



Controle Vetorial *Sensorless* do Motor BLDC Usando Estimador Neural de Velocidade

Allan G. Castro¹, Wilhiam C. Carvalho, Carlos M. R. Oliveira, Paulo R. U. Guazzelli, Thales E. P. Almeida, William C. A. Pereira, José Roberto B. A. Monteiro², Azauri A. Oliveira Jr.³

Departamento de Engenharia Elétrica e de Computação, Escola de Engenharia de São Carlos - USP, São Carlos, SP

Resumo. Devido ao fluxo não senoidal produzido pelos ímãs do rotor, motores *Brushless DC* (BLDC) requerem estratégias particulares de controle e de estimação de velocidade para operação sem sensores *Hall* ou *encoders*. Nesse contexto, esse trabalho propõe uma estratégia de controle vetorial *sensorless* do BLDC baseada na estimação de velocidade a partir de uma rede neural artificial perceptron multicamadas. Essa abordagem é analisada por meio de simulação computacional da máquina em diferentes condições de operação, alcançando erro de estimação de velocidade durante dinâmicas e regime permanente inferior à 1%.

Palavras-chave. BLDC, controle vetorial *sensorless*.

1 Introdução

Motores *Brushless DC* (BLDC) são empregados em uma ampla faixa de aplicações industriais e comerciais devido à atraentes características como alta eficiência e alta densidade de potência. Essa topologia de máquina possui ímãs permanentes no rotor e é caracterizada pela indução de forças contraeletromotrizes (FCEMs) não senoidais (usualmente trapezoidais) no enrolamento do estator. Por esse motivo, o BLDC requer esquemas de alimentação e controle particulares para produção de torque útil. Nessa perspectiva, comumente é empregada a estratégia de controle 6 pulsos, na qual o enrolamento do estator é alimentado por correntes com forma de onda retangular sincronizadas às FCEMs. Alternativamente, recentes trabalhos tem abordado o controle vetorial dessa máquina, demonstrando capacidade de redução de ondulações de torque e aumento da relação de torque por ampère [3, 4].

¹allangregori@usp.br

²jrm@sc.usp.br

³azauri@sc.usp.br

Em ambas condições de controle, o acionamento elétrico do BLDC em aplicações de velocidade variável essencialmente requer a informação da posição e velocidade rotórica para as malhas de controle de corrente e rotação, respectivamente. Para fornecer essas grandezas, usualmente sensores *Hall* são alocados na estrutura do estator ou *encoders* são acoplados ao eixo mecânico da máquina [1]. Contudo, o uso desses sensores implicam em aumento do custo, aumento do volume físico do sistema de acionamento, dentre outros fatores [1]. Em função disso, para diversas aplicações existe o interesse em alternativas técnicas de determinação da posição e velocidade rotórica em tempo real sem o uso desses sensores (operação *sensorless*), elevando a confiabilidade e reduzindo o custo do conjunto. Nesse sentido, diversas abordagens são apresentadas na literatura para obtenção da posição e velocidade rotórica do BLDC tanto para estratégias de controle 6 pulsos como o controle vetorial [2, 3, 10].

Para determinação da velocidade, técnicas usualmente baseiam-se na contagem do tempo entre os cruzamentos por zero das ondas de forças contraeletromotrizes estimadas do estator [1]. Embora esse tipo de abordagem seja amplamente empregado e produza satisfatório resultado em regime permanente, é impreciso em acelerações e em baixas velocidades já que os cruzamentos por zero não são frequentes [3].

No controle vetorial de máquinas de fluxo senoidal, abordagens de controle sem sensores de posição/velocidade podem ser implementadas a partir da estimação da posição e velocidade do fluxo do rotor [6]. No entanto, devido às componentes harmônicas, em máquinas de fluxo rotórico não senoidal como o BLDC, a posição e velocidade do fluxo ou da FCEM não correspondem àquelas do eixo mecânico da máquina, como demonstrado em [3]. Por esse motivo, em [2] é empregado um filtro de elevada ordem para filtrar tais componentes harmônicas e obter a informação de velocidade real da máquina em regime permanente. Contudo, devido à frequência do filtro necessário para filtrar as componentes harmônicas, o esquema de controle desempenha lenta dinâmica de velocidade.

Em [9] é proposto um *Phase-LockedLoop* (PLL) com a adição de filtros de extração de frequência síncrona para determinar a real posição e velocidade da máquina a partir de FCEMs estimadas. No entanto, essa abordagem exige o esforço de sintonia dos ganhos dos controladores lineares presentes no método PLL.

Tendo em vista que as FCEMs não senoidais do BLDC carregam a informação da velocidade rotórica e que expressões analíticas não apresentam satisfatório desempenho de estimação, ferramentas como redes neurais artificiais (RNA) podem ser declaradas atrativas nessa aplicação devido sua capacidade de extrair o relacionamento entre grandezas de um sistema através da emulação de funções multi-variáveis não lineares [8]. Nesse trabalho é implementada uma RNA para extrair a informação de velocidade do BLDC com base na estimação das formas de onda das FCEM não senoidais no contexto do controle vetorial *sensorless* com minimização das ondulações de torque.

2 Modelo matemático do motor BLDC

O modelo dinâmico do motor BLDC em referencial complexo estacionário $\alpha\beta$ é dado por

$$\mathbf{v}_{\alpha\beta} = R\mathbf{i}_{\alpha\beta} + L\frac{d}{dt}\mathbf{i}_{\alpha\beta} + \mathbf{e}_{\alpha\beta} \quad (1)$$

em que R e L são a resistência e indutância por fase do estator, respectivamente; $\mathbf{v}_{\alpha\beta} = [v_\alpha \ v_\beta]^T$ é o vetor de tensões de terminal no plano complexo $\alpha\beta$; $\mathbf{i}_{\alpha\beta} = [i_\alpha \ i_\beta]^T$ é o vetor de correntes de fase; e $\mathbf{e}_{\alpha\beta} = [e_\alpha \ e_\beta]^T$ é o vetor de FCEMs não senoidais. O torque eletromagnético T_e desenvolvido pela máquina é expresso no referencial $\alpha\beta$ por

$$T_e = \frac{1}{\omega_r}(\mathbf{e}_{\alpha\beta}^T \mathbf{i}_{\alpha\beta}) \quad (2)$$

em que ω_r é a velocidade mecânica.

Diferentemente de máquinas síncronas de fluxo senoidal em que o modelo elétrico da máquina é adicionalmente orientado no fluxo do rotor à título de simplificação, o modelo do BLDC pode ser orientado nas FCEMs normalizadas do rotor, como apresentado em [2], a fim de reduzir ondulações de torque. Nesse sentido, define-se a transformação T_{dq} do referencial estacionário $\alpha\beta$ para o referencial dq síncrono às FCEM $\mathbf{e}_{\alpha\beta}$ não senoidais como

$$\mathbf{T}_{dq} = \begin{bmatrix} F_\beta & -F_\alpha \\ F_\alpha & F_\beta \end{bmatrix} \quad (3)$$

sendo F_α e F_β as formas de onda de e_α e e_β , dadas por

$$\mathbf{F}_{\alpha\beta} = \frac{\mathbf{e}_{\alpha\beta}}{z_p \Psi_m \omega_r} \quad (4)$$

em que z_p é o número de pares de polo da máquina e Ψ_m a magnitude do fluxo magnético dos ímãs permanentes do rotor. Aplicando (3) em (1) tem-se

$$\mathbf{v}_{dq} = R\mathbf{i}_{dq} + \omega_1 L_s \mathbf{i}_{dq} + \mathcal{J} \omega_2 L_s \mathbf{i}_{dq} + L_s \frac{d}{dt} \mathbf{i}_{dq} + \mathbf{e}_q \quad (5)$$

sendo

$$\omega_1 = -\frac{F_\alpha \frac{d}{dt} F_\alpha + F_\beta \frac{d}{dt} F_\beta}{F_\alpha^2 + F_\beta^2}, \quad \omega_2 = \frac{F_\alpha \frac{d}{dt} F_\beta - F_\beta \frac{d}{dt} F_\alpha}{F_\alpha^2 + F_\beta^2} \quad \text{e} \quad \mathcal{J} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}. \quad (6)$$

No referencial dq orientado nas FCEM, o torque eletromagnético T_e é expresso como

$$T_e = \frac{1}{\omega_r} \mathbf{e}_{dq}^T (\mathbf{T}_{dq}^{-1})^T \mathbf{T}_{dq}^{-1} \mathbf{i}_{dq} = z_p \Psi_m i_q. \quad (7)$$

Nota-se que em (7) o torque eletromagnético desenvolvido pelo BLDC é diretamente proporcional à componente i_q da corrente de estator, similarmente à modelagem convencional de motores síncronos por orientação no fluxo senoidal do rotor. Como resultado, ondulações de torque são teoricamente eliminadas se i_q for mantida constante, uma vez que Ψ_m é constante.

Em função da FCEM da máquina armazenar a informação de velocidade rotórica, nesse trabalho é implementado uma rede neural com a função de extrair o relacionamento das variáveis $\mathbf{F}_{\alpha\beta}$ e a velocidade real da máquina de fluxo não senoidal, atuando como um aproximador de função. Para esse fim, esse trabalho implementa uma rede neural de arquitetura TDNN (*Time Delay Neural Network*) tal como ilustrada na Figura 3a, contendo duas camadas neurais (compostas de N_1 e N_2 neurônios) e entradas $\mathbf{F}_{\alpha\beta}$ atrasadas h passos no tempo discreto k .




Figura 2: (a) $F_{\alpha\beta}$ em função de $\theta_{\psi_{r\alpha\beta}}$ e (b) diagrama de estimação e consulta em tabela.




Figura 3: (a) Estrutura TDNN empregada e (b) velocidades de operação para treinamento.

Para compor o conjunto de treinamento, são armazenados os valores de $F_{\alpha\beta}$, considerando $h = 4$, para uma série de pontos de velocidade de operação da máquina, que são mostrados na Figura 3b. A Tabela 2 apresenta os parâmetros estruturais da rede neural projetada para ser implementada em uma máquina com os parâmetros da Tabela 2.

4 Resultados de Simulação

O primeiro teste do sistema *sensorless* proposto consiste em avaliar o desempenho dinâmico da estimação de velocidade. Nesse sentido, a Figura 4 apresenta dos resultados de velocidade medida ω_r e estimada $\hat{\omega}_r$, bem como o erro de estimação $e_\omega = \hat{\omega}_r - \omega_r$, durante uma manobra de aceleração e desaceleração da máquina considerando degraus de referência de velocidade no instante de tempo $t = 0, 2$ s e $t = 1, 3$ s, sendo esses valores de referência diferentes dos dados utilizados para o treinamento da RNA. A apresentação dos dados em valores por unidade utiliza como grandeza base a velocidade nominal da máquina. Na Figura 4, o erro de estimação excursionsa em uma faixa inferior à 1% da velocidade medida.

O desempenho do esquema *sensorless* é também avaliado durante distúrbios de carga. A Figura 5 apresenta o desempenho dinâmico da velocidade da máquina, sua estimação e erro de estimação em dois pontos de operação considerando inserção e alívio de carga em degrau nos instantes $t = 0, 1$ s e $t = 1$ s, respectivamente. De maneira geral, os resultados demonstram a capacidade de rejeição à distúrbio do sistema de controle bem como erro de estimação inferior à 1% pela RNA.

Tabela 1: Parâmetros da Rede Neural

Arquitetura da rede	TDNN
Neurônios N_1	10
Neurônios N_2	12
Algoritmo de Treinamento	Levenberg Marquardt
Taxa de Aprendizagem	5×10^{-2}
Número de épocas	996
Função de Ativação das Camadas Escondidas	Tangente Hiperbólica
Função de Ativação da Camada de Saída	Linear

Tabela 2: Parâmetros do BLDC

Resistência R	$2,4 \Omega$
Indutância L	$12,4 \text{ mH}$
Torque Nominal	2 Nm
Velocidade Nominal	2000 rpm
Pares de polos	3




Figura 4: Desempenho da estimação durante mudanças de velocidade de operação.




Figura 5: Desempenho da estimação de velocidade durante distúrbio de carga.

5 Conclusão

Esse trabalho apresentou uma abordagem de controle de velocidade *sensorless* de uma máquina síncrona com ímãs permanentes no rotor e força contra-eletromotriz não senoidal baseado em uma rede neural artificial. De acordo como os resultados apresentados, o desempenho da rede neural produz reduzido erro de regime permanente e rápida resposta dinâmica, apresentando-se como uma atraente alternativa para implementação em aplicações *sensorless*.

Referências

- [1] P. P. Acarnley, J. F. Watson, Review of position-sensorless operation of brushless permanent-magnet machines, IEEE Trans. on Industrial Electronics, vol. 53, no. 2, pp. 352-362, April 2006.
- [2] C. L. Baratieri, H. Pinheiro, Sensorless vector control for PM brushless motors with nonsinusoidal back-EMF, 2014 International Conference on Electrical Machines (ICEM), Berlin, 2014, pp. 915-921.
- [3] G. Buja, M. Bertoluzzo, R. K. Keshri, Torque Ripple-Free Operation of PM BLDC Drives With Petal-Wave Current Supply, IEEE Trans. on Industrial Electronics, vol. 62, no. 7, pp. 4034-4043, July 2015.
- [4] A. Damiano et al., Performance comparison between two-phase-on and three-phase-on operation of Brushless DC drives, 2014 International Symposium on Power Electronics, Electrical Drives, Automation and Motion, Ischia, 2014, pp. 489-494.
- [5] Jun Hu, Bin Wu, New integration algorithms for estimating motor flux over a wide speed range, IEEE Trans. on Power Electronics, vol. 13, no. 5, pp. 969-977, Sep 1998.
- [6] H. Kim, J. Son and J. Lee, A High-Speed Sliding-Mode Observer for the Sensorless Speed Control of a PMSM, IEEE Trans. on Industrial Electronics, vol. 58, no. 9, pp. 4069-4077, Sept. 2011.
- [7] S. B. Ozturk, H. A. Toliyat, Direct Torque and Indirect Flux Control of Brushless DC Motor, IEEE/ASME Trans. on Mechatronics, vol. 16, no. 2, pp. 351-360, April 2011.
- [8] I. N. Silva, D. H. Spatti, R. A. Flauzino, Redes Neurais Artificiais para Engenharia e Ciências Aplicadas - Curso Prático. Artliber, 2010.
- [9] X. Song et al., Adaptive Compensation Method for High-Speed Surface PMSM Sensorless Drives of EMF-Based Position Estimation Error, IEEE Transactions on Power Electronics, vol. 31, no. 2, pp. 1438-1449, Feb. 2016.
- [10] A. Stirban, I. Boldea, G. D. Andreescu, Motion-Sensorless Control of BLDC-PM Motor With Offline FEM-Information-Assisted Position and Speed Observer, IEEE Trans. on Industry Applications, vol. 48, no. 6, pp. 1950-1958, Nov.-Dec. 2012.