

文章编号: 1001-0920(2008)07-0837-04

基于 IMM-PF 的分布式估计融合算法

彭志专, 冯金富, 钟咏兵, 伍友利, 梁晓龙

(空军工程大学 工程学院, 西安 710038)

摘要: 针对基于扩展卡尔曼滤波的估计融合算法存在线性化误差,且受高斯噪声假设限制的问题,提出一种基于交互式多模型粒子滤波(IMM-PF)的分布式多传感器估计融合算法.各传感器节点采用 IMM-PF 算法,以便在非线性和非高斯条件下稳健地跟踪机动目标;融合中心则采用基于粒子滤波(PF)的分布式融合方法进行全局估计融合.该算法适用于非线性、非高斯条件下的多传感器状态估计.仿真结果表明,该算法能够提高多传感器系统状态估计的精度.

关键词: 分布式融合; 粒子滤波; 交互式多模型; 非线性/非高斯

中图分类号: TP273 **文献标识码:** A

Distributed fusion algorithm based on IMM-PF

PENG Zhi-zhuan, FENG Jin-fu, ZHONG Yong-bing, WU You-li, LIANG Xiaolong

(Engineering College, Air Force Engineering University, Xi'an 710038, China. Correspondent: PENG Zhi-zhuan, E-mail: pzz77077@yahoo.com.cn)

Abstract: Distributed fusion algorithm for nonlinear/non-Gaussian situations is addressed. The usual fusion approach is based on extended Kalman filter (EKF) which often leads to poor convergence and erratic filter behavior in highly nonlinear systems. Particle filtering (PF) is quite convenient in nonlinear/non-Gaussian filtering problems. Based on PF, a distributed fusion algorithm is developed, which can be used in nonlinear/non-Gaussian applications. At the sensor level, observer maintains its own estimate with an interacting multiple model particle filter (IMM-PF), and at the fusion level, the full state estimate is processed by using nonlinear fusion rule. Simulation results show that the proposed method can significantly improve the state estimation precision of the multisensor system.

Key words: Distributed fusion; Particle filter; Interacting multiple model; Nonlinear/non-Gaussian

1 引言

估计融合是多传感器信息融合的一个重要内容.目前,针对线性、高斯条件下多传感器状态估计融合的理论和方法日趋完善^[1],而面向复杂应用背景(非线性、非高斯环境)的融合方法,则很少有文献报道^[2,3].扩展卡尔曼滤波(EKF)及其衍生算法通常用于非线性系统状态估计^[4],但这些算法存在线性化误差,估计精度不高,而且不适用于非高斯条件系统.

粒子滤波(PF)^[5]是近年来刚刚兴起的一种基于 Monte Carlo 仿真的最优回归贝叶斯非线性滤波算法.这种滤波方法不受线性化误差和高斯噪声假定的限制,适用于任何状态转换或测量模型.粒子滤波的优点引起了众多学者的广泛关注,但如何在多

传感器系统中应用粒子滤波的成果则不多见. Ya Xue 等^[2]提出了一种联合重抽样的集中式粒子滤波融合算法,该方案需要系统承担繁重的通讯负担,实用性不强.随后, Xiong 等^[6]对该算法进行了改进,提出一种易于实现的集中式粒子滤波方法.但该方法中,融合中心计算负担过重,系统生存能力较差. Nguyen 等^[7]将粒子滤波器用于分布式机动目标融合跟踪,但并没有给出非线性系统融合的解析算法.

交互式多模型粒子滤波算法(IMM-PF)^[8-10]采用多模型结构以跟踪任意机动目标,各模型采用粒子滤波算法,以处理非线性、非高斯问题. IMM-PF 算法因其优良的性能和宽广的适应范围而得到广泛研究.本文提出一种基于 IMM-PF 的分布式多传感器估计融合算法.各传感器节点采用 IMM-PF 算

收稿日期: 2007-05-07; 修回日期: 2007-07-30.

基金项目: 国家 863 计划项目(2006AA701307); 国家自然科学基金项目(60674031).

作者简介: 彭志专(1979—),男,湖南益阳人,博士生,从事非线性滤波、估计融合等研究; 冯金富(1966—),男,江苏泰兴人,教授,博士生导师,从事武器管理与控制、多传感器信息融合等研究.

法;可在非线性、非高斯条件下稳健跟踪机动目标;融合中心采用基于PF的分布式融合方法进行全局估计融合.该算法适用于非线性、非高斯条件下的多传感器状态估计.

2 交互式多模型粒子滤波

IMM-PF算法采用多模型结构跟踪机动目标,各模型采用粒子滤波算法,以处理非线性、非高斯问题.采用IMM-PF算法的传感器节点,可以方便地得到局部先验概率密度函数和局部状态估计.

考虑如下非线性动态系统:

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

$$\mathbf{z}_k = h_k(\mathbf{x}_k, \mathbf{v}_k). \quad (2)$$

其中: $\mathbf{x}_k \in R^n$ 为 k 时刻的系统状态变量, f_k 为系统状态传播方程, \mathbf{w}_k 为过程噪声, $\mathbf{z}_k \in R^n$ 为 k 时刻的测量值, h_k 为测量方程, \mathbf{v}_k 为测量噪声. 假设马尔可夫模型转移概率矩阵为 $\mathbf{A} = \{\pi_{ij}, i, j = 1, 2, \dots, m\}$, 各模型概率矩阵 $\mathbf{U} = \{u_j^n(k), i = 1, 2, \dots, m, n = 1, 2, \dots, N\}$, m 为模型数, N 为粒子数.

根据文献[9],交互式多模型的粒子滤波算法主要步骤如下:

1) 随机抽取粒子. 在 k 时刻,根据状态变量均值和协方差随机抽取各模型粒子. 设 m 个模型各随机抽取的粒子状态值和协方差分别为 $\{\hat{\mathbf{x}}_j^n(k|k), \hat{\mathbf{P}}_j^n(k|k)\}$.

2) 输入交互. 对各模型的相应粒子进行输入交互,即

$$\bar{\mathbf{x}}_j^n(k|k) = \sum_{i=1}^m \hat{\mathbf{x}}_i^n(k|k) u_{ij}^n(k|k), \quad (3)$$

$$\bar{\mathbf{P}}_j^n(k|k) = \sum_{i=1}^m u_{ij}^n(k|k) \{\hat{\mathbf{P}}_i^n(k|k) + [\hat{\mathbf{x}}_i^n(k|k) - \bar{\mathbf{x}}_j^n(k|k)][\hat{\mathbf{x}}_i^n(k|k) - \bar{\mathbf{x}}_j^n(k|k)]^T\}. \quad (4)$$

3) 模型匹配粒子滤波. 将 $\{\bar{\mathbf{x}}_j^n(k|k), \bar{\mathbf{P}}_j^n(k|k)\}$ 代入基于第 j 个模型的粒子滤波器,获取 $k+1$ 时刻的第 n 个粒子的状态变量 $\hat{\mathbf{x}}_j^n(k+1|k+1)$ 及其协方差 $\hat{\mathbf{P}}_j^n(k+1|k+1)$, 残差 $\hat{\mathbf{r}}_j^n(k+1)$ 及其协方差 $\mathbf{O}_j^n(k+1)$, 似然函数 $\Lambda_j^n(k+1)$ 和相应权值 $\bar{w}_j^n(k+1)$.

4) 模型概率更新

$$u_j^n(k+1) = \frac{1}{c^n} \Lambda_j^n(k+1) \bar{c}_j^n, \quad (5)$$

其中 $c^n = \sum_{j=1}^m \Lambda_j^n(k+1) \bar{c}_j^n$.

5) 残差重抽样. 根据残差重抽样算法,分别对各个模型重抽样粒子,产生新的被赋以相同权值的样本系列,即 $\{\hat{\mathbf{x}}_j^n(k+1|k+1), \bar{w}_j^n(k+1) = 1/N\}$.

6) 输出交互. 对 m 个模型各相应的粒子群进

行输出交互,并对所有的粒子求加权平均和

$$\hat{\mathbf{x}}^n(k+1|k+1) = \sum_{j=1}^m \hat{\mathbf{x}}_j^n(k+1|k+1) u_j^n(k+1), \quad (6)$$

$$\hat{\mathbf{x}}(k+1|k+1) = \sum_{n=1}^N \hat{\mathbf{x}}^n(k+1|k+1) / N. \quad (7)$$

$k+1$ 时刻的后验概率密度函数可近似表示为

$$p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k+1}) \approx \sum_{n=1}^N \delta(\mathbf{x}_{k+1} - \hat{\mathbf{x}}^n(k+1|k+1)) / N. \quad (8)$$

3 基于粒子滤波器的分布式估计融合算法

分布式估计融合是指每个传感器的检测在融合之前,先由自己的数据处理器进行一些预处理,再将中间结果送到中心节点,进行融合处理^[11]. 这种结构因对信道容量要求低,系统生命力强,工程上易于实现而得到重视,并成为信息融合研究的重点.

基于IMM-PF算法的各传感器节点可以向融合中心传送局部状态估计 $\hat{\mathbf{x}}_{k+1}$ 和局部后验概率密度函数 $p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k+1}^s)$, 而分布式估计融合的任务则是根据这些得出全局状态估计 $\hat{\mathbf{x}}_{k+1}$. 根据粒子滤波的思想^[12],多传感器系统全局状态估计 $\hat{\mathbf{x}}_{k+1}$ 可由全局后验概率密度函数 $p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k+1}^{1:S})$ 求得 ($\mathbf{z}_{1:k+1}^s$ 为到 $k+1$ 时刻为止传感器 s 的量测集合, $\mathbf{z}_{1:k+1}^{1:S}$ 为所有传感器到 $k+1$ 时刻为止的量测集合.)

设 $q(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k+1}^{1:S})$ 为一重要性密度函数,抽取粒子 $\{\hat{\mathbf{x}}_{0:k+1}^i\}_{i=1, \dots, M} \sim q(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k+1}^{1:S})$, 其权值为

$$\lambda_{k+1}^i = \frac{p(\hat{\mathbf{x}}_{0:k+1}^i | \mathbf{z}_{1:k+1}^{1:S})}{q(\hat{\mathbf{x}}_{0:k+1}^i | \mathbf{z}_{1:k+1}^{1:S})}. \quad (9)$$

再考虑系统状态估计问题. 对于全局后验概率密度函数,根据贝叶斯公式,有

$$P(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k+1}^{1:S}) \propto p(\mathbf{z}_{k+1}^{1:S} | \mathbf{x}_{k+1}) p(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k}^{1:S}). \quad (10)$$

假设系统为马尔可夫过程,则上式可改写为

$$p(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k+1}^{1:S}) \propto p(\mathbf{z}_{k+1}^{1:S} | \mathbf{x}_{k+1}) p(\mathbf{x}_{k+1} | \mathbf{x}_k) p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}^{1:S}). \quad (11)$$

各传感器测量相互独立,即

$$p(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k+1}^{1:S}) \propto \prod_{s=1}^S p(\mathbf{z}_{k+1}^s | \mathbf{x}_{k+1}) p(\mathbf{x}_{k+1} | \mathbf{x}_k) p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}^{1:S}). \quad (12)$$

再根据贝叶斯公式,有

$$p(\mathbf{z}_{k+1}^s | \mathbf{x}_{k+1}) = \frac{p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k+1}^s)}{p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}^s)} p(\mathbf{z}_{k+1}^s | \mathbf{z}_{1:k}^s). \quad (13)$$

将式(13)代入(12),则有

$$p(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k+1}^{1:S}) \propto \prod_{s=1}^S \left\{ \frac{p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k+1}^s)}{p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}^s)} \right\} p(\mathbf{x}_{k+1} | \mathbf{x}_k) p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}^{1:S}). \quad (14)$$

而重要性密度函数

$$q(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k+1}^{1:S}) = q(\mathbf{x}_{k+1} | \mathbf{x}_{0:k}, \mathbf{z}_{1:k+1}^{1:S}) q(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}^{1:S}). \quad (15)$$

再将式(15),(14)代入(9),可得

$$\lambda_{k+1}^i \propto \prod_{s=1}^S \left\{ \frac{p(\hat{\mathbf{x}}_{k+1}^i | \mathbf{z}_{1:k+1}^s)}{p(\hat{\mathbf{x}}_{k+1}^i | \mathbf{z}_{1:k}^s)} \right\} \frac{p(\hat{\mathbf{x}}_{k+1}^i | \hat{\mathbf{x}}_k^i)}{q(\hat{\mathbf{x}}_{k+1}^i | \hat{\mathbf{x}}_{0:k}^i, \mathbf{z}_{1:k}^{1:S})} \lambda_k^i. \quad (16)$$

选择先验概率密度函数作为重要密度函数

$$q(\mathbf{x}_{k+1} | \mathbf{x}_{0:k}, \mathbf{z}_{1:k+1}^{1:S}) = p(\mathbf{x}_{k+1} | \mathbf{x}_k), \quad (17)$$

并由 Chapman-Kolmogorov 方程,有

$$p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}^s) = \int p(\mathbf{x}_{k+1} | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:k}^s) d\mathbf{x}_k. \quad (18)$$

将式(17),(18)代入(16),得

$$\lambda_{k+1}^i \propto \prod_{s=1}^S \left\{ \frac{p(\hat{\mathbf{x}}_{k+1}^i | \mathbf{z}_{1:k+1}^s)}{\int p(\hat{\mathbf{x}}_{k+1}^i | \hat{\mathbf{x}}_k^i) p(\hat{\mathbf{x}}_k^i | \mathbf{z}_{1:k}^s) d\mathbf{x}_k} \right\} \lambda_k^i. \quad (19)$$

又由式(8),局部后验滤波密度函数为

$$p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k+1}^s) \approx \sum_{n=1}^N \omega_{k+1}^{s,n} \delta(\mathbf{x}_{k+1} - \hat{\mathbf{x}}_{k+1}^{s,n}). \quad (20)$$

将式(20)代入(19),有

$$\lambda_{k+1}^i \propto \prod_{s=1}^S \left\{ \frac{\sum_{n=1}^N \omega_{k+1}^{s,n} \delta(\hat{\mathbf{x}}_{k+1}^i - \hat{\mathbf{x}}_{k+1}^{s,n})}{\sum_{n=1}^N p(\hat{\mathbf{x}}_{k+1}^i | \hat{\mathbf{x}}_k^{s,n}) \omega_k^{s,n}} \right\} \lambda_k^i. \quad (21)$$

于是,全局后验概率密度函数为

$$p(\mathbf{x}_{k+1} | \mathbf{z}_{1:k+1}^{1:S}) = \sum_{i=1}^M \lambda_{k+1}^i \delta(\mathbf{x}_{k+1} - \hat{\mathbf{x}}_{k+1}^i). \quad (22)$$

融合后,全局状态估计为

$$\hat{\mathbf{x}}_{k+1} = \sum_{i=1}^M \lambda_{k+1}^i \hat{\mathbf{x}}_{k+1}^i. \quad (23)$$

4 仿真研究

针对一跟踪地面目标的实例^[13]进行仿真分析.假设目标在二维平面内运动,起始位置为(6 000,8 400),运动速度为 23 m/s.前 180 s 目标以东偏南 29.36° 的角度作匀速直线运动,之后,目标以 1.15°/s 的角速度向左作 80 s 的圆周运动;然后作 110 s 的匀速直线运动,之后,目标以 0.43°/s 的角速度向右作圆周运动 140 s;最后再作 140 s 的匀速直线运动.两个 2D 雷达用来跟踪目标,一个雷达测距噪声均方差为 3 m,测角噪声均方差为 0.08°;另一

个雷达测距噪声均方差为 2 m,测角噪声均方差为 0.1°.

构造 2 个 IMM 模型:模型 1 为常速度模型(CV),模型 2 为常加速度模型(CA).即式(1)可表示为

$$\mathbf{x}_{k+1} = \Phi_k \mathbf{x}_k + \mathbf{G}_k \mathbf{w}_k, \quad (24)$$

$$\Phi_1(k) = \begin{bmatrix} 1 & T & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, \Phi_2(k) = \begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix},$$

$$\mathbf{G}_1(k) = \begin{bmatrix} T^2/2 \\ T \\ 0 \end{bmatrix}, \mathbf{G}_2(k) = \begin{bmatrix} T^2/2 \\ T \\ 1 \end{bmatrix},$$

$$\mathbf{A} = [\pi_{ij}] = \begin{bmatrix} 0.98 & 0.02 \\ 0.02 & 0.98 \end{bmatrix},$$

$$u_1(0) = u_2(0) = 0.5.$$

采样周期 $T = 1$ s,各模型的粒子数 $N = 800$,蒙特卡罗仿真次数为 300.由两点外推滤波可求得两模型的状态变量初始值和协方差.

在仿真中,将基于 IMM-PF 的分布式融合算法与基于 IMM-EKF 的最小方差融合算法进行了比较.图 1 为 x 轴位置估计均方根误差曲线.从仿真图可以看出,在目标作常速运动时,各滤波方法都能较好地估计目标;而在目标机动期间,IMM-PF 融合的位置均方根误差都小于 IMM-EKF 融合.

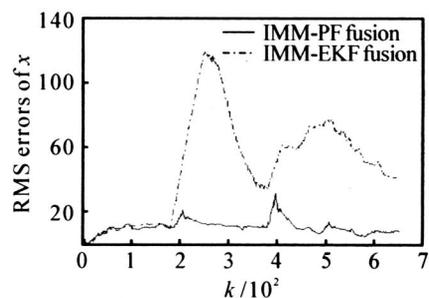


图 1 x 轴位置估计均方根误差

图 2 为 x 轴速度估计均方根误差曲线,对仿真进行比较分析,所得结果如表 1 所示.

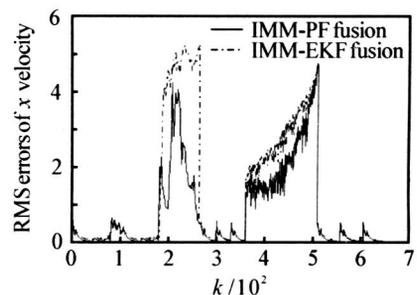


图 2 x 轴速度估计均方根误差

表 1 两种融合算法滤波误差比较

融合算法	x 轴位置均 方根误差 / m	x 轴速度均方 根误差 / (m/s)	x 轴加速度均方 根误差 / (m/s ²)
基于 IMM-EKF	38.267 3	1.221 9	9.237
基于 IMM-PF	12.287 1	0.892 3	8.965

5 结 论

IMM-PF 算法是解决非线性、非高斯条件下跟踪任意机动目标问题的最热门滤波方法之一。本文提出的融合算法将 IMM-PF 应用于分布式多传感器状态估计,各传感器节点采用 IMM-PF 算法进行局部滤波,融合中心采用基于 PF 的分布式融合方法进行全局估计融合。这种融合算法适用于非线性/非高斯的环境。仿真结果验证了本文的融合算法优于通用算法。粒子滤波最大的不足是其计算量很大,将快速粒子滤波技术应用于本文的融合算法将是下一步研究的重点。

参考文献(References)

- [1] Li X R, Zhu Y M, Wang J, et al. Optimal linear estimation fusion — Part I: Unified fusion rules [J]. IEEE Trans on Information Theory, 2003, 49 (9): 2192-2208.
- [2] Ya Xue, Morrell Darryl. Target tracking and data fusion using multiple adaptive foveal sensors [C]. The 6th Int Conf of Information Fusion. Fairborn, 2003: 326-333.
- [3] Brehard T, Cadre J P. Distributed target tracking for nonlinear systems: Application to bearings-only tracking [C]. The 7th Int Conf on Information Fusion. Philadelphia, 2005: 77-84.
- [4] Zhu Y M, Li X R. Best linear unbiased estimation fusion [C]. The 2th Int Conf on Information Fusion. Sunnyvale, 1999: 1054-1061.
- [5] Arulampalam M S, Maskell S, Gordon N, et al. A

tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking [J]. IEEE Trans on Signal Processing, 2002, 50(2): 174-188.

- [6] Xiong W, He Y, Zhang J. Particle filter method for a centralized multisensor system [J]. Berlin: Springer-Verlag, 2006: 64-69.
- [7] Nguyen T M, Jilkov V P. Comparison of sampling algorithms for multisensor distributed target tracking [C]. The 6th Int Conf on Information Fusion. Queensland, 2003: 114-121.
- [8] Yang N, Tian W, Jin Z. An interacting multiple model particle filter for manoeuvring target location [J]. Measurement Science and Technology, 2006, 17 (6): 1307-1311.
- [9] 邓小龙, 谢剑英, 杨煜普. 基于交互多模型的粒子滤波算法 [J]. 系统仿真学报, 2005, 17(10): 2360-2362. (Deng X L, Xie J Y, Yang Y P. Particle filter based on interacting multiple model [J]. J of System Simulation, 2005, 17(10), 2360-2362.)
- [10] Bugallo M F, Xu Shanshan, Petar M D. Performance comparison of EKF and particle filtering methods for maneuvering targets [J]. Digital Signal Process, 2006, 16(10): 67-78.
- [11] Li X R, Zhang S. Optimal linear estimation fusion — Part IV: Optimality and efficiency of distributed fusion [C]. Int Conf on Information Fusion. Montreal, 2001: 19-26.
- [12] Doucet A, Godsill S, Andrieu C. On sequential monte carlo sampling methods for Bayesian filtering [J]. Statistics and Computing, 2000, 10(3): 197-208.
- [13] Ningzhou Cui, Lang Hong, Layne J R. A comparison of nonlinear filtering approaches with an application to ground target tracking [J]. Signal Processing, 2005, 85(9): 1469-1492.

(上接第 836 页)

- [2] Wolfgang M Schubert, Robert F Stengel. Parallel stochastic robustness synthesis for control system design [C]. Proc of the American Control Conf. Seattle, 1995, 6: 4429-4434.
- [3] Ray L R, Stengel R F. Application of stochastic robustness to aircraft control systems [J]. J of Guidance, Control and Dynamics, 1991, 14 (6): 121-125.
- [4] 吴森堂, 许仁牛. 反舰导弹过载控制的随机鲁棒设计方

法 [J]. 航天控制, 2003, 21(3): 1-6.

- (Wu S T, Xu R N. Stochastic robustness design for overload control of antiship missiles [J]. Aerospace Control, 2003, 21(3): 1-6.)
- [5] 张有济, 关世义, 曹柏桢, 等. 战术导弹飞行力学设计 [M]. 北京: 宇航出版社, 1996: 90-121. (Zhang Y J, Guan S Y, Cao B Z, et al. Design of flight dynamics for a tactical missile [M]. Beijing: Aerospace Press, 1996: 90-121.)