

文章编号: 1001-0920(2014)09-1667-06

DOI: 10.13195/j.kzyjc.2013.0715

基于多渐消因子强跟踪UKF和约束AR模型的故障估计与预测

杜占龙, 李小民

(军械工程学院 无人机工程系, 石家庄 050003)

摘要: 针对非线性系统中不可观测故障参数估计和预测问题, 提出一种基于多重渐消因子强跟踪无迹卡尔曼滤波(MSTUKF)的状态和参数联合估计法, 通过引入多重渐消因子增强了对变化函数未知的故障参数的跟踪能力. 对于得到的故障参数估计值, 利用递推最小二乘法更新约束AR预测模型, 从而实现故障参数的在线估计与预测. 仿真结果表明, MSTUKF方法在故障参数估计精度上优于UKF和单渐消因子强跟踪UKF, 约束AR模型的预测精度高于无约束条件下的预测精度.

关键词: 强跟踪滤波; 状态和参数联合估计; AR预测模型; 约束

中图分类号: TP206+.3

文献标志码: A

Fault estimation and prediction based on multiple fading factors strong tracking UKF and constrained AR model

DU Zhan-long, LI Xiao-min

(Department of UAV Engineering, Ordnance Engineering College, Shijiazhuang 050003, China. Correspondent: DU Zhan-long, E-mail: misky110@tom.com)

Abstract: For the unmeasured fault parameters estimation and prediction problem of nonlinear systems, the state and parameter joint estimation algorithm based on multiple fading factors strong tracking unscented Kalman filter(MSTUKF) is presented. Multiple fading factors of MSTUKF are introduced to improve the tracking ability for fault parameters with the unknown changing function. With the fault parameters estimation of MSTUKF, the constrained AR prediction model is updated by recursive least squares. Online estimation and prediction of fault parameters are realized by using the proposed method. Simulation results show that the fault parameters estimation ability of MSTUKF is better than that of UKF and single fading factor strong tracking UKF, and the predicting accuracy of constrained AR model is superior to the unconstrained AR model.

Key words: strong tracking filter; state and parameter joint estimation; AR predicting model; constraint

0 引言

通常情况下, 系统的故障参数不能被直接测量, 而且故障参数的变化模型往往是未知的. 状态和参数联合滤波法^[1]将故障参数扩展为状态变量, 利用系统的输出测量值间接估计和预测故障参数, 从而实现系统的故障诊断与预测.

扩展卡尔曼滤波(EKF)是目前应用最广泛的非线性滤波器, 文献[2-3]将模型故障参数扩展为状态变量, 利用EKF估计故障参数. 对于非线性较强的系统, EKF容易引入较大误差, 为此, 相继提出了无迹卡尔曼滤波(UKF)和粒子滤波(PF). 文献[4]利用PF进

行检测并隔离故障, 但PF存在计算量大、粒子贫化和重要性密度函数选择等问题. 文献[5]提出的UKF不需要对非线性模型进行线性化计算, 理论^[6]和实验^[7-8]均已证明, UKF的估计精度优于EKF. 文献[8]利用UKF对鼠笼型感应电动机的状态变量进行在线估计, 实现了故障检测.

实际系统通常具有不同程度的不确定性, 尤其对于故障参数变化函数未知的情况. 上述非线性滤波对于故障参数的估计精度不高, 甚至可能发散. 文献[9]提出强跟踪滤波理论, 通过在预测协方差阵中引入渐消因子, 实时调整滤波过程中的增益矩阵, 使

收稿日期: 2013-06-02; 修回日期: 2013-11-11.

作者简介: 杜占龙(1986-), 男, 博士生, 从事故障诊断、故障预测的研究; 李小民(1968-), 男, 教授, 博士生导师, 从事性能检测、故障诊断等研究.

其具有较强的模型失配的鲁棒性. 文献[10]采用强跟踪EKF对故障参数进行估计. 文献[11]采用强跟踪模糊集EKF对故障参数进行多步预测. 同样为了克服强跟踪EKF在非线性较强情况下的不足, 文献[12]提出了强跟踪UKF(STUKF). 文献[13]采用STUKF对状态变量进行估计, 仿真结果表明STUKF的滤波精度高于UKF和强跟踪EKF. 以上强跟踪滤波算法都是采用单一渐消因子对所有状态估计值进行修正. 然而, 系统模型的不确定性对不同状态的影响是不相同的, 仅采用单一渐消因子时, 无法保证对每个变量都具有好的跟踪能力.

为了解决单渐消因子的局限性, 文献[14]提出了带多重渐消因子的EKF. 本文在文献[14]和单渐消因子STUKF^[12]的基础上, 提出带多重渐消因子的强跟踪UKF. 对于故障参数预测问题, 虽然滤波中的时间更新过程能够对状态和参数进行预测, 但是对于扩维成状态变量的故障参数而言, 由于故障参数的状态函数未知, 使得利用时间更新过程得到的预测值精度较低. 为此, 本文首先利用提出的MSTUKF对故障参数进行估计, 然后利用AR模型对估计值组成的时间序列进行预测, 同时为了降低AR模型的不确定性, 采用约束映射法修正AR模型预测值. 三容水箱模型的仿真结果验证了本文方法的有效性.

1 单渐消因子STUKF

考虑如下所示非线性离散系统:

$$\begin{cases} \mathbf{x}_{k+1} = f_k(\mathbf{x}_k) + \mathbf{w}_k, \\ \mathbf{z}_{k+1} = h_{k+1}(\mathbf{x}_{k+1}) + \mathbf{v}_{k+1}. \end{cases} \quad (1)$$

其中: $\mathbf{x}_k \in \mathbf{R}^n$ 和 $\mathbf{z}_k \in \mathbf{R}^m$ 分别为状态向量和量测向量; $f_k(\cdot)$ 和 $h_k(\cdot)$ 分别为状态函数和量测函数; \mathbf{w}_k 和 \mathbf{v}_k 分别为均值是 \mathbf{q}_k 和 \mathbf{r}_k 、协方差为 \mathbf{Q}_k 和 \mathbf{R}_k 的互不相关高斯白噪声, 且 \mathbf{Q}_k 和 \mathbf{R}_k 均为正定对称阵. 基于模型(1)的STUKF算法流程如下^[12].

1) 确定初始 $\hat{\mathbf{x}}_{0|0}$, $\mathbf{P}_{0|0}$.

2) 选择UT变换中Sigma点采样策略. 采用对称采样策略^[7]计算Sigma采样点 ξ_i 和对应的权值 W_i , $i = 0, 1, \dots, 2n$.

3) 时间更新过程

$$\gamma_{i,k+1|k} = f_k(\xi_{i,k|k}) + \mathbf{q}_k, \quad (2)$$

$$\hat{\mathbf{x}}_{k+1|k} = \sum_{i=0}^{2n} W_i \gamma_{i,k+1|k}, \quad (3)$$

$$\mathbf{P}_{k+1|k}^* = \sum_{i=0}^{2n} W_i (\gamma_{i,k+1|k} - \hat{\mathbf{x}}_{k+1|k}) \times (\gamma_{i,k+1|k} - \hat{\mathbf{x}}_{k+1|k})^T + \mathbf{Q}_k, \quad (4)$$

其中 $\xi_{i,k|k}$ 为由 $\hat{\mathbf{x}}_{k|k}$ 和 $\mathbf{P}_{k|k}$ 所构造的Sigma采样点.

对于STUKF, 在状态预测协方差阵 $\mathbf{P}_{k+1|k}^*$ 中引入渐消因子 λ_{k+1} , 相比于式(4)可知

$$\mathbf{P}_{k+1|k} = \lambda_{k+1} \sum_{i=0}^{2n} W_i (\gamma_{i,k+1|k} - \hat{\mathbf{x}}_{k+1|k}) \times (\gamma_{i,k+1|k} - \hat{\mathbf{x}}_{k+1|k})^T + \mathbf{Q}_k. \quad (5)$$

4) 量测更新过程

$$\boldsymbol{\eta}_{i,k+1|k}^* = h_{k+1}(\xi_{i,k+1|k}^*) + \mathbf{r}_{k+1}, \quad (6)$$

$$\hat{\mathbf{z}}_{k+1|k} = \sum_{i=0}^{2n} W_i \boldsymbol{\eta}_{i,k+1|k}^*, \quad (7)$$

$$\mathbf{P}_{\tilde{\mathbf{z}}_{k+1}}^* = \sum_{i=0}^{2n} W_i (\boldsymbol{\eta}_{i,k+1|k}^* - \hat{\mathbf{z}}_{k+1|k}) \times (\boldsymbol{\eta}_{i,k+1|k}^* - \hat{\mathbf{z}}_{k+1|k})^T + \mathbf{R}_{k+1}, \quad (8)$$

$$\mathbf{P}_{\tilde{\mathbf{x}}_{k+1} \tilde{\mathbf{z}}_{k+1}}^* = \sum_{i=0}^{2n} W_i (\xi_{i,k+1|k}^* - \hat{\mathbf{x}}_{k+1|k}) \times (\boldsymbol{\eta}_{i,k+1|k}^* - \hat{\mathbf{z}}_{k+1|k})^T, \quad (9)$$

其中 $\xi_{i,k+1|k}^*$ 为由 $\hat{\mathbf{x}}_{k+1|k}$ 和未引入渐消因子的 $\mathbf{P}_{k+1|k}^*$ 构造的Sigma采样点.

利用 $\mathbf{P}_{\tilde{\mathbf{z}}_{k+1}}^*$ 和 $\mathbf{P}_{\tilde{\mathbf{x}}_{k+1} \tilde{\mathbf{z}}_{k+1}}^*$ 计算渐消因子 λ_{k+1} ^[12], 将 λ_{k+1} 代入式(5)求得 $\mathbf{P}_{k+1|k}$, 再利用 $\hat{\mathbf{x}}_{k+1|k}$ 和 $\mathbf{P}_{k+1|k}$ 计算 $\xi_{i,k+1|k}$. 将 $\xi_{i,k+1|k}$ 代入式(6)得到 $\boldsymbol{\eta}_{i,k+1|k}$, 然后利用式(7)~(9)计算引入渐消因子后的 $\mathbf{P}_{\tilde{\mathbf{z}}_{k+1}}$ 和 $\mathbf{P}_{\tilde{\mathbf{x}}_{k+1} \tilde{\mathbf{z}}_{k+1}}$. 在获得新的量测 \mathbf{z}_{k+1} 后, 有

$$\hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k|k} + \mathbf{K}_{k+1}(\mathbf{z}_{k+1} - \hat{\mathbf{z}}_{k+1|k}), \quad (10)$$

$$\mathbf{K}_{k+1} = \mathbf{P}_{\tilde{\mathbf{x}}_{k+1} \tilde{\mathbf{z}}_{k+1}} \mathbf{P}_{\tilde{\mathbf{z}}_{k+1}}^{-1}, \quad (11)$$

$$\mathbf{P}_{k+1|k+1} = \mathbf{P}_{k+1|k} - \mathbf{K}_{k+1} \mathbf{P}_{\tilde{\mathbf{z}}_{k+1}} \mathbf{K}_{k+1}^T. \quad (12)$$

2 多重渐消因子MSTUKF

系统的不确定性对不同状态变量的影响不同, 采用单渐消因子不能保证对每个变量都具有好的跟踪性能. 若采用多个渐消因子, 分别对不同的状态估计进行调整, 则能提高滤波的强跟踪能力. 文献[14]提出了一种带多重渐消因子的强跟踪EKF(MSTEKF), 本文将其引入强跟踪UKF算法, 实现了带多重渐消因子的强跟踪UKF(MSTUKF).

对于MSTUKF, 需要将式(5)修改为

$$\mathbf{P}_{k+1|k} = \zeta_{k+1} \sum_{i=0}^{2n} W_i (\gamma_{i,k+1|k} - \hat{\mathbf{x}}_{k+1|k}) \times (\gamma_{i,k+1|k} - \hat{\mathbf{x}}_{k+1|k})^T + \mathbf{Q}_k, \quad (13)$$

其中: $\zeta_{k+1} = \text{diag}[\zeta_{k+1}^1, \zeta_{k+1}^2, \dots, \zeta_{k+1}^n]$ 为渐消因子矩阵, $\zeta_{k+1}^i \geq 1$ ($i = 1, 2, \dots, n$) 分别为对应于每个状态的渐消因子.

1) MSTUKF中多重渐消因子次优求解算法.

MSTEKF中 ζ_{k+1} 次优求解算法如下^[14]:

$$\zeta_{k+1}^i = \begin{cases} \alpha_i c_{k+1}, & \alpha_i c_{k+1} > 1 \\ 1, & \alpha_i c_{k+1} \leq 1 \end{cases}, c_{k+1} = \frac{\text{tr}[N_{k+1}]}{\sum_{i=1}^n \alpha_i M_{k+1}^i}; \quad (14)$$

$$N_{k+1} = V_{k+1} - H_{k+1} Q_k H_{k+1}^T - R_{k+1}; \quad (15)$$

$$M_{k+1} = F_{k+1|k} P_{k|k} F_{k+1|k}^T H_{k+1}^T H_{k+1}; \quad (16)$$

$$V_{k+1} = \begin{cases} e_1 e_1^T, & k=0; \\ \frac{\rho V_k + e_{k+1} e_{k+1}^T}{1+\rho}, & k \geq 1; \end{cases} \quad (17)$$

$$\frac{\partial f}{\partial \hat{x}_{k|k}} = F_{k+1|k}, \quad \frac{\partial h}{\partial \hat{x}_{k+1|k}} = H_{k+1}. \quad (18)$$

其中: $\alpha_i \geq 1$, $e_{k+1} = z_{k+1} - \hat{z}_{k+1|k}$, $0 < \rho \leq 1$. 如果 x_i 的状态函数误差较大或者 x_i 的变化较快, 则选择较大的 α_i , 否则可以令 α_i 均为 1, 此时 MSTEFK 退化为 STEKF.

2) MSTUKF 中多重渐消因子次优求解.

根据 MSTEFK 中 ζ_{k+1} 次优求解算法, 推导 MSTUKF 中 ζ_{k+1} 次优求解算法如下.

由 $x_{k+1} - \hat{x}_{k+1|k}$ 与噪声 v_{k+1} 的互不相关性^[12] 可得

$$P_{\hat{x}_{k+1} \tilde{z}_{k+1}}^* = P_{k+1|k}^* H_{k+1}^T. \quad (19)$$

前面已经假设 Q_k 为正定对称阵, 故 $P_{k+1|k}^*$ 的逆矩阵一定存在, 由式 (19) 可得

$$H_{k+1} = [P_{\hat{x}_{k+1} \tilde{z}_{k+1}}^*]^{-1} [P_{k+1|k}^*]^{-1}. \quad (20)$$

将式 (20) 代入 (15) 可得

$$N_{k+1} = V_{k+1} - [P_{\hat{x}_{k+1} \tilde{z}_{k+1}}^*]^{-1} [P_{k+1|k}^*]^{-1} Q_k \times [P_{k+1|k}^*]^{-1} P_{\hat{x}_{k+1} \tilde{z}_{k+1}}^* - R_{k+1}. \quad (21)$$

对于式 (16) 中的 $F_{k+1|k} P_{k|k} F_{k+1|k}^T$, 显然有

$$P_{k+1|k}^* = F_{k+1|k} P_{k|k} F_{k+1|k}^T + Q_k. \quad (22)$$

将式 (20) 和 (22) 代入 (16) 可得

$$M_{k+1} = (P_{k+1|k}^* - Q_k) [P_{k+1|k}^*]^{-1} \times P_{\hat{x}_{k+1} \tilde{z}_{k+1}}^* [P_{\hat{x}_{k+1} \tilde{z}_{k+1}}^*]^{-1} [P_{k+1|k}^*]^{-1}. \quad (23)$$

将式 (21) 和 (23) 代入 (14), 即可计算 MSTUKF 中 ζ_{k+1} . 其中 $P_{k+1|k}^*$ 、 $P_{\hat{x}_{k+1} \tilde{z}_{k+1}}^*$ 分别按式 (4) 和 (9) 计算.

3 约束条件下 AR 预测模型

3.1 AR 模型

AR 预测模型可表述为

$$\theta_{k+1} = a_{p-1,k} \theta_{k-p+1} + a_{p-2,k} \theta_{k-p+2} + \dots + a_{0,k} \theta_k + \varepsilon_k. \quad (24)$$

其中: $\theta_{k-p+1:k} = [\theta_{k-p+1}, \theta_{k-p+2}, \dots, \theta_k]^T$ 为故障参数时间序列, θ_{k+1} 为 $k+1$ 时刻预测值, $a_k = [a_{p-1,k}, a_{p-2,k}, \dots, a_{0,k}]$ 为自回归系数, ε_k 为模型误差, p 为

模型阶数. 采用递推最小二乘法更新 AR 模型.

3.2 约束条件下预测

上述 AR 模型的一个缺点是不能将约束条件融入预测中, 为提高预测精度, 可将已知的变化趋势转化为约束条件, 采用约束映射法, 使得 AR 模型预测值满足已知的约束条件. 约束映射公式如下:

$$\tilde{\theta}_{k+1} = \arg \min_{\theta} (\theta - \hat{\theta}_{k+1})^T W (\theta - \hat{\theta}_{k+1}); \quad (25)$$

$$\text{s.t. } A(\theta) = 0, B(\theta) \geq 0.$$

其中: $\hat{\theta}_{k+1}$ 为无约束预测值, $A(\theta)$ 和 $B(\theta)$ 分别为等式和不等式约束条件. 在具体求解中, 将式 (25) 转化为二次规划求解 θ 最小值, 变换得二次规划标准型为

$$\tilde{\theta}_{k+1} = \arg \min_{\theta} \{ \theta^T W \theta - [(W \hat{\theta}_{k+1})^T + \hat{\theta}_{k+1}^T W] \theta \}, \quad (26)$$

$W = (\sigma_k^2)^{-1}$, σ_k^2 为预测误差的方差.

需要指出, 不合适的约束条件会让预测结果变差. 实际中若无法得知故障过程的约束信息, 则不采用约束 AR 模型, 而直接采用无约束的 AR 模型进行预测.

4 故障参数估计与预测

4.1 状态与参数联合估计

为了同时估计参数, 将式 (1) 扩展为如下形式:

$$\begin{cases} x_{k+1}^e = \begin{bmatrix} x_{k+1} \\ \theta_{k+1} \end{bmatrix} = \begin{bmatrix} f_k(x_k, \theta_k) \\ \theta_k \end{bmatrix} + \begin{bmatrix} w_k \\ d_k \end{bmatrix}, \\ z_{k+1} = h_{k+1}(x_{k+1}^e) + v_{k+1}. \end{cases} \quad (27)$$

其中: $\theta_k = [\theta_k^1, \theta_k^2, \dots, \theta_k^l]^T$ 为需要估计的时变故障参数向量, l 为故障参数个数, 由于故障参数的状态函数未知, 引入辅助状态函数 $\theta_{k+1} = \theta_k$, 其他各状态变量与非线性离散系统 (1) 相同; d_k 为故障参数噪声.

4.2 故障检测与隔离

在进行故障参数估计和预测前, 需要确定故障发生时间 (故障检测) 和位置 (故障隔离). 根据文献 [4] 的多滤波器并行结构和文献 [15] 的残差 χ^2 检验法, 首先建立式 (1) 所示的无扩展参数的模型 U_0 , 利用 χ^2 检验法判断 MSTUKF 的残差是否异常, 若异常则判断系统出现故障, 继而转入隔离环节. 分别将所有 N 种可能出现故障的参数扩展为状态变量, 建立式 (27) 所示的模型 U_1, U_2, \dots, U_N , 若实际故障与假设不符, 则 U_i 的 MSTUKF 残差将会出现异常, 当所有 $N-1$ 个模型残差均检测出异常时, 即能确定发生故障的参数.

4.3 故障概率计算

对于故障参数估计值 $\hat{\theta}_{k|k}^j$ 和预测值 $\hat{\theta}_{k+t|k}^j$, t 为预测步数, $j = 1, 2, \dots, l$, 计算参数故障概率公式为^[16]

$$\text{Prob}\{\hat{\theta}_k^j \in s_2\} = \frac{\hat{\theta}_k^j - U(s_1)}{U(s_2) - U(s_1)}. \quad (28)$$

其中: $\hat{\theta}_k^j = \hat{\theta}_{k|k}^j$ 或 $\hat{\theta}_{k+t|k}^j$, s_1 和 s_2 分别表示参数 $\hat{\theta}_k^j$ 处于正常和故障状态, $U(s_1)$ 和 $U(s_2)$ 分别为 $\hat{\theta}_k^j$ 正常和故障状态对应的值.

4.4 故障参数估计与预测流程

基于 MSTUKF 和约束 AR 模型的故障参数估计与预测算法如下.

Step 1: 按照 4.2 节的方法确定发生故障的参数后, 转入 Step 2, 否则不跳转.

Step 2: 进行 MSTUKF 时间更新过程, 利用式 (3) 和 (4) 计算 $\hat{\mathbf{x}}_{k+1|k}^e$ 和协方差 $\mathbf{P}_{k+1|k}^*$.

Step 3: 利用 $\hat{\mathbf{x}}_{k+1|k}^e$ 、 $\mathbf{P}_{k+1|k}^*$ 、式 (6)~(9)、(14)、(21) 和 (23) 计算渐消因子 ζ_{k+1} , 代入式 (13) 计算 $\mathbf{P}_{k+1|k}$.

Step 4: 估计. 利用 $\mathbf{P}_{k+1|k}$ 和量测更新过程计算 $\hat{\mathbf{x}}_{k|k}^e$. 将 $\hat{\mathbf{x}}_{k|k}^e$ 中的故障参数 $\hat{\theta}_{k|k}^j$ 存入时间序列 $\hat{\theta}_{1:k}^j = [\hat{\theta}_{1|1}^j, \hat{\theta}_{2|2}^j, \dots, \hat{\theta}_{k|k}^j]^T$, $j = 1, 2, \dots, l$, 并代入式 (28) 计算 k 时刻故障概率, 当故障概率超过设定阈值时, 判定系统故障, 否则进入下一步.

Step 5: 预测. 利用 $\hat{\theta}_{k|k}^j$ 更新 AR 模型, 计算一步预测值 $\hat{\theta}_{k+1|k}^j$, 然后将 $\hat{\theta}_{k+1|k}^j$ 代入式 (26) 得到约束条件下的 $\hat{\theta}_{k+1|k}^j$. 对于多步预测, 重复将式 (26) 的输出作为下一步预测的输入, 得到多步预测值 $\hat{\theta}_{k+t|k}^j$, 计算 $k+t$ 时刻的故障概率, 当故障概率超过设定阈值时, 发出故障预警, 否则直接进入下一步.

Step 6: 返回 Step 2 进行下一步估计和预测.

5 仿真实例

5.1 仿真模型

本文采用三容水箱系统作为仿真实例^[17]. 系统离散化模型如下:

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{x}_k + \Delta t \cdot \mathbf{A} \mathbf{x}_k + \Delta t \cdot \mathbf{B} \cdot \mathbf{u}_k + \mathbf{w}_k, \\ \mathbf{z}_{k+1} = \mathbf{x}_{k+1} + \mathbf{v}_{k+1} = [x_{1,k+1} \ x_{2,k+1} \ x_{3,k+1}]^T + \mathbf{v}_{k+1}. \end{cases} \quad (29)$$

其中

$$\mathbf{u}_k = \begin{bmatrix} Q_1 \\ Q_2 \end{bmatrix}, \quad \mathbf{A} \mathbf{x}_k = \frac{1}{A_s} \begin{bmatrix} -Q_{13} \\ Q_{32} - Q_{20} \\ Q_{13} - Q_{32} \end{bmatrix}, \quad \mathbf{B} = \frac{1}{A_s} \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \end{bmatrix};$$

$$\begin{cases} Q_{13} = a_{z1} S_n \operatorname{sgn}(x_{1,k} - x_{3,k}) (2g|x_{1,k} - x_{3,k}|)^{1/2}, \\ Q_{32} = a_{z3} S_n \operatorname{sgn}(x_{3,k} - x_{2,k}) (2g|x_{3,k} - x_{2,k}|)^{1/2}, \\ Q_{20} = a_{z2} S_n (2gx_{2,k})^{1/2}. \end{cases}$$

采样间隔 $\Delta t = 1$ s, $w_{i,k} \sim N(0, 0.0001^2)$, $v_{i,k} \sim N(0, 0.0002^2)$, $i = 1, 2, 3$. 初始值 $h_{1,0} = 1$ m, $h_{2,0} = 0.9$ m, $h_{3,0} = 0.95$ m. $A_s = 0.0154$ m², $g = 9.81$ m/s², $S_n = 5 \times 10^{-5}$ m², $Q_1 = 4.5 \times 10^{-5}$ m³/s, $Q_2 = 4.5 \times 10^{-5}$ m³/s, $a_{z1} = 0.5$, $a_{z2} = 0.6$, $a_{z3} = 0.5$, $\operatorname{sgn}(\cdot)$ 为符号函数, 仿真时长为 150 Δt .

5.2 仿真结果

5.2.1 单缓变故障

假设参数 a_{z2} 按如下方式变化:

$$a_{z2,k} = \begin{cases} 0.6 + d_k^{a_{z2}}, & k \leq 50; \\ a_{z2,k-1} + 0.0001(k-50) + d_k^{a_{z2}}, & k > 50. \end{cases} \quad (30)$$

其中噪声 $d_k^{a_{z2}} \sim N(0, 0.004^2)$.

情况 1 状态初始值已知.

利用 4.2 节的方法将故障定位在参数 a_{z2} 的时刻为 75 Δt . 于是从第 75 Δt 时刻开始进行故障参数估计和预测. 为证明本文方法的有效性, 分别采用 UKF、STUKF、MSTUKF 估计 a_{z2} , 即扩展后的状态变量为 $[h_1, h_2, h_3, a_{z2}]^T$, 初始值 $h_{1,0} = 1$ m, $h_{2,0} = 0.9$ m, $h_{3,0} = 0.95$ m, $a_{z2,0} = 0.6$, MSTUKF 中计算多重渐消因子的比例系数为 [1, 1, 1, 2]. 3 种方法的 a_{z2} 估计值如图 1 所示, 进行 20 次蒙特卡洛仿真, 估计值的 MAE 和 RMSE 误差如表 1 所示.




图 1 初始值已知时参数 a_{z2} 估计值

表 1 a_{z2} 估计误差

指标	UKF		STUKF		MSTUKF	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
初值已知	0.0432	0.0490	0.0303	0.0343	0.0156	0.0208
初值未知	0.0564	0.1171	0.0405	0.0787	0.0246	0.0466
-2%容差	0.0356	0.0403	0.0230	0.0266	0.0135	0.0187
+2%容差	0.0498	0.0567	0.0365	0.0412	0.0199	0.0259

利用 MSTUKF 得到的 a_{z2} 估计值建立 AR 模型. 由于考虑的是缓变故障, 假设约束条件为下一时刻 a_{z2} 的变化范围不会超过当前时刻的 1%, 即

$$a_{z2,k} \times (1 - \alpha) \leq a_{z2,k+1} \leq a_{z2,k} \times (1 + \alpha), \quad (31)$$

其中 $\alpha = 0.01$. 约束条件下的二次规划求最优解采用 Matlab 中的 quadprog 函数.

图 2 所示为无约束和有约束条件下 a_{z2} 的 10 步预测值, 表 2 为预测误差.

设定 a_{z2} 处于正常和完全故障状态对应的值 $U(s_1) = 0.6$, $U(s_2) = 1.1$. MSTUKF 得到的 a_{z2} 估计值和约束 AR 模型得到的 10 步预测值的故障概率如图 3 所示. 假设当故障概率大于 0.7 时认为系统故障. a_{z2} 实际在第 133 步时故障概率大于 0.7, 故障估计结

果为第132步, 预测为第134步. 进行20次蒙特卡洛仿真, MSTUKF故障概率估计和预测误差步数如表3所示.




图2 初始值已知时 az_2 的10步预测值

表2 az_2 的10步预测误差

指标	无约束		有约束	
	MAE	RMSE	MAE	RMSE
初值已知	0.0581	0.0825	0.0405	0.0530
初值未知	0.1056	0.1530	0.0991	0.1038
-2%容差	0.0516	0.0682	0.0376	0.0467
+2%容差	0.0668	0.1045	0.0448	0.0599




图3 估计值、10步预测故障概率

表3 单缓变故障时故障概率估计和预测误差步数

项目	初值已知	初值未知	-2%容差	+2%容差
估计	2.20	2.20	2.20	2.40
10步预测	2.15	3.20	2.25	2.70

情况2 状态初始值未知.

当状态 h_1, h_2, h_3 和参数 az_2 的初值未知时, 随机假设 $h_{1,0} = 1\text{ m}, h_{2,0} = 1\text{ m}, h_{3,0} = 1\text{ m}, az_{2,0} = 0.3$. 仿真结果表明, 初始值存在很大误差, MSTUKF方法在开始估计和预测的几步内估计误差较大, 但随着步数的增加, 初值对估计和预测结果影响逐渐变小.

情况3 模型参数不匹配.

为检验 MSTUKF 在模型失配时参数的估计能力, 假设全部参数 (az_2 除外) 存在 $\pm 2\%$ 容差. 3种方法对 az_2 的估计误差如表1所示, 可以看出, MSTUKF对模型参数存在容差的情况下也有较好的跟踪能力. 表2所示为模型分别存在 $\pm 2\%$ 容差时10步预测误差, 误差步数如表3所示.

5.2.2 双缓变故障

考虑参数 az_2 和 Q_1 同时出现缓变故障, az_2 按式(30)变化, Q_1 按下式变化:

$$Q_{1,k} = \begin{cases} 4.5 \times 10^{-5} + d_k^{Q_1}, & k \leq 50; \\ Q_{1,k-1} - 0.0002 \times 10^{-5} \times (k-50) + d_k^{Q_1}, & k > 50. \end{cases} \quad (32)$$

其中 $d_k^{Q_1} \sim N(0, 10^{-14})$. 故障检测和隔离结果为在第101 Δt 时刻将故障定位在参数 az_2 和 Q_1 出现故障. MSTUKF中计算多重渐消因子的比例系数为 [1,1,1, 2,2]. 估计误差如表4所示.

表4 双缓变故障时不同方法估计误差

算法	az_2		Q_1	
	MAE	RMSE	MAE/ 10^{-5}	RMSE/ 10^{-5}
UKF	0.0571	0.0356	0.1932	0.1482
STUKF	0.0420	0.0269	0.1041	0.1095
MSTUKF	0.0180	0.0148	0.0625	0.0782

az_2 的约束条件如式(31), Q_1 的约束条件如下:

$$Q_{1,k} \times (1 - \beta) \leq Q_{1,k+1} \leq Q_{1,k} \times (1 + \beta), \quad (33)$$

其中 $\beta = 0.003$. az_2 和 Q_1 预测误差如表5所示.

表5 双缓变故障10步预测误差

指标	az_2		Q_1	
	MAE	RMSE	MAE/ 10^{-5}	RMSE/ 10^{-5}
无约束	0.0379	0.0877	0.2579	0.3098
约束	0.0284	0.0394	0.1428	0.1831

设定故障参数 Q_1 处于正常和故障状态对应值 $U(s_1) = 4.5 \times 10^{-5} \text{ m}^3/\text{s}, U(s_2) = 3.5 \times 10^{-5} \text{ m}^3/\text{s}$. 同样假定当故障概率大于0.7时系统出现故障. 故障概率估计和预测误差步数如表6所示.

表6 双缓变故障时故障概率估计和预测误差步数

项目	az_2	Q_1
估计	2.00	2.50
10步预测	2.75	5.45

仿真结果表明, MSTUKF和约束AR模型能较好地状态变化函数未知的故障参数进行估计和预测. 虽然与UKF和STUKF相比, MSTUKF的估计值波动性较大, 但是MSTUKF对于时变故障参数的跟踪能力较好. 约束条件下AR预测模型能够较好地克服预测中的不确定性, 使得约束条件下故障参数的预测精度高于非约束条件下的预测精度.

6 结论

本文根据强跟踪UKF对非线性模型较强的鲁棒性和时变状态的较强跟踪能力两个优点, 提出基于MSTUKF的状态和参数联合估计法. 与STUKF相比, MSTUKF能根据各状态变量不同的不确定性提供不同程度的强跟踪力度, 更加适用于故障参数变化函

数未知的情况. 对于估计得到的故障参数, 建立约束条件下的 AR 预测模型, 从而实现故障参数在线预测. 仿真结果表明, MSTUKF 对变化函数未知的故障参数跟踪能力优于 UKF 和 STUKF, 约束 AR 模型能结合约束条件有效地预测故障发展趋势.

参考文献(References)

- [1] 周东华, 叶银忠. 现代故障诊断与容错控制[M]. 北京: 清华大学出版社, 2000: 83-84.
(Zhou D H, Ye Y Z. Modern fault diagnose and faulttolerant control[M]. Beijing: Tsinghua University Press, 2000: 83-84.)
- [2] Benkouider A M, Buvat J C, Cosmao J M. Fault detection in semi-batch reactor using the EKF and statistical method[J]. J of Loss Prevention in the Process Industries, 2009, 22: 153-161.
- [3] Benkouider A M, Kessas R, Yahiaoui A. A hybrid approach to faults detection and diagnosis in batch and semi-batch reactors by using EKF and neural network classifier[J]. J of Loss Prevention in the Process Industries, 2012, 25: 694-702.
- [4] Alrowaie F, Gopaluni R B, Kwok K E. Fault detection and isolation in stochastic non-linear state-space models using particle filters[J]. Control Engineering Practice, 2012, 20: 1016-1032.
- [5] Simon J, Jeffrey U, Hugh F. A new method for the nonlinear transformation of means and covariances in filters and estimators[J]. IEEE Trans on Automatic Control, 2000, 45(3): 477-482.
- [6] Simon J, Jeffrey K. A new extension of the Kalman filter to nonlinear systems[C]. The 11th Int Symposium on Aerospace/Defense Sensing, Simulation and Controls. Orlando, 1997: 54-65.
- [7] Girish C, Ravindra J. Aerodynamic parameter estimation from flight data applying extended and unscented Kalman filter[J]. Aerospace Science and Technology, 2010, 14: 106-117.
- [8] Karami F, Poshtan J, Poshtan M. Detection of broken rotor bars in induction motors using nonlinear Kalman filters[J]. ISA Transactions, 2010, 49: 189-195.
- [9] Zhou D H, FRANK P M. Strong tracking filtering of nonlinear time-varying stochastic systems with colored noise: Application to parameter estimation and empirical robustness analysis[J]. Int J of Control, 1996, 65(2): 295-307.
- [10] Yu D, Wang J B. Leak fault detection of liquid rocket engine based on strong tracking filter[J]. J of Propulsion and Power, 2002, 18(2): 280-283.
- [11] Zhou Z J, H C H, Fan H D. Fault prediction of the nonlinear systems with uncertainty[J]. Simulation Modelling Practice and Theory, 2008, 16: 690-703.
- [12] 王小旭, 赵琳, 夏全喜. 基于 Unscented 变换的强跟踪滤波器[J]. 控制与决策, 2010, 25(7): 1063-1068.
(Wang X X, Zhao L, Xia Q X. Strong tracking filter based on unscented transformation[J]. Control and Decision, 2010, 25(7): 1063-1068.)
- [13] Wang J L, Feng X Y, Zhao L Q. Unscented transformation based robust Kalman filter and its applications in fermentation process[J]. Chinese J of Chemical Engineering, 2010, 18(3): 412-418.
- [14] 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.
(Zhou D H, Xi Y G, Zhang Z J. A suboptimal multiple fading extended Kalman filter[J]. Acta Automatica Sinica, 1991, 17(6): 689-695.)
- [15] 张志鑫, 张峰. 基于状态递推器的改进型残差 χ^2 检验法[J]. 中国惯性技术学报, 2009, 17(1): 107-110.
(Zhang Z X, Zhang F. Advanced residual chi-square test method based on state propagator[J]. J of Chinese Inertial Technology, 2009, 17(1): 107-110.)
- [16] Zhou Z J, Hu C H, Xu D L. A model for real-time failure prognosis based on hidden Markov model and belief rule base[J]. European J of Operational Research, 2010, 207: 269-283.
- [17] Wang D, Zhou D H, Jin Y H. A strong tracking predictor for nonlinear processes with input time delay[J]. Computers and Chemical Engineering, 2004, 28: 2523-2540.

(责任编辑: 孙艺红)