

# 改进的强跟踪求积分卡尔曼滤波算法

贺 珊, 赵 旭, 师 昕

(西安工程大学 计算机科学学院, 陕西 西安 710048)

**摘 要:** 在非线形系统状态估计问题中, 强跟踪求积分卡尔曼滤波算法在实现过程中由于对判断滤波发散的阈值设置较小, 即使在系统正常情况下也会以较大概率产生渐消因子, 从而导致过度调节滤波增益, 使得系统状态估计不够平滑。针对该问题, 提出了一种改进的强跟踪求积分卡尔曼滤波算法。该算法通过适当增大判断滤波发散的阈值, 从而有效地降低了误判滤波发散的频率, 增强了滤波器对系统状态的跟踪性能, 并能够根据不同维数的量测方程确定弱化因子的取值, 从而有效避免了凭经验选取弱化因子, 具有较强的操作性。对两种算法进行实验仿真, 结果表明, 改进的强跟踪求积分卡尔曼滤波算法具有更高的滤波精度, 减小了系统状态估计值与真实值之间的偏差。

**关键词:** 非线性系统状态估计; 强跟踪求积分卡尔曼滤波; 渐消因子; 弱化因子

中图分类号: TP301.6

文献标识码: A

文章编号: 1673-629X(2018)07-0043-04

doi: 10.3969/j.issn.1673-629X.2018.07.010

## Improved Strong Tracking Quadrature Kalman Filtering Algorithm

HE Shan, ZHAO Xu, SHI Xi

(School of Computer Science, Xi'an Polytechnic University, Xi'an 710048, China)

**Abstract:** In the nonlinear state estimation, strong tracking quadrature Kalman filtering algorithm sets small threshold to judge filtering divergence leading to fading factor with high probability even when the system is normal, which causes excessive regulation of the filtering gain and makes the state estimation curve lack smoothness. For this, we present an improved strong tracking quadrature Kalman filtering algorithm. The algorithm reduces probability of misjudging filter divergence by appropriately increasing the threshold, and also can enhance the tracking performance of the filter. Thereby, it can determine the softening factor by the different dimensions of measurement equation, and thus avoids the disadvantages of the previous algorithm that determines the softening factor in accordance with experiences. It is more operable and the simulation test is carried, which shows that the improved strong tracking quadrature Kalman filtering algorithm can obtain higher filtering accuracy than the strong tracking quadrature Kalman filtering algorithm, and reduces the deviation between the system state estimation value and the real value.

**Key words:** nonlinear state estimation; strong tracking quadrature Kalman filter; fading factor; softening factor

### 1 概 述

针对目标跟踪系统<sup>[1-3]</sup>中的状态估计问题, 卡尔曼滤波(Kalman filter, KF)<sup>[4]</sup>是一种线性最优滤波算法。针对非线性高斯系统滤波问题, 在实际应用中通常采用扩展卡尔曼滤波(extended Kalman filter, EKF)<sup>[5-6]</sup>, 滤波过程通过对系统的非线性状态方程或量测方程进行泰勒级数展开, 并截取展开式的前一阶或者二阶项, 即可将系统非线性方程转换成线性方程, 从而滤波过程可以使用卡尔曼滤波。扩展卡尔曼滤波算法具有较高的运算速度, 因此在解决非线性系统滤波问题时人们通常会采用该算法。然而, 该算法在对

非线性方程进行线性化近似时存在截断误差, 尤其是对于强非线性系统, 滤波过程较易产生扩散。

为使得非线性系统的滤波性能得到进一步提高, Gordon等提出了粒子滤波算法(particle filter, PF)<sup>[7-8]</sup>。PF是一种贝叶斯最优滤波和Monte Carlo随机采样方法相结合的统计滤波算法, 适用于任意非线性、非高斯系统, 且其滤波精度可以逼近最优估计, 是一种非常有效的非线性滤波算法, 但是其主要缺点是计算时间复杂度会随着状态变量维数的增加而迅速增大。随后, 为了处理非线性滤波问题时能够获得较高的精度以及较快的计算速度, Julier等在不敏变换

收稿日期: 2017-07-13

修回日期: 2017-11-23

网络出版时间: 2018-02-24

基金项目: 陕西省教育科研计划项目(16JK1347); 陕西省社会科学基金项目(2016R030); 西安市碑林区科技计划项目(GX1708)

作者简介: 贺珊(1989-), 女, 硕士, 助理工程师, 研究方向为信息融合与目标跟踪; 赵旭, 硕士, 副教授, 研究方向为网络安全。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20180224.1524.082.html>

(unscented transformation, UT)的基础上提出了不敏卡尔曼滤波(unscented Kalman filter, UKF)<sup>[9-10]</sup>。UT变换通过采样策略选取一系列的西格玛点集,并用这些西格玛点集近似系统状态分布的均值和方差,理论上其精度可以达到二阶。同时,该算法不需要计算非线性函数的雅克比矩阵,因此也得到了广泛的应用。但是,当系统的维数超过三阶时,该算法的滤波精度会随着系统维数的增加而降低。2007年,Arasaratnam等在高斯厄米特滤波的基础上提出了一种新的非线性滤波算法-求积分卡尔曼滤波(quadrature Kalman filtering, QKF)<sup>[11-13]</sup>。该算法是利用高斯-厄米特积分准则来计算非线性系统的概率密度,能够取得较好的滤波精度。

然而,上述非线性滤波算法对于系统模型都具有严格的要求,系统模型的不确定性,包括建模不准确、模型状态简化以及实际系统模型参数变动等,滤波过程如果直接采用标准的非线性滤波算法,都会使得系统的状态估计值偏离真实状态值,导致滤波过程发散,滤波精度降低。为了克服系统模型不确定的鲁棒性,周东华等提出了强跟踪滤波器(strong tracking filter, STF)<sup>[14-16]</sup>,该算法在应对系统状态突变问题时具有较好的跟踪能力和抗干扰能力。基于此,将强跟踪滤波算法思想引入到非线性滤波算法中,从而得到了几种相应的强跟踪非线性滤波算法,包括强跟踪扩展卡尔曼滤波算法(strong tracking extended Kalman filter, SEKF)<sup>[17]</sup>、强跟踪不敏卡尔曼滤波算法(strong tracking unscented Kalman filter, SUKF)<sup>[18]</sup>、强跟踪粒子滤波算法(strong tracking particle Kalman filter, SPF)<sup>[19]</sup>以及强跟踪求积分卡尔曼滤波算法(strong tracking quadrature Kalman filter, SQKF)<sup>[20]</sup>等。

上述强跟踪非线性滤波算法的主要思想是将渐消因子引入状态预测协方差阵中,能够在线实时调整增益矩阵,从而强迫当前时刻输出的残差序列能够保持正交,那么在系统模型不确定的情况下,上述算法均能保持对系统状态的良好跟踪能力。但是由于强跟踪滤波算法实现过程中对判断滤波发散的阈值设置较小,即使在系统正常情况下也会产生渐消因子,导致过度调节滤波增益,造成系统状态估计不够平滑,滤波精度降低。针对上述问题,文献[21]对强跟踪滤波算法进行了改进,提出了一种改进的强跟踪滤波算法(improved strong tracking Kalman filter, ISTF)。该算法的主要思想是在滤波过程中通过增大判断滤波发散的阈值,从而有效降低了误判滤波发散的的概率,提高了滤波器对于系统状态的跟踪性能,获得了更高的滤波精度。

为了能够改善强跟踪求积分卡尔曼滤波算法的滤波性能,借鉴文献[21]的思想,文中提出了一种改进

的强跟踪求积分卡尔曼滤波算法(improved strong tracking quadrature Kalman filter, ISQKF),并进行了仿真验证。

## 2 强跟踪求积分卡尔曼滤波

考虑如下的非线性系统模型,状态方程和量测方程分别为:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_{k-1} \quad (1)$$

$$\mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{v}_k \quad (2)$$

其中,  $\mathbf{x}_k \in \mathbb{R}^n$  表示状态变量;  $\mathbf{u}_k \in \mathbb{R}^n$  表示控制变量;  $\mathbf{z}_k \in \mathbb{R}^n$  表示观测向量;  $\mathbf{w}_{k-1}$  和  $\mathbf{v}_k$  分别为互不相关的零均值过程噪声和量测噪声,其方差分别为  $\mathbf{Q}_k$  和  $\mathbf{R}_k$ 。

强跟踪求积分卡尔曼滤波算法的主要思想是在状态预测协方差阵中引入渐消因子  $\lambda$  ( $0 \leq \lambda \leq 1$ ),在线实时调整增益矩阵  $\mathbf{W}_k$ , 强行使输出的残差序列保持正交,最大限度地提取残差序列中的一切有效信息,从而提高滤波器的跟踪性能。当系统模型和真实系统匹配度较高时,渐消因子  $\lambda$  趋近于 1, 此时,强跟踪求积分卡尔曼滤波算法将会退化为标准求积分卡尔曼滤波算法,不会影响到系统状态估计的结果。而当系统模型不确定时,  $\lambda$  的取值将趋近于 0, 此时,强跟踪算法能够削弱前一刻的数据对于当前时刻滤波结果的影响,从而减弱系统模型不确定所带来的影响,这样强跟踪求积分卡尔曼滤波算法在模型不确定时仍然能够具有较强的跟踪性能。

强跟踪求积分卡尔曼滤波算法具体的实现步骤如下:

状态更新:

$$\mathbf{P}_{k-1|k-1} = \sqrt{\mathbf{P}_{k-1|k-1}} (\sqrt{\mathbf{P}_{k-1|k-1}})^T \quad (3)$$

$$\mathbf{X}_{l,k-1|k-1} = \sqrt{\mathbf{P}_{k-1|k-1}} \boldsymbol{\xi}_l + \hat{\mathbf{x}}_{k-1|k-1}, l = 1, 2, \dots, m \quad (4)$$

$$\mathbf{X}_{l,k|k-1}^* = f(\mathbf{X}_{l,k-1|k-1}, \mathbf{u}_{k-1}, k-1) \quad (5)$$

$$\hat{\mathbf{x}}_{k|k-1} = \sum_{l=1}^m \omega_l \mathbf{X}_{l,k|k-1}^* \quad (6)$$

$$\mathbf{P}_{k|k-1} = \lambda \sum_{l=1}^m \omega_l \mathbf{X}_{l,k|k-1}^* \mathbf{X}_{l,k|k-1}^{*T} - \hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{x}}_{k|k-1}^T + \mathbf{Q}_k \quad (7)$$

量测更新:

$$\mathbf{P}_{k|k-1} = \sqrt{\mathbf{P}_{k|k-1}} (\sqrt{\mathbf{P}_{k|k-1}})^T \quad (8)$$

$$\mathbf{X}_{l,k|k-1} = \sqrt{\mathbf{P}_{k|k-1}} \boldsymbol{\xi}_l + \hat{\mathbf{x}}_{k|k-1} \quad (9)$$

$$\mathbf{Z}_{l,k|k-1} = h(\mathbf{X}_{l,k|k-1}, \mathbf{u}_k, k) \quad (10)$$

$$\hat{\mathbf{z}}_{k|k-1} = \sum_{l=1}^m \omega_l \mathbf{Z}_{l,k|k-1} \quad (11)$$

$$\mathbf{P}_{z,k|k-1} = \mathbf{R}_k + \sum_{l=1}^m \omega_l \mathbf{Z}_{l,k|k-1} \mathbf{Z}_{l,k|k-1}^T - \hat{\mathbf{z}}_{k|k-1} \hat{\mathbf{z}}_{k|k-1}^T \quad (12)$$

$$\mathbf{P}_{xz,klk-1} = \sum_{l=1}^m \omega_l X_{l,klk-1} \mathbf{Z}_{l,klk-1}^T - \hat{\mathbf{x}}_{klk-1} \hat{\mathbf{z}}_{klk-1}^T \quad (13)$$

$$\mathbf{W}_k = \mathbf{P}_{xz,klk-1} \mathbf{P}_{zz,klk-1}^{-1} \quad (14)$$

$$\hat{\mathbf{x}}_{klk} = \hat{\mathbf{x}}_{klk-1} + \mathbf{W}_k (\mathbf{z}_k - \hat{\mathbf{z}}_{klk-1}) \quad (15)$$

$$\mathbf{P}_{klk} = \mathbf{P}_{klk-1} - \mathbf{W}_k \mathbf{P}_{zz,klk-1} \mathbf{W}_k^T \quad (16)$$

其中

$$\lambda_k = \begin{cases} \lambda_{0,k}, \lambda_{0,k} \geq 1 \\ \mathbf{1}, \lambda_{0,k} < 1 \end{cases} \quad (17)$$

$$\lambda_{0,k} = \frac{\text{Tr}(\mathbf{N}_k)}{\text{Tr}(\mathbf{M}_k)} \quad (18)$$

其中

$$\mathbf{N}_k = \mathbf{V}_{0,k} - \mathbf{H}(\hat{\mathbf{x}}_{k,k-1}) \mathbf{Q}_{k-1} \mathbf{H}^T(\hat{\mathbf{x}}_{k,k-1}) - \mathbf{l}_k \mathbf{R}_k \quad (19)$$

$$\mathbf{M}_k = \mathbf{H}(\hat{\mathbf{x}}_{k,k-1}) \mathbf{F}(\hat{\mathbf{x}}_{k,k-1}, \mathbf{u}_k) \mathbf{P}_{k-1} \mathbf{F}^T(\hat{\mathbf{x}}_{k,k-1}, \mathbf{u}_k) \mathbf{H}^T(\hat{\mathbf{x}}_{k,k-1}) \quad (20)$$

$$\mathbf{V}_{0,k} = \begin{cases} \tilde{\mathbf{y}}_1 \tilde{\mathbf{y}}_1^T, k=0 \\ \frac{\rho \mathbf{V}_{0,k-1} + \tilde{\mathbf{y}}_k \tilde{\mathbf{y}}_k^T}{1+\rho}, k \geq 1 \end{cases} \quad (21)$$

其中,  $\rho$  ( $0.95 \leq \rho \leq 0.995$ ) 为遗忘因子;  $\mathbf{l}_k \geq \mathbf{1}$

为弱化因子。这里, 可以取  $\mathbf{l}_k = \mathbf{1} - \mathbf{d}_k$ ,  $\mathbf{d}_k = \frac{1-\rho}{1-\rho^{k+1}}$ ,  $\rho$  一般取值为 0.95。

### 3 改进的强跟踪求积分卡尔曼滤波算法

针对非线性滤波问题, 强跟踪求积分卡尔曼滤波算法主要思想是将渐消因子  $\lambda_{k-1}$  引入到状态预测协方差阵  $\mathbf{P}_{klk-1}$  中, 在线实时调整增益矩阵  $\mathbf{W}_k$ , 从而使输出残差序列保持正交, 这样强跟踪求积分卡尔曼滤波算法在应对模型不确定时仍然能够保持对系统状态的良好跟踪性能。然而, 在实际应用中发现, 强跟踪求积分卡尔曼滤波算法在应对系统状态突变问题时会出现滤波精度降低的问题, 导致滤波精度降低的主要原因是由于在求解  $\mathbf{V}_{0,k}$  时得不到解析解, 而只能通过参数序列获得其近似值, 从而导致其近似值与理论值出现了偏差, 使得对系统状态估计不够平滑。强跟踪求积分卡尔曼滤波算法问题分析如下:

$k$  时刻  $\mathbf{V}_{0,k}$  的理论值  $\mathbf{C}_{0,k}$  可通过下式求得:

$$\mathbf{C}_{0,k} = \mathbf{H}_k \mathbf{P}_{klk-1} \mathbf{H}_k^T + \mathbf{R}_k \quad (22)$$

$\mathbf{V}_{0,k}$  的近似值可通过式 21 求得:

$$\mathbf{V}_{0,k} = \frac{\rho \mathbf{V}_{0,k-1} + \tilde{\mathbf{y}}_k \tilde{\mathbf{y}}_k^T}{1+\rho} \approx \frac{\mathbf{V}_{0,k-1}}{2} + \frac{\mathbf{y}_k^2}{2} \quad (23)$$

其中,  $y_k \sim N(0, \mathbf{C}_{0,k})$ , 那么  $k$  时刻的残差  $\mathbf{y}_k$  可以认为是高斯分布  $N(\mathbf{y}_k; 0, \mathbf{C}_{0,k})$  的一次采样, 那么可得到:

$$P(\mathbf{y}_k^2 \leq 2 \mathbf{C}_{0,k}) = 84.1\% \quad (24)$$

相应滤波发散的率为:

$$P(\mathbf{V}_{0,k} > 2 \mathbf{C}_{0,k}) = P(\mathbf{y}_k^2 \geq 2 \mathbf{C}_{0,k}) =$$

$$1 - 84.1\% \approx 16\% \quad (25)$$

通过上述分析可知, 强跟踪求积分卡尔曼滤波算法在解决非线性滤波问题时滤波结果会有 16% 的概率出现滤波发散, 若再考虑  $\mathbf{V}_{0,k}$  的影响, 其滤波发散的率将远大于 16%, 根据式 18 及式 20, 还会使得渐消因子的值偏大 2 倍。由于上述原因将导致强跟踪算法滤波精度降低, 系统状态估计不够平滑, 即使滤波过程引入弱化因子  $\mathbf{l}_k$ , 将判断滤波发散的阈值增大到  $\mathbf{H}_k \mathbf{P}_{klk-1} \mathbf{H}_k^T + \mathbf{l}_k \mathbf{R}_k$ , 从而降低了滤波发散的率, 但阈值  $\mathbf{C}_{0,k}$  还与  $\mathbf{P}_{klk-1}$  相关, 那么对于不同的系统仅通过引入弱化因子  $\mathbf{l}_k$  来调整阈值, 且  $\mathbf{l}_k$  只能凭经验取值, 因此该方法操作性较低。

为了解决上述问题, 提出了一种新的滤波算法即改进的强跟踪求积分卡尔曼滤波算法。该算法的主要思想是在算法实现过程中适当增大判断滤波发散的阈值, 从而有效降低了误判滤波发散的率, 大大减小了产生渐消因子的率, 并能够根据不同维数的量测方程确定弱化因子的取值。

由于

$$P(\mathbf{y}_k^2 \leq 6 \mathbf{C}_{0,k}) = 98.5\% \quad (26)$$

则

$$P(\mathbf{y}_k^2 \geq 6 \mathbf{C}_{0,k}) = 1.5\% \quad (27)$$

因此, 可将判定滤波发散的阈值提高到  $3 \mathbf{C}_{0,k}$ , 则

$$P(\mathbf{V}_{0,k} \geq 3 \mathbf{C}_{0,k}) = P(\mathbf{y}_k^2 \geq 6 \mathbf{C}_{0,k}) = 1.5\% \quad (28)$$

即使考虑  $\mathbf{V}_{0,k}$  的影响, 由于  $\mathbf{V}_{0,k} < \mathbf{C}_{0,k}$ , 假设两者相等的情况下:

$$P(\mathbf{V}_{0,k} \geq 3 \mathbf{C}_{0,k}) = P(\mathbf{y}_k^2 \geq 5 \mathbf{C}_{0,k}) = 2.6\% \quad (29)$$

因此, 当把  $\mathbf{V}_{0,k}$  的值取到  $3 \mathbf{C}_{0,k}$  时, 滤波发散的率仅为 1.5% ~ 2.6%, 新算法滤波发散的率远远小于强跟踪求积分卡尔曼滤波算法滤波发散的率。

那么, 当  $\mathbf{V}_{0,k} = 3 \mathbf{C}_{0,k}$  时, 则有:

$$\mathbf{V}_{0,k} = 3(\lambda_k \mathbf{H}_k \mathbf{F}_{k-1} \mathbf{P}_{k-1} \mathbf{F}_{k-1}^T \mathbf{H}_k^T + \mathbf{H}_k \mathbf{Q}_{K-1} \mathbf{H}_k^T + \mathbf{R}_k) \quad (30)$$

由上式可得:

$$\lambda_k = \frac{\mathbf{V}_{0,k} - 3(\mathbf{H}_k \mathbf{Q}_{K-1} \mathbf{H}_k^T - \mathbf{R}_k)}{3 \mathbf{H}_k \mathbf{F}_{k-1} \mathbf{P}_{k-1} \mathbf{F}_{k-1}^T \mathbf{H}_k^T} \quad (31)$$

那么改进的强跟踪滤波算法的渐消因子即为:

$$\lambda_k = \begin{cases} \lambda_{0,k}, \lambda_{0,k} \geq 1 \\ \mathbf{1}, \lambda_{0,k} < 1 \end{cases} \quad (32)$$

$$\lambda_{0,k} = \frac{\text{Tr}(\mathbf{N}'_k)}{\text{Tr}(\mathbf{M}'_k)} \quad (33)$$

其中

$$\mathbf{N}'_k = \mathbf{V}_{0,k} - \mathbf{l}_k (\mathbf{H}_k \mathbf{Q}_{K-1} \mathbf{H}_k^T - \mathbf{R}_k) \quad (34)$$

$$\mathbf{M}'_k = \mathbf{l}_k \mathbf{H}_k \mathbf{F}_{k-1} \mathbf{P}_{k-1} \mathbf{F}_{k-1}^T \mathbf{H}_k^T \quad (35)$$

结合式 31 可知, 弱化因子  $\mathbf{l}_k = 3$ 。新算法和原有

的强跟踪求积分卡尔曼滤波算法相比,通过适当调整  $N_k$  和  $M_k$ ,能够确定弱化因子的取值,从而有效避免了凭经验选取弱化因子,在实际应用中具有更强的操作性。这样结合式 3~16 即可构成改进的强跟踪求积分卡尔曼滤波算法。

上述改进的强跟踪求积分卡尔曼滤波算法的推导是针对一维系统,若要推广到多维系统中,那么判断滤波发散的条件为:

$$\text{Tr}(\mathbf{y}_k \mathbf{y}_k^T) \geq (2l - 1) \text{Tr}(\mathbf{C}_{0,k}) \quad (36)$$

假设  $\mathbf{V}_{0,k}$  和  $\mathbf{C}_{0,k}$  两者相等,上式可改写为:

$$\text{Tr}(\mathbf{V}_{0,k}) \geq \text{Tr}(l \mathbf{C}_{0,k}) \quad (37)$$

当  $\mathbf{y}_k = \sqrt{\mathbf{C}_{0,k}} \boldsymbol{\xi}_k$ ,其中  $\boldsymbol{\xi}_k$  服从标准正态分布,上式等价于:

$$\boldsymbol{\xi}_k \boldsymbol{\xi}_k^T \geq (2l - 1) n \quad (38)$$

其中,  $n$  为量测方程的维数。

因此,为了使得判断滤波发散的概率较小,应当合理选取  $l$  的取值。由于  $\boldsymbol{\xi}_k$  服从标准正态分布,  $\boldsymbol{\xi}_k \boldsymbol{\xi}_k^T$  应当服从自由度为  $n$  的  $\chi^2$  分布,根据  $\chi^2$  分布的性质可知,式 38 应当为  $l$  和  $n$  的单调递减函数,因此需要针对不同维数  $n$  选取不同的  $l$ ,从而取得较为合理的判断滤波发散的概率。那么对于判断滤波发散的概率通常只需要控制在 3% 以内,由  $\chi^2$  分布的分布表可知,系统量测方程的维数  $n$  与弱化因子  $l$  之间存在如下关系:

$$l = \begin{cases} 3, & n \leq 5 \\ 2.5, & 5 < n \leq 10 \\ 2, & n > 10 \end{cases} \quad (39)$$

那么,针对非线性滤波问题,当采用文中提出的 ISQKF 时,即可通过式 39 确定弱化因子的取值,从而避免了凭经验选取弱化因子的问题。

### 4 仿真实验及结果分析

单变量非稳定增长模型 (univariate nonstationary growth model, UNGM) 如下:

$$\mathbf{x}_k = \alpha \mathbf{x}_{k-1} + \beta \frac{\mathbf{x}_{k-1}}{1 + \mathbf{x}_{k-1}^2} + \gamma \cos(1.2(n - 1)) + \mathbf{v}_k \quad (40)$$

$$\mathbf{y}_k = \frac{\mathbf{x}_k^2}{20} + \mathbf{w}_k, k = 1, 2, \dots, N \quad (41)$$

其中,  $\alpha = 0.5, \beta = 25, \gamma = 8$ 。

设该系统的初始值分别为:  $\mathbf{x}_0 = 0.1, \mathbf{P}_0 = 0.1$  以及  $N = 100$ 。根据式 39 可知弱化因子  $l = 3$ 。

由式 40 和式 41 可知该系统为非线性系统,滤波过程中分别采用 SQKF 以及提出的 ISQKF 进行滤波估计。

实验仿真数据如图 1 和图 2 所示。

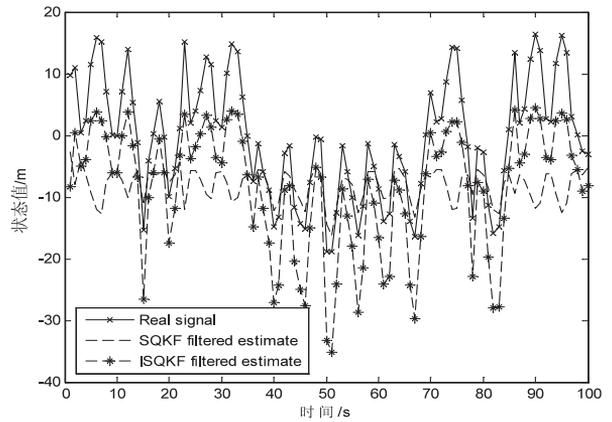


图 1 SQKF 与 ISQKF 状态估计结果对比

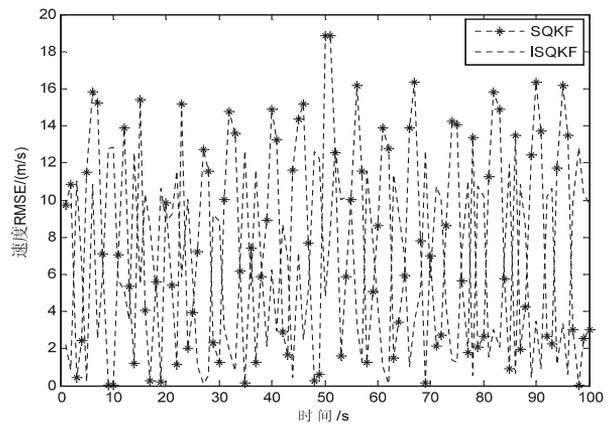


图 2 SQKF 与 ISQKF 估计误差对比

由图 1 可知,经过 ISQKF 滤波后的状态估计值与 SQKF 滤波后的状态估计值相比更加趋近系统真实状态值。由图 2 可知,采用 ISQKF 滤波后的滤波误差明显小于 SQKF 滤波后的滤波误差。综上所述,针对系统不确定问题,提出的 ISQKF 与原有的 SQKF 相比,具有更高的滤波精度,状态估计值更加接近于系统真实值。

### 5 结束语

对于非线性高斯系统,强跟踪求积分卡尔曼滤波算法在实现的过程中由于存在对判断滤波发散的阈值设置较小的问题,从而使得误判滤波发散的概率增大,进而增大了产生渐消因子的概率,造成过度调整滤波增益,最终导致对系统状态估计出现较大偏差。为了解决上述问题,提出了一种改进的强跟踪求积分卡尔曼滤波算法。该算法主要通过增大判断滤波发散的阈值,从而有效降低了误判滤波发散的概率,增强了滤波器对系统状态的跟踪性能,获得了更高的滤波精度,并能够根据不同维数的量测方程确定弱化因子的取值,从而避免了凭经验选取弱化因子,具有较强的操作性。对两种算法进行实验仿真,结果表明,改进算法具有更高的滤波精度,减小了系统状态估计值与真实值之间的偏差。

## 参考文献:

- [1] BAR-SHALOM Y, FORTMANN T E. Tracking and data association[M]. [s. l.]: Academic Press, 1988.
- [2] BAR-SHALOM Y, LI X R, KIRUBARAJAN T. Estimation with applications to tracking and navigation[M]. New York: Wiley-Interscience, 2001.
- [3] HALL D L. Mathematic techniques in multi-sensor data fusion[M]. Boston, MA: Artech House Publishers, 1992.
- [4] KALMAN R E. A new approach to linear filtering and prediction problems[J]. Journal of Basic Engineering Transactions, 1960, 82: 35-45.
- [5] SIMON D. Optimal state estimation[M]. New York: Wiley-Interscience, 2006.
- [6] 韩崇昭, 朱洪艳, 段战胜. 多源信息融合[M]. 第2版. 北京: 清华大学出版社, 2010.
- [7] ARULAMPALAM M S, MASKELL S, GORDON N, et al. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking[J]. IEEE Transactions on Signal Processing, 2002, 50(2): 174-188.
- [8] CAPPE O, GODSILL S J, MOULINES E. An overview of existing methods and recent advances in sequential Monte Carlo[J]. Proceedings of the IEEE, 2007, 95(5): 899-924.
- [9] JULIER S, UHLMANN J K. Unscented filtering and nonlinear estimation[J]. Proceeding of the IEEE, 2004, 92(2): 401-422.
- [10] TO K, XIONG K. Gaussian filters for nonlinear filtering

- problems[J]. IEEE Transactions on Automatic Control, 2000, 45(5): 910-927.
- [11] ARASARATNAM I, HAYKIN S, ELLIOTT R J. Discrete-time nonlinear filtering algorithms using Gauss-Hermite quadrature[J]. Proceedings of the IEEE, 2007, 95(5): 953-977.
- [12] ARASARATNAM I, HAYKIN S. Square-root quadrature Kalman filtering[J]. IEEE Transactions on Signal Processing, 2008, 56(6): 2589-2593.
- [13] 周东华, 席裕庚, 张钟俊. 非线性系统的带次优渐消因子的扩展卡尔曼滤波[J]. 控制与决策, 1990, 5(5): 1-6.
- [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.
- [15] 付梦印, 邓志红, 闫丽萍. Kalman 滤波理论及其在导航系统中的应用[M]. 北京: 科学出版社, 2010: 100-103.
- [16] 范文兵, 刘春风, 张素贞. 一种强跟踪扩展卡尔曼滤波器的改进算法[J]. 控制与决策, 2006, 21(1): 73-76.
- [17] 张文玲, 朱明清, 陈宗海. 基于强跟踪 UKF 的自适应 SLAM 算法[J]. 机器人, 2010, 32(2): 190-195.
- [18] 胡昌华, 张 琪, 乔玉坤. 强跟踪粒子滤波算法及其在故障预报中的应用[J]. 自动化学报, 2008, 34(12): 1522-1528.
- [19] 马丽丽, 贺 珊, 陈金广. 强跟踪求积分卡尔曼滤波算法[J]. 计算机工程与设计, 2014, 35(5): 1802-1806.
- [20] 钱华明, 葛 磊, 黄 蔚. 一种改进的强跟踪滤波算法[J]. 应用科学学报, 2015, 33(1): 32-40.

(上接第28页)

法也存在一定的不足, 未来做进一步改进, 把 SLIC 算法和 DPCA 聚类算法更好地结合在一起, 使分割效果达到更好。

## 参考文献:

- [1] 何 俊, 葛 红, 王玉峰. 图像分割算法研究综述[J]. 计算机工程与科学, 2009, 31(12): 58-61.
- [2] 张旭东, 吕言言, 缪永伟, 等. 基于区域协方差的图像超像素生成[J]. 计算机科学, 2016, 43(5): 318-322.
- [3] STOCKMAN G, SHAPIRO L G. Computer vision[M]. [s. l.]: Prentice Hall, 2001: 201-213.
- [4] KANUNGO T, MOUNT D M, NETANYAHU N S, et al. An efficient k-means clustering algorithm: analysis and implementation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002, 24(7): 881-892.
- [5] SON L H, CUONG B C, LANZI P L, et al. A novel intuitionistic fuzzy clustering method for geo-demographic analysis[J]. Expert Systems with Applications, 2012, 39(10): 9848-9859.
- [6] 周文刚, 孙 挺, 朱 海. 一种基于自适应空间信息改进 FCM 的图像分割算法[J]. 计算机应用研究, 2015, 32(7): 2205-2208.
- [7] ESTER M, KRUEGEL H P, SANDER J, et al. A density-

- based algorithm for discovering clusters a density-based algorithm for discovering clusters in large spatial databases with noise[C]//International conference on knowledge discovery and data mining. [s. l.]: AAAI Press, 1996: 226-231.
- [8] 李志梅, 肖德贵. 改进的快速模糊聚类图像分割算法[J]. 计算机仿真, 2009, 26(8): 212-215.
- [9] 关 昕, 周积林. 基于改进谱聚类的图像分割算法[J]. 计算机工程与应用, 2014, 50(21): 184-188.
- [10] 曾 山. 模糊聚类算法研究[D]. 武汉: 华中科技大学, 2012.
- [11] 宋熙煜, 周利莉, 李中国, 等. 图像分割中的超像素方法研究综述[J]. 中国图象图形学报, 2015, 20(5): 599-608.
- [12] ACHANTA R, SHAJI A, SMITH K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 34(11): 2274-2282.
- [13] 由柏娇. 一种基于超像素的彩色图像分割算法[D]. 哈尔滨: 哈尔滨工程大学, 2015.
- [14] RODRIGUEZ A, LAIO A. Machine learning: clustering by fast search and find of density peaks[J]. Science, 2014, 344(6191): 1492-1496.
- [15] REN X, MALIK J. Learning a classification model for segmentation[C]//Ninth IEEE international conference on computer vision. Nice, France: IEEE, 2003: 10-17.