

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

文成林^{1,2}, 陈志国¹, 周东华²

(1. 河南大学计算机与信息工程学院, 河南开封 475001; 2. 清华大学计算机系智能技术与系统国家重点实验室, 北京 100084)

摘 要: 本文将强跟踪滤波理论与多传感器数据融合技术相结合, 提出基于强跟踪滤波器的多传感器状态与参数联合估计新算法; 对拥有相同采样率的分布式多传感器单模型非线性动态系统, 应用强跟踪滤波器, 得到目标状态基于全局信息融合估计结果, 并利用计算机仿真结果对算法的有效性进行了验证; 这些工作初步解决了 Kalman 滤波中由于模型的不确定性而造成估计误差值偏大情况下的状态融合估计问题, 从而丰富和发展了多源信息融合理论。

关键词: 强跟踪滤波器; 融合估计; 渐消因子; 动态系统; Kalman 滤波

中图分类号: TN911. 72 **文献标识码:** A **文章编号:** 0372-2112 (2002) 11-1715-03

Joint State and Parameter Estimation for Multisensor Nonlinear Dynamic Systems on the Basis of Strong Tracking Filter

WEN Cheng lin^{1,2}, CHEN Zh i guo¹, ZHOU Dong hua²

(1. School of Computer and Information Engineering, Henan University, Kaifeng, Henan 475001, China;

2. State Key Laboratory of Intelligent Technology and Systems, Tsinghua University, Beijing 100084, China)

Abstract: By combining the strong tracking filtering theory with data fusion estimation technology, a new joint state and parameter estimation algorithm of multisensor based on strong tracking filter is proposed. For the multisensor and single model nonlinear dynamic systems having the same sample rates for every sensor, the fusion estimate on the basis of global information by use of strong tracking filter is established, and the effectiveness of the new algorithm is also illustrated by use of an example. These give a primary solution to the fusion estimation problem having bigger errors produced by Kalman filter because of uncertainties of modeling system. This work enriches and develops the information fusion theory.

Key words: strong tracking filter; fusion estimation; fading factor; dynamic systems; Kalman filtering

1 引言

多传感器数据融合是多源信息综合处理的一项非常有效的方法。它能将来自对同一目标的多源信息加以智能化合成, 产生比单一信息源更精确、更加完全的估计和判断。

对非线性系统来说, 基于扩展 Kalman 滤波器(Extended Kalman Filter 简记为 EKF)的多传感器数据融合技术被广泛采用^[1~8]。然而, 在基于 EKF 对目标状态进行估计时, 当对动态系统的建模与其所描述的动态完全匹配时, 通过 EKF 能给出状态比较准确的估计值。然而, 通常情况是对动态系统的建模具有一定程度的不确定性, 而 EKF 确关于模型不确定的鲁棒性很差, 从而造成 EKF 出现估计不准, 甚至发散等现象^[8]。

为了克服 EKF 存在的上述缺陷, 清华大学的周东华教授创立了强跟踪滤波器(Strong Tracking Filter, 简记为 STF)理论, 成功地解决了由于模型不确定性的影响造成滤波器状态估计值

偏离系统状态的现象, 有效地克服了 EKF 的上述缺陷^[9]。但在实际目标状态进行估计的过程中, 由于传感器本身及其他方面的原因, 可能使系统输出产生跳变, 对应时刻上的量测是野值的概率较大, 而 STF 由于特有的强跟踪能力, 使其对状态的估计也随之产生较大的偏差。为此, 在对传统多源信息研究的基础上, 将 STF 引入多源信息融合方法中去, 提出基于 STF 的多传感器融合估计新算法, 初步解决了由于模型不确定性而造成的状态估计值偏离系统状态的情况, 克服由于因个别传感器误差过大而造成的估计误差偏大至使目标失跟的现象, 从而实现多源信息系统的融合估计^[10]。

由于 STF 的独特的强跟踪能力, 是一种自适应滤波器, 本文将其应用于基于多传感器非线性时变随机系统的状态与参数的联合估计。计算机仿真结果表明了, STF 克服了 EKF 存在的缺陷, 可以有效地用于一大类非线性系统的状态与参数的联合估计, 在达到稳态时, 参数估计是无偏的^[9]。

2 系统描述

考虑一大类多传感器非线性系统:

$$\mathbf{x}(k+1) = f(k, u(k), \mathbf{x}(k), \theta_1, \theta_2(k)) + \Gamma(k)w(k) \quad (1)$$

$$z_i(k) = h_i(k, \mathbf{x}(k), \theta_1, \theta_2(k)) + v_i(k), i = 1, 2, \dots, N \quad (2)$$

其中, 整数 $k \geq 0$ 为离散时间变量; $\mathbf{x}(k) \in R^{n \times 1}$ 为状态向量; 非线性函数 $f: R^{n \times 1} \rightarrow R^{n \times 1}$, 具有关于状态的一阶连续偏导数; $\theta_1 \in R^{1 \times 1}$ 为已知参数, $\theta_2(k) \in R^{l \times 1}$ 是未知的时变参数向量; $\Gamma(k) \in R^{n \times q}$ 是已知矩阵; 系统噪声 $w(k) \in R^{q \times 1}$ 为高斯白噪声序列, 并具有统计特性 $w(k) \sim N[0, Q(k)]$.

有 N 个传感器(2), 以相同的采样速率对状态向量的特征进行观测, $z_i(k) \in R^{m_i \times 1}$ 是第 i 个传感器对状态 $x(k)$ 的观测值, 非线性函数 $h_i: R^{n \times 1} \rightarrow R^{m_i \times 1}$, 具有关于状态的一阶连续偏导数, 测量噪声 $v_i(k) \in R^{m_i \times 1}$ 是高斯白噪声序列, 并具有统计特性 $v_i(k) \sim N[0, R_i(k)]$.

初始状态 $x(0)$ 为高斯分布的随机向量, 且满足统计特性: $E\{x(0)\} = x_0, E\{[x(0) - x_0][x(0) - x_0]^T\} = P_0$.

假设 $x(0), w(k), v_i(k)$ 之间统计独立. 现在的目标是同时实时估计出状态 x 与参数 θ_2 的值.

首先, 在上述系统中加入如下辅助方程

$$\theta_2(k+1) = \theta_2(k) \quad (3)$$

并且令 $x_e = [x^T \theta_2^T]^T$, 那么, 系统(1)~(3)就可以写成如下的等价形式

$$\mathbf{x}_e(k+1) = f_e(k, u(k), \mathbf{x}_e(k)) + \Gamma_e(k)w(k) \quad (4)$$

$$z_i(k) = h_{ie}(k, \mathbf{x}_e(k)) + v_i(k), i = 1, 2, \dots, N \quad (5)$$

其中

$$f_e(k, u(k), \mathbf{x}_e(k)) = \begin{bmatrix} f(k, u(k), \mathbf{x}(k), \theta_1, \theta_2(k)) \\ \theta_2(k) \end{bmatrix}, \quad (6)$$

$$h_{ie}(k, \mathbf{x}_e(k)) = h_i(k, \mathbf{x}(k), \theta_1, \theta_2(k)) \quad (7)$$

3 基于 STF 的多传感器状态与参数联合估计算法

本节中将利用 STF, 在每个时刻获得状态与参数基于全局信息的融合估计值及估计误差协方差阵. 对动态系统(1)和(2)及初始条件, 若已得到 k 时刻状态 $x(k)$ 与参数 $\theta_2(k)$ 基于全局信息的融合估计值 $\hat{x}_e(k|k)$ 及估计误差方差阵 $P(k|k)$. 当 $k+1$ 时刻各个传感器的测量值到来时, 利用系统(4)和(5)及 STF, 将得到状态与参数基于全局信息的融合估计值 $\hat{x}_e(k+1|k+1)$ 及估计误差方差阵 $P(k+1|k+1)$ ^[10, 11]

$$\hat{x}_e(k+1|k+1) = \hat{x}_e(k+1|k) + P(k+1|k+1) \cdot \left\{ \sum_{i=1}^N P_i^{-1}(k+1|k+1) [\hat{x}_{ie}(k+1|k+1) - \hat{x}_{ie}(k+1|k)] - \sum_{i=1}^N P_i^{-1}(k+1|k) [\hat{x}_{ie}(k+1|k) - \hat{x}_e(k+1|k)] \right\} \quad (8)$$

$$P^{-1}(k+1|k+1) = P^{-1}(k+1|k) + \sum_{i=1}^N [P_i^{-1}(k+1|k+1) - P_i^{-1}(k+1|k)] \quad (9)$$

其中

$$\hat{x}_e(k+1|k) = f_e(k, \hat{x}_e(k|k)) \quad (10)$$

$$P(k+1|k) = A(k, \hat{x}_e(k|k)) P(k|k) + A^T(k, \hat{x}_e(k|k)) + \Gamma_e(k) Q(k) \Gamma_e^T(k) \quad (11)$$

$\hat{x}_{ie}(k+1|k+1)$ 和 $P_i(k+1|k+1)$ 分别是状态 $x_e(k+1)$ 基于传感器 i 的估计值和估计误差协方差阵

$$\hat{x}_{ie}(k+1|k+1) = \hat{x}_{ie}(k+1|k) + K_i(k+1) y_i(k+1) \quad (12)$$

$$P_i(k+1|k) = \lambda_i(k+1) A(k, \hat{x}_{ie}(k|k)) P(k|k) \cdot A^T(k, \hat{x}_{ie}(k|k)) + \Gamma_e(k) Q_e(k) \Gamma_e^T(k) \quad (13)$$

$$\text{这里 } \hat{x}_{ie}(k+1|k) = f_e(k, \hat{x}_{ie}(k|k)) \quad (14)$$

$$K_i(k+1) =$$

$$P_i(k+1|k) C_{ie}^T(k+1, \hat{x}_{ie}(k+1|k)) [C_{ie}(k+1, \hat{x}_{ie}(k+1|k)) \cdot P_i(k+1|k) C_{ie}^T(k+1, \hat{x}_{ie}(k+1|k)) + R_i(k+1)]^{-1} \quad (15)$$

$$y_i(k+1) = z_i(k+1) - h_{ie}(k+1, \hat{x}_{ie}(k+1|k)) \quad (16)$$

$$P_i(k+1|k+1) = [I - K_i(k+1) C_{ie}(k+1, \hat{x}_{ie}(k+1|k))] \cdot P_i(k+1|k) \quad (17)$$

式(11)和(13)中

$$A(k, \hat{x}_e(k|k)) = \frac{\partial f_e(k, \hat{x}_e(k))}{\partial x_e} \Big|_{x_e(k) = \hat{x}_e(k|k)} \quad (18a)$$

$$A(k+1, \hat{x}_{ie}(k|k)) = \frac{\partial f_e(k, \hat{x}_e(k))}{\partial x_e} \Big|_{x_e(k) = \hat{x}_{ie}(k|k)} \quad (18b)$$

式(15)和(17)中

$$C_{ie}(k+1, \hat{x}_{ie}(k+1|k)) = \frac{\partial h_{ie}(k+1, x_e(k+1))}{\partial x_e} \Big|_{x_e(k+1) = \hat{x}_{ie}(k+1|k)} \quad (19)$$

式(13)中 $\lambda_i(k+1)$ 是渐消因子^[9]

$$\lambda_i(k+1) = \text{diag}[\lambda_{i1}, \lambda_{i2}, \dots, \lambda_{in}] \quad (20)$$

其中

$$\lambda_{ij}(k+1) = \begin{cases} \alpha_{ij} c_i(k+1), & \alpha_{ij} c_i(k+1) > 1 \\ 1, & \alpha_{ij} c_i(k+1) \leq 1 \end{cases}, j = 1, 2, \dots, n \quad (21)$$

$$c_i(k+1) = \frac{\text{tr} \{ N^i(k+1) \}}{\sum_{j=1}^n \alpha_{ij} M_{ij}^i(k+1)} \quad (22)$$

$$N^i(k+1) = V_{i0}(k+1) - C_{ie}(k+1, \hat{x}_{ie}(k+1|k)) \Gamma_e(k) \cdot Q(k) \Gamma_e^T(k) C_{ie}^T(k+1, \hat{x}_{ie}(k+1|k)) - \beta R_i(k+1) \quad (23)$$

$$M^i(k+1) = A(k, \hat{x}_{ie}(k|k)) P(k|k) A^T(k, \hat{x}_{ie}(k|k)) \cdot C_{ie}^T(k+1, \hat{x}_{ie}(k+1|k)) C_{ie}(k+1, \hat{x}_{ie}(k+1|k)) \quad (24)$$

$$V_{i0}(k+1) = \begin{cases} y_i(1) y_i^T(1), & k=0 \\ \frac{\rho_i V_{i0}(k) + y_i(k+1) y_i^T(k+1)}{1 + \rho_i}, & k \geq 1 \end{cases} \quad (25)$$

式中的参数 $\beta, \alpha_{ij}, \rho_i$ 的选择见文献[9, 10].

4 例子与仿真

现在, 我们利用第 3 节建立的算法给出状态与时变参数的联合估计的计算机仿真实验, 并与基于 EKF 融合算法相比较, 以验证算法的有效性. 为此考虑下面的非线性系统

$$\mathbf{x}(k+1) = 0.1 a(k) \mathbf{x}^2(k) + \mathbf{x}(k) + 0.02 u(k) + w(k)$$

$$z_1(k+1) = a^3(k+1) \mathbf{x}(k+1) + v_1(k)$$

$$z_2(k+1) = a(k+1) \mathbf{x}(k+1) + v_2(k)$$

$Q = [0.001]$, $R_1 = [0.000001]$, $R_2 = [0.0002]$, 时变参数 $a(k)$ 的变化规律未知, 但知道其正常值是 $a_0 = -0.58$. 表中的数据及图中曲线均是 100 次 Monte Carlo 仿真统计结果. 在仿真中取 $x(0) = 0$, $a(0) = -0.58$, $\hat{x}(0|0) = 0$; $\hat{a}(0|0) = -0.38$, $P(0|0) = \text{diag}[0.3, 0.3]$, 并如下随机选取附加有随机噪声 $w_2(k) \sim N[0, 0.00001]$ 的参数 $a(k)$:

$$a(k+1) = \begin{cases} a(k) + w_2(k), & 0 \leq k \leq 198; \\ a(k) + a^0/10 + w_2(k), & k = 199; \\ a(k) + w_2(k), & 200 \leq k \leq 399; \\ a(k) - a^0/500 + w_2(k), & 400 \leq k \leq 499; \\ a(k) + w_2(k), & 500 \leq k \leq 698; \\ a(k) + a^0/5 + w_2(k), & k = 699; \\ a(k) + w_2(k), & 700 \leq k \leq 899. \end{cases}$$




图 1 (a)、(c) 分别表示状态 x 和参数 a 基于 EKF 的融合估计结果; (b)、(d) 分别表示状态 x 和参数 a 基于 STF 的融合估计结果. 实线表实际值, 虚线表示估计值

表 1 EKF 和 STF 累计误差绝对值的统计值

	传感器 1	传感器 2	传感器 1 和 2 融合估计
EKF	31.3964	13.2289	9.1874
STF	9.4699	6.2943	1.1067

参考文献:

[1] H R Hashemipour, et al. Decentralized structures for parallel Kalman filtering[J]. IEEE Trans. on AC, 1988, 33(1): 88- 93.

[2] 孙红岩, 毛士艺. 多传感器数据分层融合性质[J]. 电子学报, 1996, 23(16): 55- 61.

[3] Wen Cheng lin, Zhou Dong-hua. The multiscale state fusion estimation for nonlinear systems with multivariate sensors[A]. IFAC 15th World Congress[C]. Barcelona, Spain: 2002. 7.

[4] 文成林, 周东华, 潘泉, 张洪才. 多尺度动态模型单传感器动态系统分布式信息融合[J]. 自动化学报, 2001, 27(2): 158- 165.

[5] 何友, 熊伟, 陆大, 彭应宁. 带反馈信息的多传感器分层估计算法[J]. 电子学报, 2000, 28(12): 85- 89.

[6] 何友, 彭应宁. 多级式多传感器信息融合中的状态估计[J]. 电子学报, 1999, 27(8): 60- 63.

[7] 文成林. 多传感器单模型动态系统多尺度数据融合[J]. 电子学报, 2001, 29(3): 341- 345.

[8] Bonivento C, Tonielli A. A detection estimation multifilter approach with nuclear application[A]. In IFAC Proc. Series[C]. 1984. 1771- 1776.

[9] 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. 1.

[10] 文成林, 周东华. 多尺度估计理论及其应用[M]. 北京: 清华大学出版社, 2002. 9.

[11] 孙红岩, 毛士艺. 多传感器数据的准分层融合法[J]. 系统工程与电子技术, 1995, 5: 66- 72.

作者简介:



文成林 男, 1963 年生, 河南人, 博士、教授, 已发表论文 60 余篇, 出版学术专著 1 部, 教材 4 本, 主要研究领域为多尺度估计理论、多传感器信息融合、故障诊断理论与应用等.

陈志国 男, 1955 年生, 河南人, 副教授, 已发表论文 20 余篇, 出版教材 4 部, 研究方向为计算机网络技术与信息融合技术.

周东华 男, 1963 年生, 江苏人, 教授, 博士生导师, 中国自动化学会副秘书长、中国自动化学会技术过程的故障诊断与安全性专业委员会秘书长, 已在国内外发表学术论文 100 余篇、出版学术专著 3 部, 目前的研究方向是故障诊断, 容错控制, 信息融合等.