

自适应 SCKF 在机动目标跟踪中的应用

王思思^{1,2}, 齐国清¹

(1. 大连海事大学信息科学技术学院, 辽宁 大连 116026; 2. 广东海洋大学航海学院, 广东 湛江 524088)

摘要: 目标跟踪系统的数学模型或统计特性的不确定性, 往往会导致机动目标跟踪精度降低甚至跟踪发散。在综合平方根求容积卡尔曼滤波算法和改进的 Sage-Husa 估计器的基础上, 提出一种自适应求容积平方根卡尔曼滤波算法。该算法通过实时估计未知系统噪声, 抑制由于噪声统计特性未知时变而导致的滤波误差, 从而实现机动目标的自适应跟踪。仿真结果表明, 在系统噪声未知时变, 且与先验系统噪声存在一定差异时, 自适应平方根求容积卡尔曼滤波器能有效地改进标准平方根求容积卡尔曼滤波器的跟踪精度和跟踪稳定性。

关键词: 机动目标跟踪; 自适应; 平方根求容积卡尔曼滤波

中图分类号: V271.4; TN956 **文献标志码:** A **文章编号:** 1671-637X(2013)08-0006-05

Adaptive SCKF Method with Applications to Maneuvering Target Tracking

WANG Sisi^{1,2}, QI Guoqing¹

(1. College of Information Science and Technology, Dalian Maritime University, Dalian 116026, China;

2. College of Navigation, Guangdong Ocean University, Zhanjiang 524088, China)

Abstract: Considering low accuracy even divergence of maneuvering target tracking due to inaccurate tracking model and uncertain statistical property, we proposed an adaptive Square Root Cubature Kalman Filter (SCKF) based on the standard SCKF and modified Sage-Husa estimator. The proposed algorithm can estimate the statistical parameters of unknown system noises online, and restrain the tracking error caused by unknown system noises effectively; hence it is applied to maneuvering target tracking. The simulation results show that: comparing with SCKF algorithm, the adaptive SCKF can provide better accuracy and stability for maneuvering target tracking when the unknown or time variant system noises is some different from the prior noise knowledge.

Key words: maneuvering target tracking; adaptiveness; square root cubature Kalman filter

0 引言

机动目标的跟踪从来都是雷达信息处理领域中的热点和难点问题。机动目标跟踪时, 动态模型通常是在笛卡尔坐标系下建立, 状态向量中一般包含目标的速度和加速度。而观测信息通常以极坐标形式表示, 包括目标与雷达的距离、方位角和俯仰角等分量。此时, 机动目标跟踪是一个典型的高维非线性估计问题。

近年来, 平方根求容积卡尔曼滤波器 (Square Root Cubature Filter, SCKF) 较好地解决了高维非线性状态

估计的问题^[1]。仿真结果证明在相同运算量的前提下, 该算法可比粒子滤波器 (Particle Filter, PF) 和无迹卡尔曼滤波器 (Unscented Kalman Filter, UKF) 等常用的非线性估计方法获得更高的精度^[1-2]。但要将 SCKF 算法应用于机动目标跟踪, 仍需精确已知被研究对象的数学模型和噪声统计的先验知识, 否则将可能导致较大的状态估计误差, 甚至会出现滤波发散^[3]。但由于系统噪声受外界干扰、加速度的物理特性和人为操纵等因素的影响, 其统计特性很难准确描述, 通常是未知和时变的。因此, 如何在未知时变的系统噪声背景下应用 SCKF 算法实现机动目标跟踪成为一个亟待解决的问题。

为解决此问题, 本文采用了一种自适应 SCKF (Adaptive SCKF, ASCKF) 算法。该算法利用改进的

收稿日期: 2012-08-15

修回日期: 2012-09-27

基金项目: 国家高技术发展计划 (八六三) (2011AA110201)

作者简介: 王思思 (1980—), 女, 湖北黄石人, 博士生, 讲师, 研究方向为雷达信息处理。

Sage-Husa 次优无偏极大后验估值器^[3]来估计未知噪声,通过其递推形式与 SCKF 方法相结合,在滤波过程中实时估计和修正系统噪声统计特性,以减小状态估计误差。仿真结果表明,ASCKF 算法在系统噪声统计特性未知时变,且与先验系统噪声存在一定差异时,估计精度和稳定性要明显优于标准 SCKF 算法,提高了对目标的实时跟踪能力。

1 问题的描述

考虑一般的机动目标跟踪问题,在笛卡尔坐标系中,目标的离散时间状态系统方程和量测方程分别为

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

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

式中: $\mathbf{x}_k \in \mathbf{R}^n$ 是 k 时刻的动态系统状态向量; $f: \mathbf{R}^n \times \mathbf{R}^n \rightarrow \mathbf{R}^n$ 和 $h: \mathbf{R}^n \times \mathbf{R}^n \rightarrow \mathbf{R}^n$ 都为已知函数; $\mathbf{z}_k \in \mathbf{R}^n$ 为观测向量; $\{\mathbf{v}_{k-1}\}$ 是均值为 q , 方差为 \mathbf{Q}_{k-1} 的独立高斯过程噪声向量; $\{\boldsymbol{\omega}_k\}$ 是均值为 r , 方差为 R_k 的独立高斯观测噪声向量。在雷达目标跟踪问题中, 状态方程一般是线性的, 但量测方程是非线性的, 因此这是一个非线性估计问题。

2 ASCKF 算法

2.1 SCKF 算法

由于标准求容积卡尔曼滤波器 (Cubature Kalman Filter, CKF) 算法的运算过程极易使协方差矩阵失去对称正定性, 因此 Lenkaran Arasaratnam 在标准 CKF 算法的基础上提出了 SCKF 算法^[1]。

要实现 SCKF 算法, 首先按照三阶容积准则, 选取一组 $m = 2n$ 个等权值分布的 Cubature (容积) 点 $\{w_i, \boldsymbol{\xi}_i\}$ 实现分线性逼近。其中:

$$w_i = \frac{1}{m}, \quad i = 1, 2, \dots, m; \quad m = 2n \quad (3)$$

$$\boldsymbol{\xi}_i = \sqrt{\frac{m}{2}} [l]_i \quad (4)$$

式中: $\boldsymbol{\xi}_i$ 为容积点向量; w_i 为对应权重; n 为系统状态变量的维数; $[l] \in \mathbf{R}^n$, 为生成算子, 以 $n = 2$ 为例, $[l] \in \mathbf{R}^2$ 表示如式(5)所示的点集。

$$\left\{ \begin{pmatrix} 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \end{pmatrix}, \begin{pmatrix} -1 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ -1 \end{pmatrix} \right\} \quad (5)$$

$[l]_i$ 是 $[l] \in \mathbf{R}^2$ 中第 i 个元素。若 $k-1$ 时刻的后验概率 $p(\mathbf{x}_{k-1} | z_{1:k-1}) \sim N(\mathbf{x}_{k-1}; \mathbf{x}_{k-1|k-1}, \mathbf{P}_{k-1|k-1})$, 则可获得方差 $\mathbf{P}_{k-1|k-1}$ 的乔列斯基分解因子 $\mathbf{S}_{k-1|k-1}$ 。SCKF 算法具体步骤如下所述。

- 1) 给定状态初始条件 $x_{010}, \mathbf{S}_{010} = \text{chol}(\mathbf{P}_{010})$ 。
- 2) 时间更新。

- ① 计算容积点 ($i = 1, 2, \dots, m$)。

$$X_{i,k-1|k-1} = \mathbf{S}_{k-1|k-1} \boldsymbol{\xi}_i + \hat{\mathbf{x}}_{k-1|k-1} \quad (6)$$

- ② 计算预测状态容积点。

$$X_{i,k|k-1}^* = f(X_{i,k-1|k-1}, u_{k-1}) \quad (7)$$

- ③ 估计预测状态。

$$\hat{\mathbf{x}}_{k|k-1} = \frac{1}{m} \sum_{i=1}^m X_{i,k|k-1}^* + q \quad (8)$$

- ④ 估计预测协方差的平方根因子。

$$\mathbf{S}_{k|k-1} = \text{Tria}([\boldsymbol{\chi}_{k|k-1}^*, \mathbf{S}_{Q,k-1}]) \quad (9)$$

其中 $\mathbf{Q}_{k-1} = \mathbf{S}_{Q,k-1} \mathbf{S}_{Q,k-1}^T$, $\text{Tria}(\cdot)$ 表示对矩阵进行 QR 分解。而矩阵 $\boldsymbol{\chi}_{k|k-1}^*$ 定义为

$$\boldsymbol{\chi}_{k|k-1}^* = \frac{1}{\sqrt{m}} [X_{1,k|k-1}^* - \hat{\mathbf{x}}_{k|k-1} \quad X_{2,k|k-1}^* - \hat{\mathbf{x}}_{k|k-1} \quad \dots \quad X_{m,k|k-1}^* - \hat{\mathbf{x}}_{k|k-1}] \quad (10)$$

- 3) 量测更新。

- ① 计算容积点 ($i = 1, 2, \dots, m$)。

$$X_{i,k|k-1} = \mathbf{S}_{k|k-1} \boldsymbol{\xi}_i + \hat{\mathbf{x}}_{k|k-1} \quad (11)$$

- ② 计算预测量测容积点。

$$Z_{i,k|k-1} = h(X_{i,k|k-1}, u_k) \quad (12)$$

- ③ 估计预测量测值。

$$\hat{\mathbf{z}}_{k|k-1} = \frac{1}{m} \sum_{i=1}^m Z_{i,k|k-1} \quad (13)$$

- ④ 估计新息协方差矩阵。

$$\mathbf{S}_{z,k|k-1} = \text{Tria}([\boldsymbol{\zeta}_{k|k-1}, \mathbf{S}_{R,k}]) \quad (14)$$

其中, $\mathbf{R}_k = \mathbf{S}_{R,k} \mathbf{S}_{R,k}^T$ 。而矩阵 $\boldsymbol{\zeta}_{k|k-1}$ 定义为

$$\boldsymbol{\zeta}_{k|k-1} = \frac{1}{\sqrt{m}} [Z_{1,k|k-1} - \hat{\mathbf{z}}_{k|k-1} \quad Z_{2,k|k-1} - \hat{\mathbf{z}}_{k|k-1} \quad \dots \quad Z_{m,k|k-1} - \hat{\mathbf{z}}_{k|k-1}] \quad (15)$$

- ⑤ 估计互协方差矩阵。

$$\mathbf{P}_{z,k|k-1} = \boldsymbol{\chi}_{k|k-1} \boldsymbol{\zeta}_{k|k-1}^T \quad (16)$$

其中, 矩阵 $\boldsymbol{\chi}_{k|k-1}$ 定义为

$$\boldsymbol{\chi}_{k|k-1} = \frac{1}{\sqrt{m}} [X_{1,k|k-1} - \hat{\mathbf{x}}_{k|k-1} \quad X_{2,k|k-1} - \hat{\mathbf{x}}_{k|k-1} \quad \dots \quad X_{m,k|k-1} - \hat{\mathbf{x}}_{k|k-1}] \quad (17)$$

- ⑥ 估计卡尔曼增益。

$$\mathbf{W}_k = (\mathbf{P}_{z,k|k-1} / \mathbf{S}_{z,k|k-1}^T) / \mathbf{S}_{z,k|k-1} \quad (18)$$

- ⑦ 估计状态更新向量。

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{W}_k (\mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1}) \quad (19)$$

- ⑧ 估计相应协方差的平方根因子。

$$\mathbf{S}_{k|k} = \text{Tria}([\boldsymbol{\chi}_{k|k-1} - \mathbf{W}_k \boldsymbol{\zeta}_{k|k-1}, \mathbf{W}_k \mathbf{S}_{R,k}]) \quad (20)$$

2.2 ASCKF 算法的实现

自适应滤波方法有很多种, 其中利用 Sage-Husa 估计器的方法应用最广泛, 优点最多, 有与扩展卡尔曼滤波器结合应用于导航系统, 也有引入次优的 Sage-Husa 估计器而形成自适应 UKF 等等^[3-9]。同时, 也有研究^[10]指出, 在系统噪声和量测噪声统计特性均未知

的情况下, Sage-Husa 噪声估计器不能同时估计两者, 否则会引起滤波器的发散。

基于以上原因, 针对式(1)~式(2)描述的目标跟踪问题, ASCKF 算法也将次优 Sage-Husa 估计器引入 SCKF 算法中, 专对未知系统噪声统计特性的递推进行实时估计和非线性系统的自适应滤波, 具体步骤如下。

1) 给定状态初始条件 $x_{010}, S_{010} = chol(P_{010}), \hat{q}_0 = q_0, \hat{Q}_0 = Q_0$ 。

2) 时间更新。根据给定的 $S_{k-1|k-1}, \hat{x}_{k-1|k-1}, \hat{q}_{k-1}, \hat{Q}_{k-1}$, 并按照式(6)~式(10)估计预测状态 $\hat{x}_{k|k-1}$ 以及预测协方差的乔列斯基因子 $S_{k|k-1}$ 。

由于此步骤传递的是 $S_{k|k-1}$, 从而避免了由于预测误差方差 $P_{k|k-1}$ 失去正定或半正定性而引起的计算发散, 因此不需如文献[4-6]中一样进行发散判断, 而依然可以保持滤波的正常进行。

3) 量测更新。利用上步传递的估计值, 按照式(11)~式(18)求得新息协方差因子 $S_{z,k|k-1}$ 、互协方差 $P_{xz,k|k-1}$ 以及卡尔曼增益 W_k 。

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + W_k(z_k - \hat{z}_{k|k-1}) \quad (21)$$

$$S_{k|k} = Tria([\chi_{k|k-1} - W_k \zeta_{k|k-1}, W_k S_{R,k}]) \quad (22)$$

4) 递推估计系统噪声统计特性。

$$\hat{q}_k = (1 - d_k)\hat{q}_{k-1} + d_k[\hat{x}_{k|k} - \Phi_k \hat{x}_{k-1|k-1}] \quad (23)$$

$$\hat{Q}_k = (1 - d_k)\hat{Q}_{k-1} + d_k[W_k \tilde{z}_k \tilde{z}_k^T W_k^T + P_{k|k} - \Phi_k P_{k-1|k-1} \Phi_k^T] \quad (24)$$

式(23)~式(24)中: $d_k = (1 - b)/(1 - b^{k+1})$; b 为遗忘因子, 通常 b 的范围为 $0.95 < b < 0.99$, b 用来限制滤波器的记忆长度, b 越大, 新近测量数据对当前实时估计的作用越强, 噪声统计变化较快时, b 应取值偏大, 反之, b 应取值偏小; \tilde{z}_k 为预报残差, $\tilde{z}_k = z_k - h(x_{k|k-1})$; Φ_k 为系统传递矩阵。

3 仿真方案与结果分析

3.1 仿真方案

3.1.1 运动模型

在系统噪声统计特性未知的情况下, 分别采用 SCKF 算法和 ASCKF 算法仿真, 以验证 ASCKF 算法的滤波效果。二维情况下, 设雷达观测站位于坐标原点, 目标在水平平面按照恒定转向速度进行转向机动。系统噪声未知, 转向速率未知, 系统方程描述^[11]为

$$\mathbf{x}_k = \begin{bmatrix} 1 & \frac{\sin \Omega T}{\Omega} & 0 & -\left(\frac{1 - \cos \Omega T}{\Omega}\right) \\ 0 & \cos \Omega T & 0 & -\sin \Omega T \\ 0 & \frac{1 - \cos \Omega T}{\Omega} & 1 & \frac{\sin \Omega T}{\Omega} \\ 0 & \sin \Omega T & 0 & \cos \Omega T \end{bmatrix} \mathbf{x}_{k-1} + \mathbf{v}_k \quad (25)$$

其中目标的状态向量 $\mathbf{x} = [x \quad \dot{x} \quad y \quad \dot{y}]$; x 和 y 分别表示 x 和 y 方向上目标的位置, 而 \dot{x} 和 \dot{y} 则分别表示 x 和 y 方向上目标的速度; T 为采样时间间隔; 系统噪声 $\mathbf{v}_k \sim N(0, \mathbf{Q}_{k-1})$, 其中: $\mathbf{Q}_{k-1} = \text{diag}[\eta \mathbf{M} \quad \eta \mathbf{M}]$;

$$\mathbf{M} = \begin{bmatrix} T^3/3 & T^2/2 \\ T^2/2 & T \end{bmatrix}。$$

根据雷达测站的位置, 可得目标的距离 r_k 和方位 θ_k 。因此, 观测方程为

$$\begin{pmatrix} r_k \\ \theta_k \end{pmatrix} = \begin{bmatrix} \sqrt{x_k^2 + y_k^2} \\ \arctan\left(\frac{x_k}{y_k}\right) \end{bmatrix} + \mathbf{w}_k \quad (26)$$

其中观测噪声为 $\mathbf{w}_k \sim N(0, \mathbf{R})$, $\mathbf{R} = \text{diag}[\sigma_r^2 \quad \sigma_\theta^2]$ 。初始数据为 $T = 1$ s; $\Omega = -3$ ($^\circ$)/s; $\sigma_r = 10$ m; $\sigma_\theta = \sqrt{10}$ mrad。真实初始状态为 $\mathbf{x}_0 = [1000 \text{ m} \quad 300 \text{ m/s} \quad 1000 \text{ m} \quad 0 \text{ m/s}]$; 初始协方差为 $\mathbf{P}_{010} = \text{diag}[100 \text{ m}^2 \quad 10 \text{ m}^2/\text{s} \quad 100 \text{ m}^2 \quad 10 \text{ m}^2/\text{s}]$ 。初始估计状态为 $\hat{\mathbf{x}}_{010} \sim N(\mathbf{x}_0, \mathbf{P}_{010})$ 。

3.1.2 仿真场景

系统噪声和量测噪声均为独立的零均值高斯白噪声, 系统噪声的统计特性未知, 分别根据不同的系统噪声特性设置了场景1、场景2以及场景3。

场景1: $\mathbf{Q}_k = \text{diag}[\eta_1 \mathbf{M} \quad \eta_1 \mathbf{M}]$, $\eta_1 \in [1, 100]$ 。

场景2: $\mathbf{Q}_k = \text{diag}[\eta_3 \mathbf{M} \quad \eta_3 \mathbf{M}]$ 。

场景3: $\mathbf{Q}_k = \begin{cases} \text{diag}[\eta_2 \mathbf{M} \quad \eta_2 \mathbf{M}], & 1 \leq k \leq 30 \\ \text{diag}[\eta_3 \mathbf{M} \quad \eta_3 \mathbf{M}], & 31 \leq k \leq 70 \\ \text{diag}[\eta_4 \mathbf{M} \quad \eta_4 \mathbf{M}], & 71 \leq k \leq 100 \end{cases}$ 。

其中: $\eta_2 = 10$; $\eta_3 = 40$; $\eta_4 = 90$ 。

3.2 仿真结果

对 ASCKF 算法和先验过程噪声 $\mathbf{Q}_0 = \text{diag}[\eta_1 \mathbf{M} \quad \eta_1 \mathbf{M}]$, $\eta = 0.1 \text{ m}^2/\text{s}^3$ 的标准 SCKF 算法分别做 250 次独立蒙特卡罗仿真, 每次仿真的采样次数为 100 次, 遗忘因子 $b = 0.97$ 。仿真试验的位置均方根误差 (Root Mean Square Error, RMSE) 定义为

$$R_{\text{RMSE}_{\text{pos}(k)}} = \sqrt{\frac{1}{N} \sum_{n=1}^N ((x_k^n - \hat{x}_k^n)^2 + (y_k^n - \hat{y}_k^n)^2)} \quad (27)$$

其中: $(x_k^n \quad y_k^n)$ 和 $(\hat{x}_k^n \quad \hat{y}_k^n)$ 是第 n 次蒙特卡罗仿真的第 k 次采样目标位置的真正值和估计值; N 为蒙特卡罗仿真次数。按照式(27), 类似定义速度 RMSE。

场景1中 $\eta_1 \in [1, 100]$, 为此范围内的整数。图1表示 η_1 的取值逐渐增大时, SCKF 和 ASCKF 的位置和速度 RMSE 的均值比较。由图1可看出, SCKF 算法的位置和速度跟踪误差都会随 η_1 的增大而缓慢增大; 而

ASCKF 算法可有效减小由系统噪声未知而引起的位
置跟踪误差。系统噪声的变化对速度均方根误差的影
响不如对位置均方根误差的影响大,在未知实际系统
噪声与先验噪声相差不大时,ASCKF 对于目标速度跟
踪的效果略差于 SCKF 算法,但随着 η_1 值的逐渐增
大,ASCKF 算法对速度的跟踪效果将逐渐优于 SCKF
算法。




图 1 场景 1 位置和速度均方根误差均值比较

Fig.1 Average RMSE of position and velocity for scenario 1

场景 2 中目标的真实运动轨迹如图 2 所示。图 3
为场景 2 中 SCKF、ASCKF 以及真实 RMSE 的距离和速
度均方根误差曲线的比较。表 1 是场景 2 中 SCKF 和
ASCKF 的位置和速度均方根误差的均值和方差统计
数据。




图 2 场景 2 目标真实轨迹

Fig.2 Target trajectory of scenario 2




图 3 场景 2 位置和速度均方根误差比较

Fig.3 RMSE of position and velocity for scenario 2

表 1 场景 2 性能比较

Table 1 Comparison of performance for scenario 2

算法	位置误差 均值/m	速度误差 均值/(m·s ⁻¹)	位置误差 方差/m	速度误差 方差/(m·s ⁻¹)
SCKF	108.035	22.749	59.345	10.748
ASCKF	27.344	17.609	16.895	8.560

由图 3 可知在未知定常系统噪声背景下,当先验
噪声统计特性和系统噪声统计特性差异较大时,采用
标准 SCKF 算法得到目标的位置均方根误差很大,无
法准确显示目标位置的变化,而 ASCKF 算法却能够有
效地减小目标跟踪的位置误差,提高跟踪精度。由图 3
还可知,ASCKF 算法跟踪的目标速度均方根误差同样
小于标准 SCKF 算法得到的速度均方根误差。表 1 中
的数据可以验证以上分析。

场景 3 中目标的真实运动轨迹如图 4 所示。图 5
分别为场景 3 中 ASCKF、SCKF 以及真实 RMSE 算法
的距离和速度均方根误差曲线的比较。表 2 是场景 3
下 ASCKF 和 SCKF 均方根误差的均值和方差统计
数据。




图 4 仿真场景 3 目标真实轨迹

Fig.4 Target trajectory of scenario 3




图 5 场景 3 位置和速度均方根误差比较

Fig.5 RMSE of position and velocity for scenario 3

表 2 仿真场景 3 性能比较

Table 2 Comparison of performance for scenario 3

算法	位置误差 均值/m	速度误差 均值/(m·s ⁻¹)	位置误差 方差/m	速度误差 方差/(m·s ⁻¹)
SCKF	44.996	16.234	34.874	9.746
ASCKF	20.160	15.868	11.351	9.293

由图 5 可知,在系统噪声未知时变且与先验噪声存在一定差异的情况下,采用标准 SCKF 算法跟踪目标位置 RMSE 很大,而采用 ASCKF 算法跟踪能够有效地抑制目标跟踪的发散,从而减小跟踪误差,提高了跟踪精度。而从图 5 中还可得到,ASCKF 算法和标准 SCKF 均能在一定程度上减小速度跟踪误差,特别是在跟踪后期,当跟踪趋于稳定状态时,自适应 SCKF 算法的跟踪性能明显优于标准 SCKF 算法。由表 2 数据同样可知,此时 ASCKF 算法的性能要优于标准 SCKF 算法。

由此可见,基于 Sage-Husa 估计器的 ASCKF 算法在系统噪声未知恒定和系统噪声未知时变的两个仿真试验中,均能有效解决由于滤波统计特性不能精确已知而引起的滤波不稳定问题,并大为提高滤波精度。但显然在系统统计特性未知恒定的情况下,未知噪声统计特性估计更简单,因此滤波效果更好。仿真结果也证明 ASCKF 算法在以上 3 个场景中均可取得比 SCKF 算法更好的滤波效果。

4 结束语

针对标准 SCKF 算法在系统噪声未知时变情况下易出现滤波精度下降甚至发散的问题,提出基于改进 Sage-Husa 估计器的 ASCKF 算法。该算法在滤波过程中能实时估计和修正系统噪声,从而改善滤波精度和稳定性。仿真结果表明,ASCKF 算法在统计噪声未知时变的情况下对机动目标的跟踪效果要明显优于标准 SCKF 算法。但本算法存在一定局限性,在系统噪声与先验系统噪声相差不大时,算法对于速度的跟踪效果略差,在后续研究中将着重解决该问题。

参 考 文 献

- [1] ARASARA I, HAYKIN S. Cubature Kalman filter [J]. IEEE Transactions on Automatic Control, 2009, 54 (6): 1254-1260.
- [2] 杨艳成,张丽珂,郭永亮. 一种“当前统计”模型的模糊自适应算法[J]. 指挥控制与仿真, 2011, 33 (3): 46-49.
- [3] 陈海,单甘霖. 基于 IMMCKF 机动目标跟踪算法[J]. 电光与控制, 2011, 18 (10): 1-5.
- [4] SAGE A, HUSA G W. Adaptive filtering with unknown prior statistics [C]//Proceedings of Joint Automatic Control Conference. Boulder, USA: American Society of Mechanical Engineers, 1969:760-769.
- [5] 石勇,韩崇昭. 自适应 UKF 算法在目标跟踪中的应用[J]. 自动化学报, 2011, 37 (6): 754-759.
- [6] 赵琳,王小旭,孙明,等. 基于极大后验估计和指数加权的自适应 UKF 滤波算法[J]. 自动化学报, 2010, 36 (7): 1007-1019.
- [7] 周卫东,乔相伟,吉宇人,等. 基于新息和残差的自适应 UKF 算法[J]. 宇航学报, 2010, 31 (7): 1798-1804.
- [8] 张品秀,黄操军,乔相伟. 基于自适应扩展 Kalman 滤波的 SINS/GPS 深组合研究[J]. 传感技术学报, 2010, 23 (3): 408-412.
- [9] 张常云. 自适应滤波方法研究[J]. 航空学报, 1998, 19 (7): 96-99.
- [10] 齐立峰,陶剑锋,冯新喜,等. 一种改进的 UKF 非线性滤波器研究[J]. 弹箭与制导学报, 2011, 31 (2): 179-188.
- [11] BAR SHALOM Y, LI X R, KIRUBARAJAN T. Estimation with applications to tracking and navigation [M]. New York: Wiley & Sons, 2001:182-183.

下 期 要 目

基于代价函数修正的异类传感器数据关联算法
 基于多分辨分析的红外/被动毫米波图像主成分融合
 一种突出边缘特征的遥感图像快速融合方法
 基于 NSCT 的红外与可见光图像融合
 激光主动成像技术应用及发展
 单兵作战系统中信息监听冲突消除技术研究

大气湍流退化图像过渡区域细化算法
 PRS 前沿判别法抗三点源诱偏性能研究
 约束同时扰动随机逼近的鲁棒自适应波束形成
 基于网格连通的联合概率数据关联算法
 编队协同作战目标分配建模综述