



Estimador de velocidade neural com entradas atrasadas no tempo para acionamento V/f de motor de indução

Carlos M. R. Oliveira ¹

Manoel L. Aguiar

Allan G. Castro

William C. A. Pereira

Paulo R. U. Guazzelli

José Roberto B. A. Monteiro

Escola de Engenharia de São Carlos, USP, São Carlos, SP

Resumo. Este trabalho tem como objetivo a utilização de uma rede neural artificial (RNA) para estimação de velocidade em motores de indução trifásicos, baseando-se em um treinamento com variações proporcionais de tensão e frequência estatísticas. Os resultados demonstraram a eficácia da RNA para ampla faixa de operação, incluindo região de baixa frequência com variações de torque de carga.

Palavras-chave. Motor de indução, RNA.

1 Introdução

O motor de indução trifásico (MIT) tem sido utilizado em diversos setores e consequentemente elevado sua relevância no panorama energético, obrigando os pesquisadores a trazerem alternativas que melhorem o desempenho dinâmico e ainda custos. A eliminação dos sensores mecânicos (de posição, velocidade e torque) sem prejudicar o desempenho dinâmico do sistema, tem sido uma alternativa eficaz e recorrente. Assim é possível reduzir a complexidade da estrutura física de acionamento de servomecanismos; diminuir a necessidade de manutenção, e em alguns casos aumentar a confiabilidade do sistema [1].

O desempenho das estratégias de controle *sensorless* possuem algumas limitações. Algumas técnicas apresentam bom desempenho para a estimação da velocidade com parâmetros nominais, exceto em baixa velocidade (região de baixa frequência). O fraco desempenho na região de baixa frequência é devido, principalmente, a maior sensibilidade dos estimadores e observadores às mudanças nos valores dos parâmetros da máquina, ausência de modelos das não-linearidades e ruídos dos sensores [2].

Diversos trabalhos podem ser encontrados na literatura dedicados à melhoria dos métodos *sensorless*, podendo ser separados em: com injeção de sinal; e sem injeção de

¹carlosmro@usp.br

sinal. Durante os últimos anos as técnicas *sensorless* baseadas na injeção de sinal de alta frequência evoluíram, podendo até mesmo garantir o controle do torque em velocidade zero. Para o uso desse método são necessárias modificações no projeto do motor, criando saliências ou ranhuras no rotor, encarecendo o custo da máquina e trazendo risco de danificar a mesma [3]. As técnicas *sensorless* sem o uso de injeção de sinal de alta frequência utilizam o modelo da máquina para extrair informações sobre a força contraeletromotriz [4].

O uso de sistemas inteligentes como a rede neural artificial (RNA) tem sido uma alternativa atraente para sistemas de alto desempenho dinâmico envolvendo o uso do MIT [5–7]. O fato está relacionado principalmente sua capacidade de ser tolerante a falhas, capacidade de se adaptar e generalizar e ainda robustez a ruídos de medição. As RNAs possuem capacidade de aquisição e retenção do conhecimento baseado na experiência, podendo ser definidas como um conjunto de unidades de processamento denominados neurônios artificiais, os quais são interligados por um grande número de conexões e matematicamente representadas por vetores ou matrizes de pesos sinápticos. O processo de treinamento consiste num algoritmo de aprendizagem em que os pesos são ajustados de forma a mapear o comportamento entre as variáveis de entrada e saída de um sistema [8].

Neste trabalho será explorado as potencialidades de um RNA como estimador de velocidade de um motor de indução, podendo ser aplicado a qualquer sistema de controle para ampla faixa de velocidade.

2 Motor de Indução Trifásico

Com intuito de se obter uma simplificação do modelo dinâmico do MIT e uma redução do número de variáveis que compõem o modelo matemático, utiliza-se transformação ortogonal conhecida como $\alpha\beta$ com representação vetorial. Assim, as tensões trifásicas do estator v_{ABC} pode ser analisada por meio da notação vetorial $\vec{v}_s$, tal como [4]:

$$\vec{v}_s = \begin{bmatrix} v_\alpha \\ v_\beta \end{bmatrix} = \frac{2}{3} \begin{bmatrix} 1 & -\frac{1}{2} & \frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \cdot \begin{bmatrix} v_A \\ v_B \\ v_C \end{bmatrix} \quad (1)$$

Desta forma, é possível descrever o MIT com rotor em gaiola de esquilo na notação vetorial com um conjunto de equações [4]:

$$\vec{v}_s = R_s \vec{i}_s + \frac{d\vec{\psi}_s}{dt} + j\omega_\lambda \vec{\psi}_s \quad (2a)$$

$$0 = R_r \vec{i}_r + \frac{d\vec{\psi}_r}{dt} + j(\omega_\lambda - p\omega_m) \vec{\psi}_r \quad (2b)$$

$$\vec{\psi}_s = L_s \vec{i}_s + L_h \vec{i}_r \quad (2c)$$

$$\vec{\psi}_r = L_h \vec{i}_s + L_r \vec{i}_r \quad (2d)$$

$$\frac{d\omega_m}{dt} = \frac{1}{J} (T - F\omega_m - T_L) \quad (2e)$$

$$T = \frac{3}{2}p \cdot \text{Im}\{\vec{\psi}'_s \cdot \vec{i}_s\} \quad (2f)$$

sendo que $\vec{v}_s$ é a tensão de estator do motor de indução, $\vec{i}_s$ é corrente de estator, $\vec{\psi}_s$ é o fluxo de estator; $\vec{i}_r$ é a corrente de rotor; $\vec{\psi}_r$ é o fluxo de rotor; R_s é a resistência de estator; R_r é resistência de rotor; L_s é a indutância de estator; L_r é a indutância de rotor; L_h é a indutância mútua; J é o momento de inércia do motor; F é o coeficiente de atrito viscoso do motor; T_L é o torque de carga; n_{pp} é o número de pares de polos; T_{el} é o torque eletromagnético; ω_m é a velocidade angular mecânica; ω_λ é a velocidade angular do referencial adotado. A notação “ ’ ” indica o conjugado de uma variável.

3 Estimador Neural de Velocidade

Para resolver os problemas encontrados em sistemas de controle *sensorless*, propõe-se a utilização de uma rede perceptron multicamadas (PMC) de entradas atrasadas no tempo (do inglês *Time Delay Neural Network*, TDNN) para estimação da velocidade. Esta é uma RNA de arquitetura *feedforward*, sendo apresentada primeiramente por [9]. A rede calcula sua saída em função dos valores de entradas anteriores, ou seja:

$$x(t) = f(x(t-1), x(t-2), \dots, x(t-n_p)) \quad (3)$$

onde n_p é a ordem dos atrasos do preditor.

Desse modo, uma PMC aplicada em processos variantes no tempo tem configuração com n neurônios conforme apresentado na Figura 1. Nota-se que os atrasos são aplicados somente na camada de entrada, denominada de TDNN com configuração focada (*focused time-lagged feedforward network*) [10].

Neste problema, a rede TDNN opera como um aproximador universal de funções, como as entradas estão atrasadas no tempo é possível que a rede assimile o comportamento dinâmico, ou seja, temporal do processo. A topologia utilizada possui no vetor de entrada a amostra atual em conjunto com as atrasadas, sendo composta por cinco variáveis de entradas e apenas uma saída. Nesta rede é considerada em cada entrada a ordem do preditor n_p igual a três.

O treinamento foi do tipo supervisionado baseado no algoritmo de aprendizagem *back-propagation*. Neste algoritmo apresenta-se à rede o vetor de entrada contendo as tensões, correntes e frequências. A saída produzida pela rede é então comparada com a saída desejada, neste caso a velocidade, para o respectivo vetor de entrada. Possuindo a diferença entre ambas as saídas, o erro é calculado e a saída da rede é produzida. O sinal de erro é retro propagado com o objetivo de ajustar os pesos sinápticos de forma que a saída produzida pela rede esteja próxima da saída desejada. Este processo é repetido para todos os vetores de entrada da rede até que o erro quadrático médio das saídas da rede estejam com valores aceitáveis [11].

Durante a fase de treinamento, várias topologias foram testadas e a escolha ficou baseada na capacidade de generalização da rede, sendo utilizado o desvio padrão como parâmetro para escolha. Para isso dividiu-se o conjunto de dados de forma aleatória em 70% para treinamento e o restante para teste. A topologia que apresentou o menor desvio padrão é composta por duas camadas escondidas, com 10 e 11 neurônios na primeira e

segunda camada, respectivamente. Assim como relatado no trabalho realizado por [8], os atrasos amostrais utilizados no estimador de velocidade também contribuem para minimizar os efeitos de uma possível variação repentina da corrente elétrica e também dos ruídos dos sinais de entrada, ou seja, a TDNN também atua como um filtro das variáveis de entrada. A escolha das entradas são baseadas no conhecimento do MIT, ou seja, as variáveis que mais influenciam no processo. Vale ressaltar que outro fator importante é a maneira como os dados de treinamento são tratados.




Figura 1: Diagrama da topologia TDNN utilizada para simulação

Para que o estimador de velocidade proposto seja generalista com relação as variáveis do motor de indução acionado, foi adotada a normalização com os valores máximos de todas as variáveis de entrada e saída, sendo que cada vetor possui sua respectiva normalização. Dessa forma, objetiva-se que o estimador tenha desempenho satisfatório mesmo para uma máquina cujos parâmetros são diferentes daqueles usados nas simulações, desde que se tenha mesma faixa de potência.

Tendo os dados de entrada e saída normalizados, a PMC é treinada com variações proporcionais da frequência e amplitude da tensão do estator, este método de treinamento é baseado em um modo de operação conhecido como V/f , onde o MIT trabalha com desempenho satisfatório, tendo praticamente a mesma performance de torque em motores CC. Nesta estratégia de atuação, o fluxo de campo permanece constante. Como as variações V/f de são proporcionais a frequência, ela é dada como entrada.

De posse dos dados de entrada, são realizados atrasos amostrais de ordem três nas variáveis de frequência, tensão e corrente do estator, formando o conjunto de treinamento. Assim cada variável de entrada é constituída por um conjunto dado por $x(t); x(t-1); x(t-2); x(t-3)$ ou seja, para cada entrada da RNA são utilizadas seus valores atuais e atrasos amostras de ordem 3.

Durante o processo de treinamento e validação a TDNN de ordem 3 foi a que apresentou os melhores resultados. Similar a rede proposta por [8] para estimação de velocidade, nas simulações realizadas com atrasos amostrais de ordem maior a RNA apresentou *overfitting*. Tem-se uma taxa de aprendizagem de 0,03, as funções de ativação dos neurônios das camadas escondidas são tangentes hiperbólicas e no neurônio da camada de saída a função linear.

4 Treinamento da RNA-PMC

Os resultados são obtidos por meio de simulações em ambiente MATLAB/Simulink, sendo que a estrutura é constituída do conjunto inversor fonte de tensão com controle em malha aberta com ajuste da frequência (frequência de chaveamento em 2kHz) com *Space Vector Modulation* (SVM). Assim, tem-se ainda a aquisição dos dados de corrente, tensão e frequência como parâmetros de entrada para a RNA. Os parâmetros do MIT são: $R_s = 7,56 \, \Omega$; $R_r = 3,84 \, \Omega$; $L_s, L_r = 350,85 \, \text{mH}$; $L_h = 336,15 \, \text{mH}$; $n_{pp} = 2$; $J = 0,017 \, \text{Kg.m}^2$ e $F = 0,0001 \, \text{N.m.s}$.

A geração dos dados de treinamento apartir de simulações com variações V/f constantes, partindo de valores baixos até os nominais de tensão e frequência da máquina. Optou-se por utilizar uma separação nas faixa de V/f baseadas na divisão de frequência proposta por [8], assim as simulações realizadas compreendem o MIT operando numa faixa de 1 Hz a 60 Hz, variando com o passo de 1 Hz na faixa de 6 Hz a 60 Hz e 0,5 Hz na faixa entre 1 a 6 Hz, totalizando simulações da partida ao regime permanente.

Como existe certa dificuldade em mapear o comportamento dinâmico do MIT em baixas frequências, ou seja, em baixos valores de V/f , obteve-se maior concentração amostral nesta faixa de operação. Ainda, para cada ponto de operação de V/f foram utilizados 5 valores de conjugado resistente de carga, variando de 0 a 4 N.m com incremento de 1 N.m. A Figura 2 ilustra as velocidades geradas com os dados para treinamento. Além disso, é possível visualizar que durante o treinamento existiu proporcionalidade da tensão pelo torque.




Figura 2: Amostras de treinamento para variações de V/f com diferentes torques no eixo dados em instantes aleatórios.

5 Discussão e Análise dos Resultados

Após o treinamento, foram realizados testes de comparações das velocidades estimadas e reais. Inicialmente, a Figura 3 ilustra duas situações de operação com variação de carga de 0 a 4 N.m por períodos de 0,4 segundo. Assim, tem-se a operação em condições nominais (60Hz) e também com metade da frequência (30Hz), onde em ambos os casos obteve-se razoável estimativa. Embora as respostas se apresentem um pouco ruidosas, é possível

obter melhora com o uso de filtros.




Figura 3: Gráficos da Velocidade estimada com variações de torque no eixo.

Na Figura 4 é ilustrado o comportamento da estimação perante a situação mais crítica, em baixa velocidade. Nota-se o comportamento mais oscilatório da velocidade do MIT, isto se deve ao baixo valor dado pela proporção de V/f . A frequência se manteve com 6 Hz com um sinal de carga no eixo variando de 0 a 0,2 N.m. A velocidade estimada nesta faixa de V/f não se apresentou com a mesma fidelidade demonstrada nas situações anteriores, entretanto para aplicações que não requerem elevado desempenho nessa faixa o MIT poderia operar normalmente.




Figura 4: Gráficos da velocidade estimada operando em 6Hz.

6 Conclusões

Neste trabalho é proposto uma metodologia para estimar a velocidade do MIT acionado por um inversor de frequência com controle em malha aberta utilizando da modulação SVM, baseando-se em uma RNA-PMC com treinamento supervisionado *off-line*. A estimação de velocidade compreendendo toda a faixa de operação do MIT para diferentes valores de carga.

De maneira geral, os resultados demonstraram a capacidade de generalização da RNA fornecendo respostas com oscilações razoáveis. Notou-se que com a redução proporção V/f as ondulações na velocidade aumentaram e consequentemente o comportamento dinâmico se apresentou mais oscilatório. Logo, para baixas frequência a RNA teve maior dificuldade de estimar a velocidade.

Conforme demonstrado no trabalho, não foi necessário inserir nenhum modelo matemático ou parâmetro do MIT ao treinamento da RNA. Assim, o sistema apresentado pode ser um bom candidato a sistemas que requerem estimação de velocidade para aumentar robustez perante falhas.

Referências

- [1] T. Ramesh, A. Panda and S. Kumar, Sensorless control of induction motor drives, *Proceedings of the IEEE*, 1359-1394, (2002).
- [2] C. Lascu, I. Boldea, F. Blaabjerg, Very-low speed variable-structure control of sensorless induction machines drives without signal injection, *IEEE Transactions on Industry Applications*, 591-598, (2005).
- [3] T. Ramesh, A. Panda and S. Kumar, Sensorless control of AC motor - Where are we now?, *IEEE International Conference on Electrical Machines and Systems*, (2011).
- [4] P. Vas, *Artificial Intelligence Based Electrical Machines and Drives: Fuzzy, Neural, Fuzzy-neural and Genetic Algorithm based technique*, Oxford University Press, (1999).
- [5] X. Sun, L. Chen, Z. Yang, H. Zhu, Speed-Sensorless Vector Control of a Bearingless Induction Motor With Artificial Neural Network Inverse Speed Observer, *IEEE/ASME Transactions on Mechatronics*, 1357-1366, (2012).
- [6] S. M. Gadoue, D. Giaouris, J. W. Finch, Sensorless Control of Induction Motor Drives at Very Low and Zero Speeds Using Neural Network Flux Observers, *IEEE Transactions on Industrial Electronics*, 3029-3039, (2009).
- [7] M. Wlas, Z. Krzeminski, J. Guzinski, H. Abu-Rub and H. A. Toliyat, Artificial-neural-network-based sensorless nonlinear control of induction motors, *IEEE Transactions on Energy Conversion*, 520-528, (2005).
- [8] T. H. Santos, Estimador neural de velocidade aplicado a um driver de controle escalar do motor de indução trifásico, dissertação, UTFPR, (2012).
- [9] K. J. Lang, G. E. Hinton, The development of the time-delay neural network architecture for speech recognition, (1988).
- [10] I. N. Silva, D. H. Spatti, R. A. Flauzino, *Redes neurais artificiais para engenharia e ciências aplicadas - curso prático*, vol. 1, (2010).
- [11] A. Goedtel, Estimador neural de velocidade para motores de indução trifásico, Tese, USP, (2007).