

非线性系统的异步多速率数据融合估计算法研究

闫莉萍, 邓志红, 付梦印
(北京理工大学自动化学院, 北京 100081)

摘 要: 研究了一类非线性时变动态系统的状态估计问题, 在不同传感器以不同采样率异步对同一目标进行观测时, 提出了一种有效的数据融合估计算法. 通过建立多尺度模型, 将异步多速率系统形式转化为同步多速率系统; 在每一步分别进行状态的预测和更新. 在状态和观测预测时, 采用强跟踪滤波 (STF) 算法; 在状态更新时, 采用有反馈分布式结构, 顺序的利用每一个传感器的观测信息去更新状态的估计; 从而基于给定的非线性系统模型, 得到融合所有异步、多速率传感器观测信息的状态估计结果. 该方法不需要对状态或观测进行扩维, 计算量适当, 从而保证了算法的实时性. 仿真结果验证了算法的有效性.

关键词: 数据融合; 非线性系统; 异步; 多速率; 强跟踪滤波

中图分类号: TN911.72 **文献标识码:** A **文章编号:** 0372-2112 (2009) 12-2735-06

Study of Asynchronous Multirate Data Fusion Estimation Algorithm Based on Nonlinear Systems

YAN Li-ping, DENG Zhi-hong, FU Meng-yin
(Beijing Institute of Technology, School of Automation, Beijing 100081, China)

Abstract: A kind of time-vary nonlinear dynamic system is studied in this paper. An effective data fusion state estimation algorithm is presented in time of multiple sensors observing a single target with different sampling rates asynchronously. The asynchronous multirate system is transformed to synchronous multirate system by use of the established multiscale models. In each step, to get the state estimate, state prediction is followed by state update. In state and measurements prediction step, strong tracking filter (STF) is used. While, in state update step, distributed structure with feedback is used, and the fused state estimate is obtained by sequentially use of the measurements observed by different sensors. The augmentation of state or measurement dimensions are avoided by use of the presented method, and the real-time property of the algorithm is guaranteed. Simulation results show the effectiveness of the proposed algorithm.

Key words: data fusion; nonlinear system; asynchronous; multirate; strong tracking filter

1 引言

非线性系统的状态估计利用最多的是扩展 Kalman 滤波 (Extended Kalman filter: EKF)^[1]. EKF 的基本思想是将非线性系统进行线性化, 而后运用广义 Kalman 滤波技术进行状态估计. 这样, 在估计的过程中引入了线性化误差, 线性化处理的效果直接影响了最终的状态估计结果. 此外, EKF 需要计算 Jacobi 矩阵, Jacobi 矩阵计算的不准确会带来滤波发散的问题.

伪量测变换估计器 (PLE) 是通过伪量测变换重新构造量测, 使得量测矩阵成为量测角的函数, 并且具有线性形式^[2]. 该方法缓解了 EKF 由于 Jacobi 矩阵计算不

准确带来的滤波发散的问题, 同时具有形式简单, 计算量小的优点. 然而, 该方法由于量测矩阵与等价噪声的相互关联, 得到的状态估计一般是有偏的.

粒子滤波技术是另一类非线性滤波方法^[3,4], 它是一种基于 Bayes 原理用粒子概率密度表示的序贯 Monte Carlo 方法, 适用于任何能用状态空间模型以及用传统 Kalman 滤波表示的非线性系统. 包括 Bayes 滤波器、序贯重要采样法 (SIS) 及其各种修正算法等. Bayes 滤波原理的实质是试图构造状态变量的后验概率密度, 从中得到状态的最优估计. 与 Kalman 滤波类似, Bayes 滤波也包含预测和更新两个阶段. 预测过程用系统模型来预测状态的先验概率密度, 更新过程则使用最近的量测值

收稿日期: 2008-12-11; 修回日期: 2009-07-07

基金项目: 国家自然科学基金 (No. 60773044); 教育部创新团队支持计划资助项目

进行修正,得到后验概率密度.但 Kalman 滤波中的概率密度函数可以通过高斯函数的均值和方差来表征,而对于一般的非线性系统, Bayes 滤波没有通用的概率密度形式.序贯重要采样法是通过 Monte Carlo 模拟实现递推 Bayes 滤波器的技术.其核心思想是利用随机样本的加权和表示所需的后验概率密度得到状态的估计值.这样,当样本点增至无穷大, Monte Carlo 特性与后验概率密度的函数表示等价, SIS 滤波器接近于最优 Bayes 估计.

Sigma 点 Kalman 滤波方法 (SPKF) 是一类被广泛研究和应用的非线性滤波方法,根据变换矩阵和实现方法的不同,可分为平淡 Kalman 滤波 (Unscented Kalman filter: UKF)、中心分布 Kalman 滤波 (Central Difference Kalman filter: CDKF)、平方根 UKF (Square - Root UKF: SPUKF)、平方根中心分布 Kalman 滤波 (Square - Root Central Difference Kalman filter: SPCDKF), 等等^[5~7]. 它们的实现方法大同小异,以 UKF 最为著名. UKF 是由 Julier 和 Uhlmann 提出的,其基本思想不同于扩展 Kalman 滤波,它是通过设计少量的点,由点经由非线性函数的传播来实现的.扩展 Kalman 滤波是基于非线性函数的一阶 Taylor 展开来实现的,所以,一般只对线性或近似线性系统具有比较好的效果.而 UKF 是用若干个服从高斯分布的函数的组合来驱动的,一般可达到二阶精度,在某些情况下,逼近精度可达三阶.然而,仔细分析不难发现: SPKF 除了利用若干高斯分布的组合代替传统 EKF 的高斯分布的噪声激励外,在滤波过程中,其基本思想依然是 Kalman 滤波,因此,在线性系统滤波中存在鲁棒性差缺陷的 Kalman 滤波的诸多缺点在 SPKF 中依然存在.

强跟踪滤波 (Strong Tracking Filter: STF) 是另外一类被广泛应用的非线性滤波方法^[8,9]. 其首先是由清华大学的周东华教授在上世纪 90 年代提出的,随后的十多年间,该方法被广泛应用于故障诊断、容错控制、机器人控制等多种应用领域.该方法的基本思想在于正交原理的实现,其核心在于强迫不同时刻之间的残差正交,从而实现观测值的充分利用.该方法也是一种实时滤波方法,状态的估计通过在线递推实现,计算量适当.

本文尝试将 STF 算法推广用于非线性、异步、多速率采样多传感器的数据融合状态估计问题中,推导出了相应的数据融合算法,仿真结果验证了算法的有效性.

2 问题描述

有 N 个传感器对同一目标进行观测的异步、多速率传感器、单模型离散非线性动态系统可描述为^[9,10]

$$x(k+1) = f(x(k)) + G(k)u(k) + w(k) \quad (1)$$

$$y_i(k) = h(x_i(k)) + v_i(k); i = 1, 2, \dots, N \quad (2)$$

其中,式(1)为系统方程, $x(k) \in R^n$ 表示最高采样速率 S_N 下 k 时刻的状态变量. $f(\cdot)$ 为过程模型,其由非线性映射 f 唯一确定. $u(k) \in R^l$ 是控制信号, $G(k) \in R^{n \times l}$ 是控制增益. 系统噪声 $w(k) \in R^n$ 是高斯白噪声,且 $w(k) \sim N(0, Q(k))$.

有 N 个传感器对目标进行观测,观测方程如式(2)所示,其中 $y_i(k) \in R^{q_i}$ 表示采样率为 S_i 的第 i 个传感器的第 k 次观测. $h(\cdot)$ 为观测模型,其由非线性映射 h 唯一确定. 其中, $i(1 \leq i \leq N)$ 表示第 i 个传感器,同时也表示第 i 尺度. 具有最高采样率的传感器 N 具有最细的尺度. 不同传感器之间的采样可以是非同步、不均匀的,采样率之间满足下列关系:

$$S_N = n_i S_i, 1 \leq i \leq N-1 \quad (3)$$

其中, n_i 是正整数. $y_i(k) \in R^{q_i}$ 观测的状态假设满足:

$$x_i(k) = f_i(x(n_i(k-1)+1)), i = 1, 2, \dots, N \quad (4)$$

其中, f_i 由 f 、 $x(n_i(k-1)+1)$ 和 $G(n_i(k-1)+1)$, $u(n_i(k-1)+1)$; $l = 1, 2, \dots, n_i$ 确定. 可近似的由下式略去状态转移时的噪声项得到:

$$x_i(k) = \frac{1}{n_i} \left(\sum_{l=1}^{n_i} x_i(n_i(k-1)+l) \right), i = 1, 2, \dots, N(5)$$

特别的,当 $u(k) = 0$ 时,有:

$$f_i = \frac{1}{n_i} \left(\sum_{j=0}^{n_i-1} f^j \right), i = 1, 2, \dots, N \quad (6)$$

其中,记 $n_N = 1$, $f_N = I$ 表示恒等变换,即 $x_N(k) = x(k)$.

观测误差 $v_i(k) \in R^{q_i}$ 假设为高斯白噪声: $v_i(k) \sim N(0, R_i(k))$. 并且,假设 $w(k)$ 与 $v_i(k)$ 统计独立.

初始状态向量 $x(0)$ 是一个随机向量,其均值和方差分别为 x_0 和 P_0 . 同时假设 $x(0)$ 、 $w(k)$ 与 $v_i(k)$ 彼此统计不相关.

本文的目的在于融合各个传感器的观测信息以获得最高采样率下状态的最优估计值.

3 基于 STF 估计非线性系统状态的融合算法

由式(2)和式(4),可得

$$\begin{aligned} y_i(k) &= h(f_i(x(n_i(k-1)+1))) + v_i(k) \\ &= (h \circ f_i)(x(n_i(k-1)+1)) + v_i(k) \\ &\triangleq h_i(x(n_i(k-1)+1)) + v_i(k) \end{aligned} \quad (7)$$

其中, $h_i = h \circ f_i$ 表示新的观测算子.

当 $(k-1) \bmod n_i = 0$ 时,式(7)可改写为

$$y_i\left(\frac{k-1}{n_i} + 1\right) = h_i(x(k)) + v_i\left(\frac{k-1}{n_i} + 1\right) \quad (8)$$

对 $i = 1, 2, \dots, N$, 定义

$$Y_1^k(i) \triangleq \{y_i(1), y_i(2), \dots, y_i(k)\} \quad (9)$$

和

$$\hat{x}(k|k) \triangleq E\{x(k) | Y_1^{\lfloor \frac{k-1}{n_i} \rfloor + 1}(i); i=1, 2, \dots, N\} \quad (10)$$

$$\hat{x}_i(k|k) \triangleq E\{x(k) | Y_1^{\lfloor \frac{k-1}{n_i} \rfloor + 1}(j), j=1, 2, \dots, N; y(i, \frac{k-1}{n_i} + 1)\} \quad (11)$$

$$\hat{x}_{1,2,\dots,l}(k|k) \triangleq E\{x(k) | Y_1^{\lfloor \frac{k-1}{n_i} \rfloor + 1}(j), j=1, 2, \dots, N; y(i_p, \frac{k-1}{n_{i_p}} + 1), p=1, 2, \dots, l\} \quad (12)$$

其中,式(9)中的 $Y_1^k(i)$ 表示传感器 i 观测的第 1 到第 k 个观测值. $\hat{x}(k|k)$ 和 $\hat{x}_{1,2,\dots,l}(k|k)$ 分别为 $x(k)$ 在信息 $\left\{ Y_1^{\lfloor \frac{k-1}{n_i} \rfloor + 1}(i) \right\}_{i=1,2,\dots,N}$ 和 $\left\{ Y_1^{\lfloor \frac{k-1}{n_j} \rfloor + 1}(j) \right\}_{j=1,2,\dots,N}$ 条件下的期望. $[a]$ 表示大于等于 a 的最小正整数.

对非线性动态系统(1)~(2),若非线性函数 $f(\cdot)$ 和 $h(\cdot)$ 具有关于状态的一阶连续偏导数,则基于 STF 对该系统进行状态估计的算法如下:假设已知 $k-1$ 时刻状态的估计值 $\hat{x}(k-1|k-1)$ 和相应的估计误差协方差矩阵 $P(k-1|k-1)$,那么 k 时刻的状态的估计值和相应的估计误差协方差矩阵,即 $\hat{x}(k|k)$ 和 $P(k|k)$ 可由下面的步骤获得:

(1)在时刻 $k=1, 2, \dots$, 若对任意 $i=1, 2, \dots, N-1, (k-1) \bmod n_i \neq 0$, 那么

$$\hat{x}(k|k) = \hat{x}_N(k|k) \quad (13)$$

$$P(k|k) = P_N(k|k) \quad (14)$$

其中,

$$\hat{x}_N(k|k) = \hat{x}_N(k|k-1) + K_N(k) \tilde{y}_N(k) \quad (15)$$

$$P_N(k|k) = P_N(k|k-1) - K_N(k) P_{\tilde{y}_N}(k) K_N^T(k) \quad (16)$$

$$\hat{x}_N(k|k-1) = f(\hat{x}(k-1|k-1)) + G(k-1)u(k-1) \quad (17)$$

$$P_N(k|k-1) = {}_N(k) F(\hat{x}(k-1|k-1)) P(k-1|k-1) + F^T(\hat{x}(k-1|k-1)) Q(k-1) \quad (18)$$

$$\tilde{y}_N(k) = y_N(k) - \hat{y}_N(k) = y_N(k) - h(\hat{x}_N(k|k-1)) \quad (19)$$

$$K_N(k) = P_{\tilde{y}_N}(k) P_{\tilde{y}_N}^{-1}(k) \quad (20)$$

$$P_{\tilde{y}_N}(k) = E\{[x(k) - \hat{x}(k|k-1)] [y_N(k) - \hat{y}_N(k)]\} = P_N(k|k-1) H_N^T(\hat{x}_N(k|k-1)) \quad (21)$$

$$P_{\tilde{y}_N}(k) = H_N(\hat{x}_N(k|k-1)) P_N(k|k-1) + R_N^T(\hat{x}_N(k|k-1)) + R_N(k) \quad (22)$$

其中, ${}_N(k) < 1$ 为自适应渐消因子. 可以由下面的方法确定:

$${}_N(k) = \begin{cases} 0, {}_N(k), & 0, {}_N(k) < 1 \\ 1, & 0, {}_N(k) < 1 \end{cases} \quad (23)$$

其中,

$$0, {}_N(k) = \frac{\text{tr}(N_N(k))}{\text{tr}(M_N(k))} \quad (24)$$

$$N_N(k) = V_N(k) - H_N(\hat{x}_N(k|k-1)) Q(k-1) H_N^T(\hat{x}_N(k|k-1)) - l(k) R_N(k) \quad (25)$$

$$M_N(k) = H_N(\hat{x}_N(k|k-1)) F(\hat{x}_N(k|k-1)) P(k-1|k-1) + F^T(\hat{x}_N(k|k-1)) H_N^T(\hat{x}_N(k|k-1)) \quad (26)$$

$$V_N(k) = \begin{cases} \tilde{y}_N(1) \tilde{y}_N^T(1), & k=0 \\ \frac{V_N(k-1) + \tilde{V}_N(k) \tilde{V}_N^T(k)}{1 + d_k}, & k=1 \end{cases} \quad (27)$$

其中,

$$H_N(\hat{x}_N(k|k-1)) = \left. \frac{\partial h_N(x(k))}{\partial x} \right|_{x(k) = \hat{x}_N(k|k-1)} \quad (28)$$

$$F(\hat{x}_N(k|k-1)) = \left. \frac{\partial f(x(k))}{\partial x} \right|_{x(k) = \hat{x}_N(k|k-1)} \quad (29)$$

$$h_N = h \quad (30)$$

$l(k) < 1$ 为弱化因子,特别的,可以取

$$l(k) = 1 - d_k \quad (31)$$

其中,

$$d_k = \frac{1 - 0.95^k}{1 - 0.95^{k+1}} \quad (32)$$

其中,0.95~0.995 为遗忘因子.

(2)在时刻 $k=1, 2, \dots$, 若存在一个传感器 $i(1 \leq i \leq N-1)$, 满足 $(k-1) \bmod n_i = 0$, 那么

$$\hat{x}(k|k) = \hat{x}_N(k|k) + K_i(\frac{k-1}{n_i} + 1) \tilde{y}_i(\frac{k-1}{n_i} + 1) \quad (33)$$

$$P(k|k) = P_N(k|k) - K_i(\frac{k-1}{n_i} + 1) P_{\tilde{y}_i}(\frac{k-1}{n_i} + 1) K_i^T(\frac{k-1}{n_i} + 1) \quad (34)$$

其中, $\hat{x}_N(k|k)$ 和 $P_N(k|k)$ 由式(15)~(32)计算. 而 $K_i(\frac{k-1}{n_i} + 1)$, $\tilde{y}_i(\frac{k-1}{n_i} + 1)$ 和 $P_{\tilde{y}_i}(\frac{k-1}{n_i} + 1)$ 的计算如下:

$$\tilde{y}_i(\frac{k-1}{n_i} + 1) = y_i(\frac{k-1}{n_i} + 1) - h_i(\hat{x}_N(k|k)) \quad (35)$$

$$K_i(\frac{k-1}{n_i} + 1) = P_{\tilde{y}_i}(\frac{k-1}{n_i} + 1) P_{\tilde{y}_i}^{-1}(\frac{k-1}{n_i} + 1) \quad (36)$$

$$P_{\tilde{y}_i}(\frac{k-1}{n_i} + 1) = H_i(\hat{x}_N(k|k)) P_N(k|k) H_i^T(\hat{x}_N(k|k)) + R_i(\frac{k-1}{n_i} + 1) \quad (37)$$

$$P_{\tilde{y}_i}(\frac{k-1}{n_i} + 1) = E\{[x(k) - \hat{x}_N(k|k)] \tilde{y}_i^T(\frac{k-1}{n_i} + 1)\}$$

$$= P_N(k|k) H_i^T(\hat{x}_N(k|k)) \quad (38)$$

其中,

$$H_i(\hat{x}_N(k|k)) = \left. \frac{\partial h_i(x(k))}{\partial x} \right|_{x(k)=\hat{x}_N(k|k)}, h_i = h \cdot f_i \quad (39)$$

(3) 在时刻 $k = 1, 2, \dots$, 若存在 j 个传感器, 即, 传感器 $i_1, i_2, \dots, i_j (N \ i_1 \ i_2 \ \dots \ i_j \ 1)$ 满足 $(k-1) \bmod n_p = 0, p = 1, 2, \dots, j$, 那么

$$\hat{x}(k|k) = \hat{x}_{i_1, i_2, \dots, i_j}(k|k) \quad (40)$$

$$P(k|k) = P_{i_1, i_2, \dots, i_j}(k|k) \quad (41)$$

其中, 对 $l = 1, 2, \dots, j$, 有

$$\hat{x}_{i_1, i_2, \dots, l}(k|k) = \hat{x}_{i_1, i_2, \dots, (l-1)}(k|k) + K_i(l, \frac{k-1}{n_i} + 1)$$

$$[y_{i_l}(\frac{k-1}{n_i} + 1) - \hat{y}_{i_l}(\frac{k-1}{n_i} + 1)] \quad (42)$$

$$P_{i_1, i_2, \dots, l}(k|k) = P_{i_1, i_2, \dots, (l-1)}(k|k) - K_i(\frac{k-1}{n_i} + 1)$$

$$P_{y_{i_l}}(\frac{k-1}{n_i} + 1) K_i^T(\frac{k-1}{n_i} + 1) \quad (43)$$

和

$$\hat{x}_{i_0}(k|k) = \hat{x}_N(k|k) \quad (44)$$

$$P_{i_0}(k|k) = P_N(k|k) \quad (45)$$

$$K_i(\frac{k-1}{n_i} + 1) = P_{\tilde{y}_{i_l}}(\frac{k-1}{n_i} + 1) P_{y_{i_l}}^{-1}(\frac{k-1}{n_i} + 1) \quad (46)$$

$$\tilde{y}_{i_l}(\frac{k-1}{n_i} + 1) = y_{i_l}(\frac{k-1}{n_i} + 1) - H_i(\hat{x}_{i_1, i_2, \dots, (l-1)}(k|k)) \quad (47)$$

$$P_{y_{i_l}}(\frac{k-1}{n_i} + 1) = H_i(\hat{x}_{i_1, i_2, \dots, (l-1)}(k|k)) P_{i_1, i_2, \dots, (l-1)}(k|k)$$

$$H_i^T(\hat{x}_{i_1, i_2, \dots, (l-1)}(k|k)) + R_{i_l}(\frac{k-1}{n_i} + 1) \quad (48)$$

$$P_{\tilde{y}_{i_l}}(\frac{k-1}{n_i} + 1) = E\{[x(k) - \hat{x}_{i_1, i_2, \dots, (l-1)}(k|k)] \tilde{y}_{i_l}^T(\frac{k-1}{n_i} + 1)\} \\ = P_{i_1, i_2, \dots, (l-1)}(k|k) H_i^T(\hat{x}_{i_1, i_2, \dots, (l-1)}(k|k)) \quad (49)$$

其中,

$$H_i(\hat{x}_N(k|k)) = \left. \frac{\partial h_i(x(k))}{\partial x} \right|_{x(k)=\hat{x}_N(k|k)}, h_i = h \cdot f_i \quad (50)$$

$\hat{x}_N(k|k)$ 和 $P_N(k|k)$ 由式(15) ~ (32) 计算.

算法流程如图 1 所示.

4 实验验证

本节将用实例验证算法的有效性, 并将第 3 节所示的算法与 EKF 进行比较.

一艘轮船的推进系统模型为^[9]:

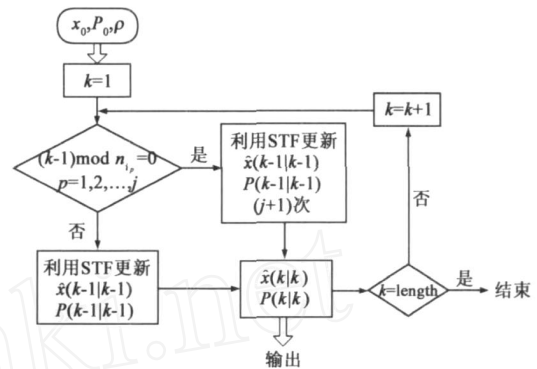


图1 算法流程图

$$x(k+1) = 0.1ax^2(k) + x(k) + 0.1bu(k) + w(k) \quad (51)$$

$$z_i(k) = x_i(k) + v_i(k); \quad i = 1, 2, 3 \quad (52)$$

其中, 参数 a 表示船体所受到的阻力, b 是船发动机的功率, x 是船行驶的速度. 参数 a 和 b 的正常值分别为: $a_0 = -0.58$ 和 $b_0 = 0.2$. 动态系统建模噪声是零均值的高斯白噪声, 协方差为 $Q(k) = 10^{-6}$. 控制信号 $u(k)$ 是幅值在 $0.9 \sim 1.1$ 之间、周期为 200 的正弦信号. 有两个传感器分别对状态变量进行观测, 观测噪声是协方差为 $R_1(k) = 10^{-4}$, $R_2(k) = 4 \times 10^{-4}$ 和 $R_3(k) = 9 \times 10^{-4}$ 的零均值白噪声序列, 三个传感器的采样率之比为 2 3 6. 系统初始值为 $x(0) = 0$, 算法初始值为 $\hat{x}(0|0) = 0$, $P(0|0) = 100$.

为了验证算法的有效性, 我们分以下 4 种情况分别进行仿真实验:

情况 1. 模型是准确的, 即, $a = a_0, b = b_0$.

情况 2. 模型参数存在较小偏差, 控制项无偏差, 即, $a = 0.75a_0, b = b_0$.

情况 3. 模型参数是准确的, 控制项存在偏差, 即, $a = a_0, b = 1.5b_0$.

情况 4. 模型和控制项都存在偏差, 即, $a = 0.75a_0, b = 1.5b_0$.

在进行状态估计时, 取遗忘因子 $\lambda = 0.95$.

表 1 估计误差绝对值均值

	参数	传感器	EKF	STF
情况 1	$a = a_0$ $b = b_0$	传感器 3	0.0027	0.0140
		传感器 3, 2, 1 的融合	0.0022	0.0031
情况 2	$a = 0.75a_0$ $b = b_0$	传感器 3	0.0732	0.0175
		传感器 3, 2, 1 的融合	0.0504	0.0141
情况 3	$a = a_0$ $b = 1.5b_0$	传感器 3	0.1194	0.0200
		传感器 3, 2, 1 的融合	0.0934	0.0193
情况 4	$a = 0.75a_0$ $b = 1.5b_0$	传感器 3	0.1300	0.0196
		传感器 3, 2, 1 的融合	0.0918	0.0180

各种情况下的估计误差绝对值均值如表 1 所示. 在模型准确时(情况 1), EKF 的估计结果优于 STF. 而在模型参数存在偏差时(情况 2 ~ 情况 4), 均有 STF 的估计

误差绝对值均值小于同等条件下 EKF 的. 因此, 从表 1 可知, STF 在对模型的鲁棒性方面, 大大优于 EKF. 此外, 就各种情况(情况 1~情况 4), 对 EKF 和 STF, 均有: 融合估计误差绝对值均值小于基于传感器 3 的观测信息得到的估计结果. 可见, 融合算法是有效的.

图 2~图 6 是仿真曲线. 图 2 为状态实际值和三个传感器的观测值, 其中, (a) 表示原始信号, (b)、(c)、(d) 依次表示传感器 1、传感器 2 和传感器 3 的观测曲线, 在同一段时间内, 三个传感器的采样点数分别为 200、300 和 600. 图 3~图 6 分别是 4 种情况的估计曲线, 其中, (a)、(b)、(c)、(d) 中的实线均为原始信号 (x), 而虚线则分别表示基于传感器 3 的观测 Kalman 滤波的结果 (x_e -EKF)、利用 Kalman 滤波融合 3 个传感器的估计结果 (x_{ef} -EKF)、利用 STF 滤波传感器 3 的结果 (x_e -STF)、利用 STF 融合 3 个传感器的估计结果 (x_{ef} -STF).




图2 原始信号和观测信号




图3 第1种情况下的估计曲线

观察图 3~图 6 可以看出:(1) 在模型准确时, EKF、STF 算法都是有效的, 在利用相同数据的情况下, 比较起来, EKF 得到的估计结果更为平滑一些;(2) 在模型或控制项存在一定偏差时, EKF 的估计结果出现了比较大的偏差, 完全不可用(观察图 4~图 6 的 (a)、(b) 子图); 而此时, STF 的跟踪估计结果却比较好(观察图 4~图 6




图4 第2种情况下的估计曲线




图5 第3种情况下的估计曲线




图6 第4种情况下的估计曲线

的 (c)、(d) 子图); (3) 比较基于单个传感器的观测得到的估计和融合三个传感器信息得到的估计(分别比较图 3~图 6 的 (a)、(b) 子图, 和 (c)、(d) 子图), 可以看出, 融合估计结果更为平滑.

综上, 可以得出结论:(1) 融合算法是有效的;(2) 在算法的鲁棒性方面, STF 优于 EKF;(3) STF 推广用于非线性系统异步多速率数据融合估计是有效的.

5 结论

针对一类非线性时变动态系统,本文推导出了 STF 在融合多传感器异步多速率观测数据时的状态估计算法.仿真结果表明,算法是有效的,并且对模型参数和控制项的不确定性都具有很好的鲁棒性.

本文推导出的算法在航空导航、制导、机动目标跟踪,以及包括机器人导航等在内的诸多军、民用领域都具有广泛的推广应用价值.

参考文献:

- [1] Chui C K, Chen G. Kalman Filtering: With Real-Time Applications[M]. New York: Springer, 1999, 18 - 65.
- [2] 康健, 司锡才. 被动定位跟踪中的非线性滤波技术[J]. 系统工程与电子技术, 2004, 26(2): 160 - 162.
Kang J, Si X C. Nonlinear filtering techniques for passive locating and tracking[J]. Journal of Systems Engineering and Electronics, 2004, 26(2): 160 - 162. (in Chinese)
- [3] 文成林. 多尺度动态建模理论及其应用[M]. 北京: 科学出版社, 2007, 323 - 342.
- [4] Henk A P B, Edwin A B. Particle filtering for stochastic hybrid systems[A]. 43rd IEEE Conference on Decision and Control [C]. Atlantis, Paradise Island, Bahamas: IEEE, 2004. 3221 - 3226.
- [5] Rudolph V D M, Eric A W, Simon I J. Sigma-Point Kalman filters for nonlinear estimation and sensor fusion applications to integrated navigation [A]. AIAA Guidance, Navigation, and Control Conference and Exhibit [C]. Providence, Rhode Island: AIAA, 2004, 5120: 1 - 30.
- [6] Simon J J, Jeffrey K U. Unscented filtering and nonlinear estimation[J]. Proceedings of the IEEE, 2004, 92(3): 401 - 422.
- [7] Rambabu K, Bjarne F, Lars I. Applying the unscented Kalman filter for nonlinear state estimation[J]. Journal of Process Control, 2008, 18(7): 753 - 768.
- [8] 周东华, 王庆林. 有色噪声干扰的非线性系统强跟踪滤波[J]. 北京理工大学学报, 1997, 17(3): 321 - 326.
Zhou D H, Wang Q L. Strong tracking filtering of nonlinear systems with colored noise[J]. Journal of Beijing Institute of Technology, 1997, 17(3): 321 - 326. (in Chinese)

- [9] 文成林, 陈志国, 周东华. 基于强跟踪滤波器的多传感器非线性动态系统状态与参数联合估计[J]. 电子学报, 2002, 30(11): 1715 - 1717.

Wen C L, Chen Z G, Zhou D H. Joint state and parameter estimation for multisensor nonlinear dynamic systems on the basis of strong tracking filter[J]. Acta Electronica Sinica, 2002, 30(11): 1715 - 1717. (in Chinese)

- [10] Yan L P, Liu B S, Zhou D H. An asynchronous multirate multisensor information fusion algorithm[J]. IEEE Transactions on Aerospace and Electronic Systems, 2007, 43(3): 1135 - 1146.

作者简介:



闫莉萍 女, 博士, 讲师. 主要研究方向有: 数据融合, 图像匹配, 组合导航, 机动目标跟踪与定位等.

E-mail: yanliping03@tsinghua.org.cn



邓志红 女, 博士, 副教授, 本文通讯作者. 主要研究方向有: 组合导航与智能导航, 多传感器信息融合, 滤波理论及算法等.

E-mail: dzh.deng@bit.edu.cn



付梦印 男, 教授, 博士生导师. 主要研究方向: 多传感器感知、图像处理、信息融合、智能导航等.

E-mail: fumy@bit.edu.cn