

# 基于参数跟踪的感应电机转速与磁链 强跟踪滤波估计方法

张中磊<sup>1,2</sup>, 薄婷婷<sup>3</sup>, 孙传杰<sup>1,2</sup>, 王自满<sup>1,2</sup>, 姜一达<sup>1,2</sup>, 杨敬然<sup>1,2</sup>, 田凯<sup>1,2</sup>

(1. 天津电气科学研究院有限公司, 天津 300180; 2. 电气传动国家工程研究中心, 天津 300180; 3. 国网天津市电力公司检修公司, 天津 300250)

**摘要:** 针对感应电机高性能矢量控制中的转速与磁链估计问题, 提出了一种包含参数跟踪的转速与磁链联合估计强跟踪滤波(STF)方法。考虑电机参数变化及模型不确定性, 采用粒子群迭代学习动态优化算法实现对感应电机参数的在线跟踪, 修正的 STF 算法用于实现对感应电机转速与转子磁链的联合估计。仿真结果表明, 包含参数跟踪的 STF 算法能够有效实现对感应电机转速与转子磁链的高性能估计; 与扩展卡尔曼滤波算法相比, 包含参数跟踪的 STF 算法在估计精度、跟踪速度和稳定性方面得到大幅度提高, 并且能够快速跟踪突变状态, 尤其在低速段仍能保持较好的估计性能, 有效提高了状态估计精度和模型鲁棒性。

**关键词:** 感应电机; 状态估计; 参数跟踪; 粒子群优化; 强跟踪滤波器

**中图分类号:** TM346 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed21386

## Strong Tracking Filter Estimation Method for Speed and Flux of Induction Motor Based on Parameter Tracking

ZHANG Zhonglei<sup>1,2</sup>, BO Tingting<sup>3</sup>, SUN Chuanjie<sup>1,2</sup>, WANG Ziman<sup>1,2</sup>, JIANG Yida<sup>1,2</sup>, YANG Jingran<sup>1,2</sup>, TIAN Kai<sup>1,2</sup>

(1. Tianjin Research Institute of Electric Science Co., Ltd., Tianjin 300180, China;

2. National Engineering Research Center for Electric Drive, Tianjin 300180, China;

3. State Grid Tianjin Electric Power Company Overhaul Company, Tianjin 300250, China)

**Abstract:** According to the speed and flux estimation of induction motor in high-performance field-oriented vector control, a strong tracking filter (STF) method for speed and flux joint estimation with parameter tracking was proposed. Considering time-varying parameters and model uncertainties of induction motor, the particle swarm iterative learning dynamic optimization algorithm was used to realize online parameters tracking of induction motor, and the modified STF algorithm was used to realize speed and flux joint estimation of induction motor. Simulation results show that STF algorithm with parameter tracking can effectively estimate the speed and rotor flux of induction motor accurately. STF algorithm with parameter tracking is better than extended Kalman filter (EKF) on the estimating accuracy, tracking speed and stability, and it can quickly track jumping state, especially in the low-speed, and the state estimating accuracy and robustness against model uncertainties are improved effectively.

**Key words:** induction motor; state estimation; parameter tracking; particle swarm optimization (PSO); strong tracking filter (STF)

感应电机以其适应性强、运行可靠等优点, 在高性能传动控制领域得到越来越广泛的应用。磁场定向矢量控制可以实现感应电机的转矩与磁链解耦, 具有优越的动态控制性能, 是目前应用最广泛的控制方法<sup>[1]</sup>。在感应电机的矢量控制

系统中, 转速与磁链的闭环控制是实现磁场准确定向和高性能控制的关键, 尤其在无速度传感器控制中, 不仅要求其具有较高的转速控制精度、较快的动态响应, 而且还需要具有较强的模型鲁棒性<sup>[2-3]</sup>。随着高性能矢量控制要求的不断提高

和无速度传感器容错控制技术的发展,如何快速准确地获取感应电机的转速和磁链信息以及提高转速估计精度和磁链观测性能,显得尤为重要。许多学者对感应电机参数辨识和状态估计问题开展了大量研究,主要方法集中在改进电压-电流模型<sup>[4]</sup>、模型参考自适应<sup>[5-6]</sup>、自适应状态观测器<sup>[7-8]</sup>、扩展卡尔曼滤波器<sup>[9-11]</sup>以及人工智能<sup>[12-13]</sup>等方法。改进电压-电流模型方法在一定程度上克服了电压模型法和电流模型法的缺点,但对电机参数的鲁棒性差,属于开环系统,并且两种模型在切换过程中存在抖动。模型参考自适应方法过度依赖参考模型的准确性,电机参数的变化影响状态估计精度和控制效果,而对电机参数进行在线辨识将大大增加控制器负荷和自适应律设计难度。自适应状态观测器受电机参数变化和噪声干扰的影响较小,但磁链观测的不确定性会导致转速自适应律在全速范围内不能满足正实性,并且受电机状态方程固有极点的限制和反馈增益矩阵设计的影响,低速发电状态的转速估计性能不如高速场合,可能会出现观测器不稳定的现象<sup>[14-15]</sup>。扩展卡尔曼滤波(extended Kalman filter, EKF)算法可以有效对非线性系统进行状态估计,并且能够削弱测量噪声及随机干扰的影响,但EKF算法对电机模型不确定性和参数变化的鲁棒性较差,尤其对突变状态的跟踪可能引起不稳定<sup>[16]</sup>。

为改善感应电机由于参数变化及模型不确定性引起的转速与磁链估计性能差,尤其是对突变状态不能快速准确跟踪和低速运行时的估计精度低的问题,本文提出一种包含粒子群优化(particle swarm optimization, PSO)迭代学习参数跟踪的强跟踪滤波(strong tracking filter, STF)估计方法,针对电机参数变化及模型不确定性,采用PSO迭代学习动态优化算法实现对电机参数的在线跟踪,修正的STF算法用于实现对感应电机转速与转子磁链的高性能联合估计。与现有的自适应观测器和扩展卡尔曼滤波方法相比,包含参数跟踪的STF方法利用粒子群优化算法对电机参数进行辨识,改善因参数变化引起的模型误差,并通过引入时变渐消因子,在线调整卡尔曼增益矩阵,使残差序列保持正交,迫使STF保持对系统状态的准确跟踪<sup>[17]</sup>,提高估计精度与对突变状态的跟踪能力。最后通过仿真对比,验证了包含参数跟踪的STF算法在状态估计精度、跟踪速

度和稳定性方面的优越性。

## 1 感应电机数学模型

忽略感应电机的磁路非线性及铁损等影响,选择定子电流、转子磁链及电机转速作为状态变量,得到两相静止坐标系下离散化状态方程为

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{A}[\mathbf{x}(k)]\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k) \\ \mathbf{y}(k+1) = \mathbf{C}\mathbf{x}(k+1) + \mathbf{D}\mathbf{u}(k) \end{cases} \quad (1)$$

其中

$$\begin{aligned} \mathbf{u}(k) &= [u_{s\alpha}(k) \ u_{s\beta}(k)]^T \\ \mathbf{y}(k) &= [i_{s\alpha}(k) \ i_{s\beta}(k)]^T \\ \mathbf{x}(k) &= [i_{s\alpha}(k) \ i_{s\beta}(k) \ \Psi_{r\alpha}(k) \ \Psi_{r\beta}(k) \ \omega_r(k)]^T \end{aligned}$$

$$\mathbf{A}[\mathbf{x}(k)] = \begin{bmatrix} \mathbf{A}_{11}(k) & \mathbf{A}_{12}(k) \\ \mathbf{A}_{21}(k) & \mathbf{A}_{22}(k) \end{bmatrix}$$

$$\mathbf{B} = \begin{bmatrix} T/\sigma L_s & 0 & 0 & 0 & 0 \\ 0 & T/\sigma L_s & 0 & 0 & 0 \end{bmatrix}^T$$

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix}$$

$$\mathbf{A}_{11}(k) = \begin{bmatrix} 1 - T\xi & 0 & \frac{T\eta}{T_r} & T\eta\omega_r(k) \\ 0 & 1 - T\xi & -T\eta\omega_r(k) & \frac{T\eta}{T_r} \\ \frac{TL_m}{T_r} & 0 & 1 - \frac{T}{T_r} & -T\omega_r(k) \\ 0 & \frac{TL_m}{T_r} & T\omega_r(k) & 1 - \frac{T}{T_r} \end{bmatrix}$$

$$\mathbf{A}_{21}(k) = [-T\xi\Psi_{r\beta}(k) \ T\xi\Psi_{r\alpha}(k) \ 0 \ 0]$$

$$\mathbf{A}_{12}(k) = \mathbf{0}_{4 \times 1} \quad \mathbf{A}_{22}(k) = 1$$

$$\eta = L_m / (\sigma L_s L_r)$$

$$\xi = (R_s L_r^2 + R_r L_m^2) / (\sigma L_s L_r^2)$$

$$\zeta = 3n_p^2 L_m / (2JL_r)$$

式中: $\mathbf{u}(k)$ 为输入变量; $\mathbf{y}(k)$ 为输出变量; $\mathbf{x}(k)$ 为系统状态向量; $\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}$ 为状态方程的系数矩阵, $\mathbf{D}=\mathbf{0}$ ;  $u_s$ 为定子电压; $i_s$ 为定子电流; $\Psi_r$ 为转子磁链; $R_s, L_s$ 为定子电阻与电感; $R_r, L_r$ 为转子电阻与电感; $L_m$ 为互感; $\omega_r$ 为转子角速度; $T_r$ 为转子时间常数, $T_r = L_r / R_r$ ;  $T$ 为采样周期; $\sigma$ 为漏磁系数, $\sigma = 1 - L_m^2 / L_s L_r$ ;  $n_p$ 为极对数; $J$ 为转动惯量。

雅克比矩阵如下式:

$$\mathbf{F}[\mathbf{x}(k)] = \begin{bmatrix} \mathbf{F}_{11}(k) & \mathbf{F}_{12}(k) \\ \mathbf{F}_{21}(k) & \mathbf{F}_{22}(k) \end{bmatrix} \quad (2)$$

$$\mathbf{H}(k) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix} \quad (3)$$

其中

$$\begin{aligned}
 \mathbf{F}_{12}(k) &= \begin{bmatrix} T\eta\Psi_{\varphi\beta}(k) \\ -T\eta\Psi_{\varphi\alpha}(k) \\ -T\Psi_{\varphi\beta}(k) \\ T\Psi_{\varphi\alpha}(k) \end{bmatrix} \\
 \mathbf{F}_{21}(k) &= \begin{bmatrix} -T\zeta\Psi_{\varphi\beta}(k) \\ T\zeta\Psi_{\varphi\alpha}(k) \\ T\zeta i_{\varphi\beta}(k) \\ -T\zeta i_{\varphi\alpha}(k) \end{bmatrix}^T \\
 \mathbf{F}_{11}(k) &= \mathbf{A}_{11}(k) \\
 \mathbf{F}_{22}(k) &= \mathbf{A}_{22}(k)
 \end{aligned}$$

## 2 包含参数跟踪的强跟踪滤波方法

### 2.1 包含时变渐消因子的强跟踪滤波器

考虑非线性时变离散状态空间模型:

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{f}[k, \mathbf{u}(k), \mathbf{x}(k)] + \Gamma(k)\mathbf{w}(k) \\ \mathbf{y}(k+1) = \mathbf{h}[k+1, \mathbf{x}(k+1)] + \mathbf{v}(k+1) \end{cases} \quad (4)$$

其中,过程激励噪声  $\mathbf{w}$  和测量噪声  $\mathbf{v}$  均为不相关的零均值高斯白噪声,其协方差矩阵  $\mathbf{Q}$  和  $\mathbf{R}$  分别为对称非负定矩阵和对称正定矩阵。

具有时变渐消因子的 STF 递推算法为如下:

步骤 1: 设置初始值  $\hat{\mathbf{x}}(0|0)$ ,  $\mathbf{P}(0|0)$  以及噪声协方差矩阵  $\mathbf{Q}(k)$ ,  $\mathbf{R}(k)$ 。

步骤 2: 状态预测与输出预测如下式:

$$\hat{\mathbf{x}}(k+1|k) = \mathbf{f}[k+1, \hat{\mathbf{x}}(k|k)] \quad (5)$$

$$\hat{\mathbf{y}}(k+1) = \mathbf{h}[k+1, \hat{\mathbf{x}}(k+1|k)] \quad (6)$$

步骤 3: 计算输出残差:

$$\boldsymbol{\gamma}(k+1) = \mathbf{y}(k+1) - \mathbf{h}[k+1, \hat{\mathbf{x}}(k+1|k)] \quad (7)$$

步骤 4: 计算残差协方差矩阵:

$$\mathbf{V}(k+1) = \begin{cases} \boldsymbol{\gamma}(1)\boldsymbol{\gamma}^T(1) & k=0 \\ \frac{\rho\mathbf{V}(k) + \boldsymbol{\gamma}(k+1)\boldsymbol{\gamma}^T(k+1)}{1+\rho} & k \geq 1 \end{cases} \quad (8)$$

式中:  $\rho$  为遗忘因子,取值在 0~1 之间。

步骤 5: 计算时变次优渐消因子:

$$\lambda(k+1) = \begin{cases} \lambda_0 & \lambda_0 \geq 1 \\ 1 & \lambda_0 < 1 \end{cases} \quad (9)$$

$$\lambda_0 = \frac{\text{tr}[\mathbf{N}(k+1)]}{\text{tr}[\mathbf{M}(k+1)]} \quad (10)$$

其中

$$\begin{aligned}
 \mathbf{M}(k+1) &= \mathbf{H}(k+1)\mathbf{F}(k)\mathbf{P}(k|k) \cdot \\
 &\quad \mathbf{F}^T(k)\mathbf{H}^T(k+1)
 \end{aligned}$$

$$\begin{aligned}
 \mathbf{N}(k+1) &= \mathbf{V}(k+1) - \mathbf{H}(k+1)\mathbf{Q}(k) \cdot \\
 &\quad \mathbf{H}^T(k+1) - \beta\mathbf{R}(k+1)
 \end{aligned}$$

式中:  $\beta$  为弱化因子,用于削弱渐消因子的调节,使状态估计更加平滑;  $\text{tr}[\cdot]$  为矩阵求迹运算;  $\lambda(k+1)$  为时变渐消因子;  $\mathbf{M}(k+1)$ ,  $\mathbf{N}(k+1)$  为计算渐消因子过程中的中间变量。

步骤 6: 状态误差协方差预测:

$$\mathbf{P}(k+1|k) = \mathbf{LMD} \cdot \mathbf{F}(k)\mathbf{P}(k)\mathbf{F}^T(k) + \mathbf{Q}(k) \quad (11)$$

其中

$$\mathbf{LMD} = \text{diag}[\lambda_1(k+1), \lambda_2(k+1), \dots, \lambda_n(k+1)]$$

式中:  $\mathbf{LMD}$  为多重次优渐消因子。

步骤 7: 计算卡尔曼增益矩阵:

$$\begin{aligned}
 \mathbf{K}(k+1) &= \mathbf{P}(k+1|k)\mathbf{H}^T(k+1) \cdot \\
 &\quad [\mathbf{H}(k+1)\mathbf{P}(k+1|k)\mathbf{H}^T(k+1) + \\
 &\quad \mathbf{R}(k+1)]^{-1} \quad (12)
 \end{aligned}$$

步骤 8: 更新状态误差协方差:

$$\begin{aligned}
 \mathbf{P}(k+1) &= \{\mathbf{I} - \mathbf{K}(k+1)\mathbf{H}[k+1, \hat{\mathbf{x}}(k+1|k)]\} \cdot \\
 &\quad \mathbf{P}(k+1|k) \quad (13)
 \end{aligned}$$

步骤 9: 状态校正如下:

$$\hat{\mathbf{x}}(k+1|k+1) = \hat{\mathbf{x}}(k+1|k) + \mathbf{K}(k+1)\boldsymbol{\gamma}(k+1) \quad (14)$$

当模型不确定性和状态突变造成滤波器的状态估计偏离系统的实际状态时,必然会在输出残差序列上表现出来。STF 算法利用时变渐消因子对过去数据进行渐消,并实时调整状态误差协方差阵的预测值以及相应的增益阵,使残差序列满足下式所示的正交性,迫使强跟踪滤波器保持对系统实际状态的准确跟踪。

$$\begin{cases} \mathbf{E}[\mathbf{x}(k) - \hat{\mathbf{x}}(k|k)][\mathbf{x}(k) - \hat{\mathbf{x}}(k|k)]^T = \min \\ \mathbf{E}[\boldsymbol{\gamma}(k+j)\boldsymbol{\gamma}^T(k)] = 0 \quad k=0,1,2,\dots; j=1,2,\dots \end{cases} \quad (15)$$

### 2.2 基于 PSO 迭代学习动态优化算法的参数跟踪

PSO 迭代学习动态优化算法是一类基于群智能的随机全局优化进化算法,该算法以其实现容易、精度高、收敛速度快和适应性强等优点得到广泛应用<sup>[18]</sup>。在 PSO 算法中,种群中的每个粒子代表寻优空间中的一个潜在解,适应值由被优化的函数决定,粒子群通过个体间的协作竞争与学习进化,实现多维空间中最优解的搜索。在每次迭代进化中,粒子通过自身和群体的历史最优位置,更新当前的速度和位置。在任意  $k+1$  时刻,第  $i$  个粒子的速度和位置更新公式为

$$\begin{cases} v_{id}(k+1) = \chi \{ wv_{id}(k) + c_1 r_{1d}(k) [p_{id} - x_{id}(k)] + \\ c_2 r_{2d}(k) [p_{gd} - x_{id}(k)] \} \\ v_{id}(k) = \min \{ v_{\max}(k), \max [v_{\min}(k), v_{id}(k)] \} \\ x_{id}(k+1) = x_{id}(k) + v_{id}(k+1) \end{cases} \quad (16)$$

式中:  $d$  为解空间的维数;  $i$  为种群规模,  $i = 1, 2, \dots, N$ ;  $v_{id}, x_{id}$  分别为第  $i$  个粒子的速度和位置;  $\chi$  为限制因子;  $w$  为惯性权重因子;  $c_1$  为认知加速因子, 所在项表征粒子自身的学习进化;  $c_2$  为社会加速因子, 所在项表征粒子之间的信息共享与合作;  $p_{id}, p_{gd}$  分别为个体和群体的历史最优位置;  $r_{1d}, r_{2d}$  为两个相互独立的服从  $[0, 1]$  均匀分布的随机数。

该粒子所经历的历史最后位置的函数值为  $p_{best i}$ , 粒子群所经历的历史最优位置对应的函数值为  $g_{best}$ 。

设置最大迭代次数为  $iter_{\max}$ , 当前迭代次数为  $iter$ , 惯性权重  $w$  随迭代次数线性下降:

$$w(k) = w_{\max} - \frac{w_{\max} - w_{\min}}{iter_{\max}} iter \quad (17)$$

限制因子  $\chi$  取:

$$\chi = \frac{2}{|2 - \phi - \sqrt{\phi^2 - 4\phi}|} \quad (18)$$

其中  $\phi = c_1 + c_2$

构建适应度函数为

$$f_p = \sum_{k=1}^N \{ [\hat{i}_s(k) - \hat{i}_s(k)]^2 + \gamma [\omega_r(k) - \hat{\omega}_r(k)]^2 \} \quad (19)$$

其中, 罚因子  $\gamma$  表示适应度函数中转速分量与定子电流分量的权重。

PSO 迭代学习动态优化算法通过构造与被控对象具有相似结构的可调感应电机模型, 计算辨识模型与参考系统的输出残差, 通过适应度函数进行评价, 利用适应度评价对可调模型中待辨识参数进行修正, 不断重复迭代学习过程, 直到模型输出的性能指标达到最优或者到达最大迭代次数, 从而实现了对感应电机的参数跟踪。

### 3 仿真结果

为验证包含参数跟踪的 STF 状态估计算法的有效性, 构建如图 1 所示的感应电机矢量控制系统, 并进行系统仿真。其中, PSO 参数跟踪部分用于对感应电机定子参数与转动惯量进行跟踪, STF 状态估计部分用于对感应电机的转速与转子

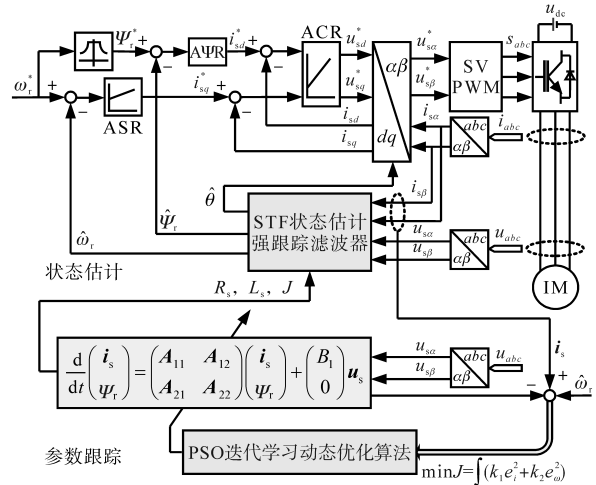


图1 包含参数跟踪 STF 算法的感应电机矢量控制系统

Fig.1 FOC system of induction motor with parameter tracking and STF

磁链进行联合估计, 参数跟踪辨识出的电机参数值用于修正 STF 算法中的系数矩阵。设置定子电阻  $R_s=1.54 \Omega$ , 定子电感  $L_s=0.1004 \text{ H}$ , 转子电阻  $R_r=1.294 \Omega$ , 转子电感  $L_r=0.0969 \text{ H}$ , 励磁电感  $L_m=0.0915 \text{ H}$ , 转动惯量  $J=0.15 \text{ kg} \cdot \text{m}^2$ 。

考虑感应电机的转动惯量与定子参数变化及模型不确定性, 构造与电机动态模型相同结构的被辨识模型, 以被控模型和辨识模型的输出残差加权平方和的积分作为优化指标, 采用 PSO 迭代学习动态优化算法对感应电机定子电阻  $R_s$ 、定子电感  $L_s$  及转动惯量  $J$  进行在线跟踪。PSO 算法设置种群规模为  $N = 50$ , 最大迭代次数为  $iter_{\max} = 200$ , 惯性权重系数  $w_{\max} = 0.9, w_{\min} = 0.4$ , 加速因子  $c_1=c_2=2.05$ , 限制因子  $\chi = 0.73$ , 罚因子  $\gamma = 0.2$ 。在迭代次数为  $iter = 50$  时, 转动惯量  $J$  突变为初始值的 1.2 倍, 定子电阻  $R_s$  突变为初始值的 1.25 倍, 定子电感  $L_s$  突变为初始值的 1.2 倍。

图 2 为 PSO 迭代学习动态优化算法结束时粒子群分布与最优适应度函数值  $g_{best}$ 。图 3 为迭代优化得到的感应电机转动惯量  $J$ 、定子电阻  $R_s$  与定子电感  $L_s$  以及包含扰动的参数跟踪波形。从图中可以看出, PSO 迭代学习动态优化算法具有较好的参数跟踪性能和较高的稳态精度。

在 STF 状态估计部分, 采用时变次优渐消因子对滤波算法中的过去数据渐消, 实时调整状态预测误差协方差阵及 Kalman 滤波增益阵, 实现对状态的精确实时估计。系统初始误差协方差阵  $P(0|0)$ 、噪声协方差阵  $Q$  和  $R$  的取值影响 STF 的估计性能,  $Q$  取值过小会对突变状态的跟踪存在






图2 PSO迭代优化结果与粒子群分布  
Fig.2 PSO iterative optimization results and particle swarm distribution




图3 感应电机参数PSO辨识结果  
Fig.3 Results of parameters identification of IM with PSO

滞后,  $Q$  取值过大会导致稳态精度和抗扰能力下降。综合考虑算法的动态性能、收敛速度及稳定性, 本文中取初始  $P(0|0) = \text{diag}(10^{-6}I_4, 10^{-4}I_1)$ ,  $Q = \text{diag}(2 \times 10^{-6}I_4, 5 \times 10^{-5}I_1)$ ,  $R = 3 \times 10^{-2}I_2$ , 遗忘因子  $\rho = 0.95$ , 弱化因子  $\beta = 1.2$ 。仿真初始给定转速为 2 rad/s, 在 2 s 时阶跃增至 80 rad/s, 在仿真时间 2~6 s 内, 转速为 80 rad/s; 在 6 s 时阶跃降至 50 rad/s。为验证 STF 算法的鲁棒性, 仿真中设置随机干扰噪声及测量噪声, 以及负载扰动, STF 对包含随机噪声负载转矩的估计结果如图 4 所示。




图4 随机扰动负载转矩及STF估计结果  
Fig.4 Results of load torque STF estimation with stochastic disturbance

电机转速与转子磁链的 STF 估计结果如下: 图 5 为感应电机转速估计仿真波形, 可以看出, EKF 和 STF 两种估计算法均具有较好的估计性能, 并对电机参数变化具有较强的鲁棒性。将其其中极低速段、中速段以及过渡段的转速估计波形放大, 如图 6~图 8 所示, STF 算法具有更高的转速估计精度和对突变状态的跟踪能力, 尤其在低速段的跟踪能力与估计精度明显优于 EKF 算法, 并对负载扰动具有较强的鲁棒性。图 9 为定子电压、定子电流波形, 可以看出, 转速过渡段的电压、电流切换较为平滑, 定子电流的 STF 估计精度较好。




图5 全速域内转速估计仿真结果  
Fig.5 Simulation results of speed estimation at all-speeds




图6 极低速段转速估计结果  
Fig.6 Results of speed estimation at very-low speed




图7 中速段转速估计结果  
Fig.7 Results of speed estimation at medium speed

图 10 为感应电机转子磁链估计仿真波形, 可见, EKF 与 STF 两种估计算法在中、高转速段的估计效果较好, 在低速段的转子磁链估计误差较大。图 11~图 13 分别是在极低速段、中速段以及转速过渡段的转子磁链估计放大波形。在极低转速段, STF 与 EKF 的估计精度较差, 但 STF 算法




图8 转速阶跃过渡段转速估计结果

Fig.8 Results of speed estimation with speed step

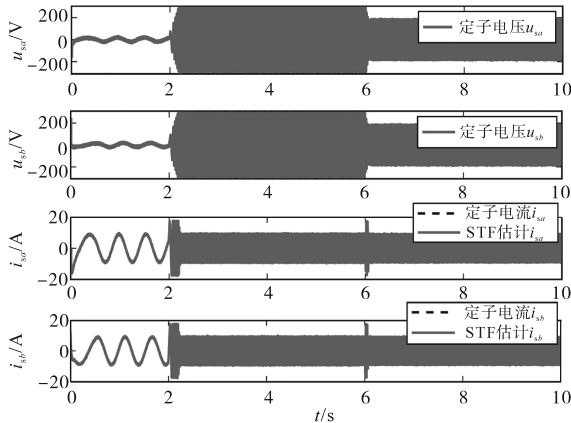


图9 定子电压与定子电流波形

Fig.9 Waveforms of stator voltages and stator currents

能够快速跟踪参考磁链波形,动态性能优于EKF。在高速段与中速段,STF与EKF均具有较高的稳态估计精度,相对参考磁链稳态误差在2%以内。在转速阶跃过渡段,EKF算法对突变状态的跟踪不稳定,而STF算法能够快速跟踪磁链,并具有较好的动态性能和跟踪精度。




图10 全速域内转子磁链估计仿真结果

Fig.10 Simulation results of rotor flux estimation at all-speeds




图11 极低速段转子磁链估计结果

Fig.11 Results of rotor flux estimation at very-low speed




图12 中速段转子磁链估计结果

Fig.12 Results of rotor flux estimation at medium speed




图13 转速阶跃过渡段转子磁链估计结果

Fig.13 Results of rotor flux estimation with speed step

## 4 结论

本文提出了包含参数跟踪的感应电机转速与磁链联合估计的STF方法,针对电机参数变化及模型不确定性,采用PSO迭代学习动态优化算法实现对电机参数的在线跟踪,修正的STF算法用于实现对感应电机状态的联合估计。仿真结果表明,STF能够有效实现对感应电机转速与转子磁链的高性能估计。与EKF相比,包含参数跟踪的STF算法在估计精度、跟踪速度和稳定性方面均得到大幅度改善,并且能够快速跟踪突变状态,尤其在低速段仍能保持较好的估计性能,有效提高了状态估计精度和算法鲁棒性。

## 参考文献

- [1] Bimal K Bose. 现代电力电子学与交流传动[M]. 王聪,赵金,于庆广,等,译. 北京:机械工业出版社,2013.
- [2] 李永东,李明才. 感应电机高性能无速度传感器控制系统——回顾、现状与展望[J]. 电气传动,2004, 34(1): 4-10.
- [3] Xu D, Wang B, Zhang G, et al. A review of sensorless control methods for AC motor drives[J]. CES Transactions on Electrical Machines and Systems, 2018, 2(1): 104-115.
- [4] 陈振锋,钟彦儒,李洁,等. 基于改进磁链观测器的感应电机转速辨识[J]. 电工技术学报,2012, 27(4): 42-48.
- [5] 王高林,于泳,陈伟,等. 基于改进MRAS观测器无速度传感器感应电机转速估计方法[J]. 电气传动,2009, 39(1): 15-18.
- [6] Zbde Y B, Gadoue S M, Atkinson D J. Model predictive

- MRAS estimator for sensorless induction motor drives[J]. IEEE Transactions on Industrial Electronics, 2016, 63(6): 3511-3521.
- [7] 赵金,杨坤. 基于自适应观测器的感应电机无速度传感器矢量控制[J]. 电气传动, 2013, 43(10): 14-17.
- [8] 吴文进,苏建徽,刘鹏,等. 感应电机全阶磁链观测器设计及其控制性能对比分析[J]. 电机与控制学报, 2016, 20(4): 78-92.
- [9] Shi K L, Chan T F, Wong Y K, *et al.* Speed estimation of an induction motor drive using an optimized extended Kalman filter[J]. IEEE Transactions on Industry Electronics, 2002, 49(1): 124-133.
- [10] 杨文强,李树广,贾正春. 基于降阶推广卡尔曼滤波算法的交流感应电动机无速度传感器矢量控制系统[J]. 上海交通大学学报, 2003, 37(9): 1362-1365.
- [11] 李洁,钟彦儒. 无轨迹卡尔曼滤波器在感应电机转速估计中的应用研究[J]. 电工技术学报, 2006, 21(2): 45-50.
- [12] Kim S, Park T, Yoo J, *et al.* Speed-sensorless vector control of an induction motor using neural network speed estimation[J]. IEEE Transactions on Industry Electronics, 2001, 48(3): 609-614.
- [13] 尹忠刚,肖鹭,孙向东,等. 基于粒子群优化的感应电机模糊扩展卡尔曼滤波器转速估计方法[J]. 电工技术学报, 2016, 31(6): 55-65.
- [14] 陈伟,于泳,杨荣峰,等. 感应电机自适应全阶观测器算法低速稳定性研究[J]. 中国电机工程学报, 2010, 30(36): 33-40.
- [15] 宋文祥,周杰,朱洪志,等. 基于自适应全阶观测器的感应电机低速发电运行稳定性[J]. 电工技术学报, 2014, 29(3): 197-205.
- [16] 陆可. 基于强跟踪滤波算法的异步电机参数自适应无速度传感器控制[J]. 电机与控制应用, 2011, 38(5): 16-21.
- [17] 周东华,席裕庚,张钟俊. 一种带多重次优渐消因子的扩展卡尔曼滤波器[J]. 自动化学报, 1991, 17(6): 689-695.
- [18] Liang J, Qin K, Suganthan P N, *et al.* Comprehensive learning particle swarm optimizer for global optimization of multimodal functions[J]. IEEE Transactions on Evolutionary Computation, 2006, 10(3): 281-295.

收稿日期:2020-01-13

修改稿日期:2020-03-05