O índice superior 's' indica grandezas no eixo de referência estacionário, sendo:

v_{ds}^s (v_{qs}^s) Tensões do estator no eixo d (eixo q)

i_{ds}^s (i_{qs}^s) Correntes do estator no eixo d (eixo q)

λ_{ds}^s (λ_{qs}^s) Fluxo concatenado do estator no eixo d (eixo q)

λ_{dr}^s (λ_{qr}^s) Fluxo concatenado do rotor no eixo d (eixo q)

r_s (r_r) Resistência do estator (rotor)
 L_{ls} (L_{lr}) Indutância de dispersão do estator (rotor)
 λ_{dm}^s (λ_{qm}^s) Fluxo concatenado no entreferro no eixo d (eixo q)
 L_m Indutância de Magnetização
 L_r Indutância Própria do Rotor

Partindo dessa formulação, a equação (7) descreve o conjugado eletromagnético (Ce) em função dos sinais de fluxo concatenado do estator, das correntes do estator e do número de pólos (P).

$$Ce = \frac{3P}{4} \cdot (\lambda_{ds}^s \cdot i_{qs}^s - \lambda_{qs}^s \cdot i_{ds}^s) \quad (7)$$

Com base no equacionamento apresentado, verifica-se que o fluxo estatórico, uma medida de difícil aferição, mantém dependência com a tensão e a corrente do estator (medidas de fácil aferição). Assim é proposta uma nova forma de estimar o fluxo estatórico utilizando redes neurais. A próxima seção descreve a RNA utilizada, e os resultados obtidos são apresentados na seção 5.

3 Redes Neurais Artificiais

O conceito de RNA utilizado para a estimação, foi a das redes MLP (Multi-Layer Perceptron), que tem sua formulação matemática e de treinamento descritos a seguir.

3.1 Rede MLP

Cada neurônio é formulado com base nas equações (8) e (9)

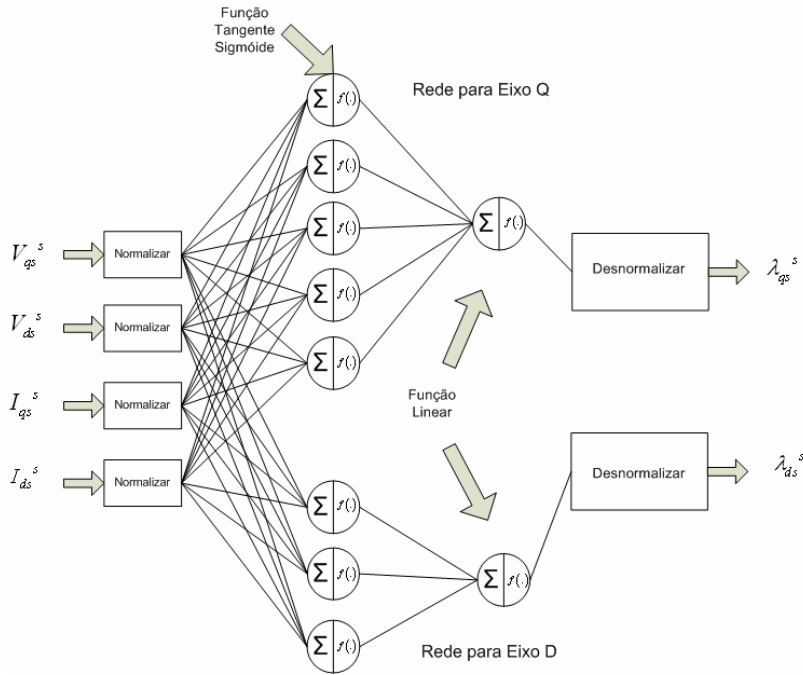


Figura 2. Arquitetura das redes utilizadas.

$$net_i(w_i, x) = \sum_{j=1}^n w_{ij} \cdot x_j + \theta_i \quad (8)$$

$$y_i = f(net_i) \quad (9)$$

Sendo, $net_i(w_i, x)$ a função de base linear, w_{ij} são os pesos do neurônio i , relacionado à entrada j , x é um vetor com j entradas, θ_i é o 'bias' relacionado ao neurônio i e y_i é a resposta do neurônio i , onde $f(\cdot)$ é a função de ativação.

São usadas como funções de ativação, para os neurônios das camadas escondidas a função tangente hiperbólica, e para os neurônios da camada de saída, função linear.

3.2 Treinamento e Aprendizagem da MLP

Foi utilizado para treinamento da rede o método "backpropagation", gradiente descendente, com taxa de momento (m) e heurística de taxa de aprendizagem variável.

O erro calculado a cada iteração é o erro médio quadrático, descrito na equação (10), e considerado o erro de aproximação entre a função estimada e a simulada.

$$E = \sum_{p=1}^P E_p = \frac{1}{2} \cdot \sum_{p=1}^P \sum_{j=1}^S (d_j^p - y_j^p)^2 \quad (10)$$

Sendo d_j^p uma das S saídas desejadas, y_j^p é uma das S saídas da rede, p é o número de padrões utili-

zados no treinamento, E_p é o erro quadrático médio para cada padrão e E é o erro quadrático médio geral, somatório de todos os erros de cada padrão de treinamento.

A taxa de aprendizagem variável (η) é apresentada como uma variação da taxa de aprendizagem, caso o erro exceda o erro máximo apresentado como parâmetro de treinamento. As equações (11) e (12) descrevem o processo de aprendizagem da rede.

$$\eta = \eta \cdot \eta_{inc} \quad \text{ou} \quad (11)$$

$$\eta = \eta \cdot \eta_{dec}$$

$$w_{ij}(t+1) - w_{ij}(t) = \Delta w_{ij}(t+1) = \eta \frac{\partial E_p}{\partial w_{ij}(t)} + m \cdot \Delta w_{ij}(t) \quad (12)$$

Para a técnica, $w_{ij}(t+1)$ são os novos pesos após aprendizado e $w_{ij}(t)$ são os pesos antigos.

4 Arquitetura da MLP

A estrutura da MLP é baseada em 4 entradas e 2 saídas. São usados v_{ds} , v_{qs} , i_{ds} e i_{qs} como entradas e λ_{ds} , λ_{qs} como saídas.

Foi observado que a rede com a configuração de uma única camada escondida com 8 neurônios aproximava satisfatoriamente a função que relacionava entrada e saída, diferente de Vas (1999), mas sem uso de tratamento aos dados de entrada (memória). Aspecto importante para futura implementação.

Tabela 1. Parâmetros dos motores de indução.

Parâmetro	2,2 kW	7,5 kW
Resist. Estator (ohm)	4,34	1,89
Resist. Rotor (ohm)	4,34	1,07
Indut. Magnetização (mH)	219,4	158,4
Indut. Disper. Estator (mH)	11,5	9,2
Indut. Disper. Rotor (mH)	11,5	9,5
Coefic. Atrito (N.m.s)	0,0008	0,0465
Momento Inércia (kg.m ²)	0,0013	0,0104

Outro ponto a ser ressaltado é a redução da rede para os cálculos de estimação do fluxo do estator, agregando aos cálculos posteriores (obtenção do fluxo do rotor) apenas na velocidade de processamento do microcontrolador, diferente de Simões (1995) e Shi (2001), que simularam todo o sistema de controle em forma de redes neurais.

Com esta arquitetura, foi identificado que a rede, para o fluxo estatístico do eixo q, era de aprendizagem lenta, sobrecarregando o treinamento da rede para valores de fluxo estatístico do eixo d.

Por isso, foi proposta a criação de duas redes com a mesma característica da original (uma única camada escondida), com as mesmas entradas para ambas as redes, e cada saída desejada (fluxo do estator no eixo q e no eixo d) como resposta de cada rede. A medida assegurou que cada eixo convergia para valores de fluxo com erros iguais.

Foi mantido o número de neurônios nas camadas escondidas das redes, tal que o somatório desses números seria o número de neurônios da camada escondida da rede original. A rede original que tinha a arquitetura 4-8-2 passou a ser a rede do eixo d: 4-3-1 e a rede do eixo q: 4-5-1. Chamamos de rede, a partir deste ponto, a nova topologia projetada. A Figura 2 representa a arquitetura adotada para a proposta de estratégia de estimação.

5 Desempenho e Utilização da Rede

A base de dados de treinamento foi obtida a partir da simulação no modelo da máquina de indução trifásica apresentado por Krause (1986).

Foram utilizados dois motores para análise dos resultados e das propostas de treinamento. Foi utilizado um motor de 2,2 kW (3 HP) e outro de 7,5 kW (10 HP). Os parâmetros dos motores para a simulação e obtenção de dados são apresentados na Tabela 1.

Os motores possuíam rotor gaiola de esquilo, 4 pólos, carcaça de alumínio. Os motores fazem parte das bancadas do LAMOTRIZ – Laboratório de Eficiência Energética em Sistemas Motrizes, parceria entre ELETROBRÁS e UFC.

Tabela 2. Influência no conjugado da estimação de fluxo do motor de 2,2 kW – Rede Geral.

TREINO			
		Estim.	Conjug.
TESTE	60 Hz	0,001	1,70%
	50 Hz	0,003	6,45%
	40 Hz	0,002	6,08%
	30 Hz	0,003	6,37%
	20 Hz	0,017	23,16%

Tabela 3. Influência no conjugado da estimação de fluxo do motor de 7,5 kW – Rede Geral.

TREINO			
		Estim.	Conjug.
TESTE	60 Hz	0,002	6,55%
	50 Hz	0,002	8,97%
	40 Hz	0,003	12,30%
	30 Hz	0,004	15,43%
	20 Hz	0,007	20,83%

Os motores foram simulados com o mesmo conjugado mecânico aplicado ao eixo: 12,6 N.m (plena carga para o motor de 3 HP e carga parcial para o de 10 HP). O tempo de simulação foi de 8 segundos.

5.1 Estratégia de treinamento

A proposta inicial é a partir da simulação do motor em uma frequência de alimentação para determinado espectro, verificar se a rede responde a outras frequências de alimentação. Essa proposta mostra que se o motor for treinado para uma determinada frequência de alimentação, ele responderá adequadamente para todo o espectro de frequências proposto.

Essa estratégia de treinamento e uso da rede foi realizada para todas as frequências propostas (60, 50, 40, 30 e 20 Hz), e para efeito de comparação foi realizado o treinamento geral dos dados obtidos em todas as frequências, obtendo uma rede geral.

A comparação foi feita entre essas 5 redes e testadas conforme a estratégia de treinamento. A rede geral foi testada em todas as frequências, separadamente.

Vale salientar que todos os treinamentos possuíam grupo de dados para treinamento e dados para teste. Foi convencionado que os dados simulados nos primeiros 4 segundos seriam dados de treinamento e os dados simulados nos últimos 4 segundos, seriam dados de teste.

Tabela 4. Influência no conjugado da estimação do fluxo no motor de 2,2 kW.

		TREINO									
		60 Hz		50 Hz		40 Hz		30 Hz		20 Hz	
		Estim.	Conjug.	Es- tim.	Conjug.	Estim.	Conjug.	Es- tim.	Conjug.	Es- tim.	Conjug.
TESTE	60 Hz	0,128	1,41%	0,001	2,75%	0,005	7,96%	0,024	15,98%	0,067	25,77%
	50 Hz	0,001	2,51%	0,048	1,55%	0,004	5,96%	0,013	11,51%	0,064	26,25%
	40 Hz	0,003	5,90%	0,005	7,82%	0,080	0,84%	0,005	8,26%	0,036	20,24%
	30 Hz	0,005	8,42%	0,006	9,19%	0,002	5,98%	0,060	1,32%	0,029	20,37%
	20 Hz	0,008	11,14%	0,012	16,53%	0,007	9,76%	0,007	6,71%	0,055	2,19%

Tabela 5. Influência no conjugado da estimação do fluxo no motor de 7,5 kW.

		TREINO									
		60 Hz		50 Hz		40 Hz		30 Hz		20 Hz	
		Estim.	Conjug.	Es- tim.	Conjug.	Estim.	Conjug.	Es- tim.	Conjug.	Es- tim.	Conjug.
TESTE	60 Hz	0,062	1,82%	0,002	4,01%	0,004	5,20%	0,009	10,82%	0,071	30,52%
	50 Hz	0,001	3,10%	0,125	2,11%	0,004	4,92%	0,006	9,05%	0,062	28,15%
	40 Hz	0,005	9,52%	0,003	6,25%	0,062	1,04%	0,002	6,11%	0,029	19,82%
	30 Hz	0,058	10,53%	0,004	7,56%	0,002	5,26%	0,069	1,90%	0,022	17,54%
	20 Hz	0,024	21,52%	0,015	16,60%	0,005	5,11%	0,009	13,62%	0,038	1,25%

5.2 Desempenho e comparação

Como norma, ficou estabelecida que fosse comparada a influência de cada estratégia de treinamento sobre o conjugado eletromagnético calculada para cada valor estimado, a partir da equação (7). Com essa ação seria verificada a eficácia da estimação do fluxo estatístico.

Também foi estabelecido que somente o erro percentual do conjugado em regime permanente seria analisado, visto que a estimação de conjugado para a respectiva faixa de frequências, utilizando a técnica “V/f” constante, teria respostas eficazes para regime permanente.

Na Tabela 2, é apresentado o resultado da rede geral para o motor de 2,2 kW, e na Tabela 3 é apresentado o resultado da rede geral para o motor de 7,5 kW.

A Tabela 4 e a Tabela 5 apresentam os dados relativos à rede treinada no espectro de frequência e os testes para ambos os motores com 2,2 kW e 7,5 kW de potência nominal, respectivamente.

Foi observado no motor de 2,2 kW (3 HP), que a rede treinada em 40 Hz não apresentou erro maior

que 10% no conjugado calculado a partir do fluxo estimado. Para todas as outras frequências de treinamento, houve erros maiores que 10% em determinada frequência de teste.

No motor de 7,5 kW (10 HP), a rede apresentou o mesmo comportamento da rede treinada para o motor anterior. Este não apresentou erros maiores que 5% no conjugado calculado, na frequência de 40 Hz. Nas outras frequências de treinamento, houve erros maiores que 10% em determinada frequência de teste.

No treino da rede com os valores simulados em todas as frequências, o resultado não foi satisfatório para os dois motores. Erros no conjugado calculado foram maiores que 10% nas frequências abaixo de 40 Hz, mas obteve-se erros em torno de 5% para as frequências acima de 40 Hz.

6 Conclusão

Podemos identificar com os testes realizados que o treinamento na frequência de 40 Hz apresenta boa aproximação na faixa de 60 a 20 Hz, com erros menores que 10% no valor de conjugado eletromagnético em regime permanente, validando esta como es-

tratégia de estimação e fluxo do estator por rede neural para um espectro de 20 Hz a 60 Hz. Ainda é possível verificar que a rede geral não aproxima com resultados tão satisfatórios quanto à rede treinada em 40 Hz.

É observado também que essa característica é acentuada com o aumento da potência do motor. No motor de 7,5 kW (10 HP), o erro no conjugado calculado com valores de fluxo estimado não supera os 5%. Já para as outras frequências, os resultados não são tão satisfatórios, apresentando a nova proposta de estimação de fluxo satisfatória para motores até 10 HP.

Também é observado que a análise de como se comporta cada saída da rede, perante o erro quadrático médio geral, pode levar a utilização de redes com as mesmas entradas, mas que trabalhem especificamente cada saída, a partir de uma arquitetura para cada rede. Com essa análise é possível garantir que este erro represente a aproximação entre valores estimados e simulados, além de uma melhoria no erro quadrático médio geral de cada resposta.

É necessário, como comparação entre métodos de estimação identificar o desempenho do método de estimação por RNA aqui proposto. Outro método que pode ser aplicado é o método de estimação por Filtro de Kalman.

Agradecimentos

Ao Departamento de Engenharia Elétrica da Universidade Federal do Ceará, e ao LAMOTRIZ.

Referências Bibliográficas

- BEN (2006). Balanço Energético Nacional – MINISTÉRIO DAS MINAS E ENERGIA.
- Santos, A. S., Soares, G. A., Perrone, F. P. D., Moreira, M. A. G. e Pontes, O. P. (2003). Programa Nacional de Eficiência na Indústria: Direcionando o Foco para Sistemas Motrizes, *Anais do XVII SNPTEE – Seminário Nacional de Produção e Transmissão de Energia Elétrica*, GCE, Uberlândia.
- Fitzgerald, A. E. e Kingsley, Jr. (1952). *Electric Machinery*, McGraw-Hill: New York.
- Del Toro, V. (1994). *Fundamentos de Máquinas Elétricas*, LTC: Rio de Janeiro.
- Lipo, T. A. e Novotny, D. W. (1996). *Vector Control and Dynamics of AC Drives*, Oxford: New York.
- Bose, B. K. (2002). *Modern Power Electronics and AC Drives*, Prentice-Hall: New York.
- Haykin, S. (1999). *Neural Networks 2º Ed*, Prentice-Hall: New Jersey.
- Krause, P. C. (1986). *Analysis of Electric Machinery*, Mac-Graw Hill: New York.
- Vas, P. (1999). *Artificial-Intelligence-Based Electrical Machines and Drives: Application of*

Fuzzy, Neural, Fuzzy-Neural, and Genetic-Algorithm-Based Techniques, Oxford: New York.

Simões, M. G., Bose, B. K. (1995). Neural Network Based Estimation of Feedback Signals for a Vector Controlled Induction Motor Drive, *IEEE Transactions on Industry Applications*, **31**(3): 620-629.

Shi, K. L., Wong, Y. K. e Ho, L. S. (2001). Direct-Self Control of Induction Motor Based on Neural Network, *IEEE Transactions on Industry Applications*, **37**(5): 1290-1298.