

Firefly Algorithm aplicado em um Filtro de Kalman Estendido utilizado para estimação de velocidade de um motor de indução trifásico

Firefly Algorithm applied in an Extended Kalman Filter used for speed estimation of a three-phase induction motor

Heloisa Oliveira dos Santos
heloisa.o.santos@outlook.com
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Marcelo Favoretto Castoldi
marcastoldi@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Alessandro Goedel
agoedel@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

RESUMO

Este trabalho consiste na estimação de velocidade de um motor de indução trifásico (MIT), a partir de uma técnica *sensorless* baseada no Filtro de Kalman Estendido (EKF). Para melhorar o desempenho do estimador, as matrizes de covariância do EKF devem ser sintonizadas com precisão. Desse modo, este trabalho propõe a sintonia de tais matrizes utilizando o Algoritmo de Enxame de Vagalumes (FA) em detrimento ao método tradicional de tentativa e erro, que é custoso e consome tempo. Os resultados são validados por testes realizados no software Simulink®. Para demonstrar a robustez do método proposto, simulação com entrada de carga é apresentada.

PALAVRAS-CHAVE: Estimação de Velocidade. Filtro de Kalman Estendido. Algoritmo de Enxame de Vagalumes.

ABSTRACT

This paper consists in the speed estimation of a three-phase induction motor, using a sensorless technique based on the Extended Kalman Filter (EKF). To improve the performance of the estimator, the covariance matrices of the EKF must be tuned accurately. Thus, this work proposes the tuning of such matrices using the Firefly Algorithm (FA) in detriment of the traditional method of trial and error, which is costly and time-consuming. The results are validated by tests performed on software Simulink®. To demonstrate the robustness of the proposed method, simulation with load input is presented.

KEYWORDS: Speed Estimation. Extended Kalman Filter. Firefly Algorithm,.

Recebido: 31 ago. 2018.

Aprovado: 04 out. 2018.

Direito autoral:

Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



1 INTRODUÇÃO

O Motor de Indução Trifásico (MIT) é amplamente utilizado no setor industrial devido ao seu baixo custo, robustez e confiabilidade (KOSOW, 2005). No entanto, a eficiência do motor no processo produtivo pode depender de acionamento e controle de velocidade adequado. Usualmente para o monitoramento de velocidade são utilizados equipamentos auxiliares acoplados ao sistema, denominados *encoders* (FITZGERALD; KINGDLEY; UMAS, 2016). Porém, o custo adicional deste equipamento torna a vantagem econômica do MIT menor.

Com isso, estratégias *sensorless* foram desenvolvidas para estimar a velocidade do MIT de maneira satisfatória baseando-se em suas próprias grandezas, o que permite que os custos relacionados a medição de velocidade sejam reduzidos, quando comparados a utilização de *encoders*. Uma das técnicas *sensorless* na estimação de velocidade de um MIT é o algoritmo Filtro de Kalman Estendido (EKF – do inglês *Extended Kalman Filter*). Contudo, há uma grande dificuldade em determinar os valores das Matrizes de Covariância (MC) do sistema e do ruído de medição no algoritmo EKF, pois estas são obtidas a partir de tentativas e erros (ZERDALI; BARUT, 2017).

O desempenho do EKF pode ser aprimorado por meio de um ajuste *offline* das matrizes de covariância. Tal ajuste pode ser feito a partir de métodos automáticos empregados na sintonização dos valores dessas matrizes.

O Algoritmo Enxame de Vagalumes (FA – do inglês *Firefly Algorithm*) pode ser uma boa opção para realizar tal ajuste, pois este vem se mostrando eficiente em situações que não se tem uma boa solução inicial para começar o processo de iteração (TJAHJONO et al., 2017).

Devido à dificuldade em se determinar as matrizes de covariância do EKF, em consequência do método tradicional consistir em tentativas e erros, o FA foi o algoritmo adotado para realizar a otimização. O algoritmo de otimização em questão será implementado para sintonizar os valores dos parâmetros das matrizes de covariância do EKF, o que resultará em melhoras significativas na estimação de velocidade e um *sensorless* robusto, trazendo impactos econômicos consideráveis a indústria, uma vez que o MIT é o motor mais utilizado no setor.

2 ALGORITMO DE ENXAME DE VAGALUMES

O FA é um dos mais recentes algoritmos bio-inspirados, tendo tal denominação por se basearem no comportamento de grupos encontrados na natureza, como insetos, pássaros, peixes, entre outros (CAVALI, 2017).

Segundo Silva et al. (2017) o FA se baseia no comportamento social dos vagalumes, onde através de um processo de bioluminescência emitem luz com a finalidade de atrair parceiros e presas em potencial.

Para a elaboração do FA deve-se levar em consideração que a atratividade de um vagalume é proporcional a intensidade de luz vista por vagalumes adjacentes e pode ser calculada a partir da Eq. (1).

$$\beta = \beta_0 e^{-\gamma r^2} \quad (1)$$

onde β_0 é definido como a atratividade quando $r = 0$ e seu valor para a maior parte das aplicações é 1. Já γ define o coeficiente de absorção de luz em um determinado meio e seu valor varia tipicamente entre 0,1 e 10 (YANG, 2010).

A distância r_{ij} entre os vagalumes i e j , em \mathbf{x}_i e \mathbf{x}_j é determinada pela distância cartesiana e pode ser calculada a partir da Eq. (2)

$$r_{ij} = \|\mathbf{x}_i - \mathbf{x}_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (2)$$

O vagalume menos atraente caminha em direção ao mais atrativo e este movimento é exibido na Eq. (3), em que t é a iteração atual.

$$\mathbf{x}_{i_{t+1}} = \mathbf{x}_{i_t} + \beta_0 e^{-\gamma r_{ij}^2} (\mathbf{x}_{j_t} - \mathbf{x}_{i_t}) + \alpha \epsilon_i \quad (3)$$

onde $\mathbf{x}_{i_{t+1}}$ representa a posição do vagalume menos atrativo após o movimento, $\beta_0 e^{-\gamma r_{ij}^2} (\mathbf{x}_{j_t} - \mathbf{x}_{i_t})$ refere-se ao termo relacionado à atração e $\alpha \epsilon_i$ termo referente a aleatorização, sendo α o coeficiente de aleatoriedade e ϵ_i um valor aleatório, gerado para maioria dos casos a partir de uma distribuição gaussiana e neste caso pode ser substituído por valores aleatórios de -0,5 a 0,5.

Segundo Tjahjono et al. (2017) o coeficiente de aleatoriedade α assume valores entre 0 e 1 e desempenha um importante papel para determinar o quão aleatório será o movimento do vagalume. Visando melhorar o tempo de convergência do algoritmo o parâmetro de aleatoriedade deve ser variado de maneira progressiva à medida que se aproxima do ótimo valor. Um dos métodos utilizados para essa atualização é exibido na Eq. (4) (ALB et al., 2016).

$$\alpha(t + 1) = \delta \alpha_o^t \quad (4)$$

onde o fator δ assume valores entre 0,9 e 0,99.

3 METODOLOGIA

O refinamento da sintonia dos parâmetros das MC do EKF foi realizado em duas etapas, primeiro a de otimização e posteriormente a de validação. Os parâmetros do MIT utilizado para ambas as etapas foram: 7,56 Ω para Resistência do estator (R_1); 3,84 Ω para Resistência do rotor (R_2); 0,35085 H para Indutância do estator (L_1) e Indutância do rotor (L_2); 0,33615 H para Indutância mútua (L_M); 0,0001 N.m.s para Coeficiente de atrito (K_D); 0,017 Kg/m² para Momento de inércia (J).

Devido às limitações textuais a implementação do EKF não pode ser descrita, porém pode ser observada em Vas (1998) e Zerdali e Barut (2017). O EKF possui três MC sendo elas \mathbf{Q} , \mathbf{R} e \mathbf{P} , no qual possuem valores diferentes de zero apenas na diagonal principal, onde, a matriz de covariância $\mathbf{Q} \in \mathbb{R}^{5 \times 5}$, $\mathbf{P} \in \mathbb{R}^{5 \times 5}$ e $\mathbf{R} \in \mathbb{R}^{2 \times 2}$. Vale ressaltar que todos os termos da diagonal principal da matriz de covariância \mathbf{P} são de mesmo valor e foram denominados por conveniência como p_{11} . Na matriz \mathbf{Q} os termos q_{11} e q_{22} possuem os mesmos valores e foram denominados como q_{11} , os termos q_{33} e q_{44} também são iguais e foram denominados como q_{33} , enquanto que o termo q_{55} se diferencia dos demais termos da matriz. Já na matriz \mathbf{R} os termos diferentes de zero possuem os mesmos valores, portanto r_{11} e r_{22} são iguais e foram denominados como r_{11} .



Observou-se que em problemas semelhantes ao estudado que tiveram bons resultados os parâmetros das MC do EKF obtidos de forma tradicional foram de 10^{-10} para p_{11} , 10^{-1} para r_{11} , 10^{-7} para q_{11} , 10^{-8} para q_{33} e 10^{-5} para q_{55} , como pode ser visto em Maschio (2006) e Buzanelli (2016). Dessa forma, tais valores foram adotados como sendo os parâmetros das MC do EKF tradicional e serão utilizados como base para o espaço de busca na geração dos indivíduos iniciais utilizados no FA.

Os limites definidos para o espaço de busca de cada parâmetro na geração dos indivíduos iniciais utilizados no FA foram de: $10^{-14} \leq p_{11} \leq 10^{-6}$; $10^{-5} \leq r_{11} \leq 10^3$; $10^{-11} \leq q_{11} \leq 10^{-3}$; $10^{-12} \leq q_{33} \leq 10^{-4}$; e $10^{-6} \leq q_{55} \leq 10^0$. Os parâmetros para a implementação do FA foram: $\beta_0 = 1$; $\alpha_0 = 1$; $\gamma = 0,1$; $\delta = 0,97$; *Número de vagalumes* = 20; e *Máximo de iterações* = 100.

A fase de otimização inicialmente consistiu em comparar a velocidade estimada pelo EKF e a simulada do MIT, em que este parte com uma carga de 0,5 N.m e após 0,5s, tem uma carga de 3,5 N.m acrescentada ao seu eixo. Tal teste foi realizado com os valores das MC do EKF tradicional e posteriormente com os valores das MC do EKF otimizado, obtidos a partir do FA. Essa comparação ocorreu através da Função Objetivo (FO), que é uma função de minimização de erro entre a curva de velocidade estimada pelo EKF e a simulada pelo MIT. A FO é exibida na Eq. (5).

$$FO = \frac{1}{N} \sum_{n=0}^N (\omega_{n_{simulada}} - \omega_{n_{estimada}})^2 \quad (5)$$

onde N representa número de pontos utilizados, $\omega_{n_{simulada}}$ é a velocidade simulada do MIT e $\omega_{n_{estimada}}$ é a velocidade estimada pelo EKF.

O teste da fase de validação consistiu em acionar o MIT sem carga conectada ao seu eixo e após 0,5s acrescentar uma carga de 3 N.m.

Posteriormente realizou-se a comparação entre as velocidades estimadas pelo EKF tradicional e otimizado com a simulada pelo MIT. Tal comparação se deu através do *fitness*, onde este é definido como o argumento mínimo da função FO.

$$fitness = \arg \min FO(\mathbf{P}, \mathbf{Q}, \mathbf{R}) \quad (6)$$


4 RESULTADOS

A fase de otimização retornou um valor de 17,8822 para o *fitness* do EKF tradicional e de 3,4959 para o *fitness* do EKF otimizado. A Figura 1 exibe a comparação entre as curvas de velocidade simulada do MIT e as estimadas pelo EKF com parâmetros obtidos a partir do método tradicional e o otimizado via FA.

O teste da fase de validação retornou um valor de 15,9203 para o *fitness* do EKF tradicional e de 3,5011 para o *fitness* do EKF otimizado. Este refinamento pode ser analisado através da Figura 2.


Observando as Figuras 1 e 2 pode-se perceber que o desempenho do EKF otimizado foi satisfatório, uma vez que a velocidade estimada pelo EKF otimizado se aproximou da velocidade simulada desde o regime transitório.

Figura 1 – Teste da fase de otimização.



Fonte: Autoria própria.

Figura 2 – Teste da fase de validação.



Fonte: Autoria própria.

5 CONCLUSÃO

O presente trabalho apresentou resultados satisfatórios, uma vez que o FA garantiu o refinamento da sintonia dos parâmetros do EKF gerando um melhor desempenho na estimação de velocidade. A robustez do EKF otimizado pode ser comprovada na fase de validação.

A partir do processo de otimização o EKF se torna mais robusto e preciso, podendo melhorar significativamente a estimativa de velocidade de um motor de indução trifásico. Desta forma, a utilização da abordagem proposta pode trazer um impacto positivo na indústria, uma vez que tal motor é o mais utilizado no setor.

Dando continuidade aos estudos, a próxima etapa consiste em realizar o acionamento do motor de indução trifásico utilizando inversor de frequência.



REFERÊNCIAS

ALB, M.; ALOTTO, P.; MAGELE, C.; RENHART, W.; PREIS, K.; TRAPP, B. **Firefly algorithm for finding optimal shapes of electromagnetic devices**. IEEE Transactions on Magnetics, v. 52, n. 3, pp. 1-4, 2016.

BUZANELLI, J. H. **Estimador de velocidade de um motor de indução trifásico utilizando Filtro de Kalman Estendido**. 2016. 61 f Trabalho de Conclusão de Curso – Curso de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, 2016.

CAVALI, T. S. **Controle de potência via algoritmo de enxame de vaga-lumes para atenuação dos efeitos da variação de temperatura ambiente em redes OCDMA**. 2017. 86 f. Dissertação (Mestrado) – Curso de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, 2017.

FITZGERALD, A. E.; KINGDLEY, C.; UMAS, S. D. **Máquinas Elétricas: com introdução a eletrônica de potência**. 6. Ed. Porto Alegre: Bookman, 2006.

KOSOW, I. L. **Máquinas Elétricas e Transformadores**. 15. ed. São Paulo: Globo, 2005.

MASCHIO, K. A. F. **Estudo de estimadores de velocidade de motor de indução com observadores de estado e filtro de kalman**. 2006. 98 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2006.

SILVA, M. J.; VIDAL, J. F.; COSTA Jr, C. T.; SILVA, O. F. **redução de ordem de sistemas dinâmicos utilizando inteligência computacional uma abordagem via firefly algorithm**. Simpósio Brasileiro de Automação Inteligente, Porto Alegre, 2017. p. 1089 – 1094.

TJAHJONO, A.; ANGGRIAWAN, D. O.; FAIZIN, A. K.; PRIYADI A.; PUJANTARA, M.; TAUFIK, T.; PURNOMO, M. H. Adaptive modified firefly algorithm for optimal coordination of overcurrent relays. **IET Generation, Transmission & Distribution**, v.11, n. 10, p. 2575-2585, jul. 2017.

VAS, P. **Sensorless Vector and Direct Torque Control**. New York, USA: Oxford University Press Inc, 1998.

YANG, X. S. **Nature-Inspired Metaheuristic Algorithms**. 2. Ed. University of Cambridge: Luniver Press, 2010.



ZERDALI, E.; BARUT M. **The comparisons of optimized extended kalman filters for speed-sensorless control of induction motors.** IEEE, Transactions on Industrial Electronics, v. 64, n. 6, p. 4340-4351, jun. 2017.