

文章编号: 1001-0920(2012)04-0547-04

## 量测不确定条件下多传感器自适应粒子滤波算法

胡振涛<sup>1</sup>, 潘泉<sup>2</sup>, 金勇<sup>1</sup>, 张帆<sup>1</sup>

(1. 河南大学 图像处理与模式识别研究所, 河南 开封 475001; 2. 西北工业大学 自动化学院, 西安 710072)

**摘要:** 针对量测不确定条件下多传感器量测数据的有效利用问题, 提出一种多传感器自适应粒子滤波算法. 利用随机采样策略和量测模型转移概率实现当前时刻多传感器量测集合的采样, 通过粒子滤波中重采样步骤完成估计状态和量测集合的更新, 进而依据重采样后单个传感器量测数目在传感器量测集合中的比重实现当前时刻传感器量测的确认. 该算法通过有效量测的合理选择, 改善了扰动对滤波精度和计算量的不利影响. 理论分析和仿真实验均验证了所提出算法的有效性.

**关键词:** 非线性滤波; 多传感器; 信息融合; 粒子滤波; 量测不确定

**中图分类号:** TP391

**文献标识码:** A

### Multi-sensor adaptive particle filter in measurement uncertainty

HU Zhen-tao<sup>1</sup>, PAN Quan<sup>2</sup>, JIN Yong<sup>1</sup>, ZHANG Fan<sup>1</sup>

(1. Institute of Image Processing and Pattern Recognition, He'nan University, Kaifeng 475001, China; 2. College of Automation, Northwestern Polytechnical University, Xi'an 710072, China. Correspondent: HU Zhen-tao, E-mail: hzt@henu.edu.cn)

**Abstract:** Aiming at the effective utilization of multi-sensor measurement in measurement uncertainty, a multi-sensor adaptive particle filter algorithm is proposed. In the algorithm, multi-sensor measurement set is sampled by the random sampling strategy and measurement model transition probability. Then state estimation and the update of multi-sensor measurement set are realized by re-sampling in particle filter. Finally, the current moment measurement is validated according to the proportion of measurement number of single sensor in multi-sensor measurement set after re-sampling. The adverse influence of interference to the computational complexity is by reasonably selecting effective measurement. The theoretical analysis and experimental results show the efficiency of the proposed algorithm.

**Key words:** nonlinear filter; multi-sensor; information fusion; particle filter; measurement uncertainty

## 1 引言

多传感器信息融合相对于单个传感器所获得的信息具有冗余性、互补性, 从而使得被估计系统具有较强的鲁棒性. 在结构上, 多传感器信息融合系统一般分为集中式、分布式、混合式和多级式. 后两种结构形式实际上是在集中式和分布式基础上的拓展, 可通过集中式和分布式优化组合实现. 在满足一些特定假设条件下, 基于集中式和分布式结构特点已经推导出最优加权融合准则. 然而, 实现最优加权融合的前提条件在于对系统实现准确建模, 并精确获取系统的过程噪声和量测噪声统计信息. 实际工程环境中, 一些外界扰动(传输误差、计算误差、环境噪声和人为干扰等)是无法回避的, 这便使得建模噪声与实际噪

声的统计特性具有较大偏差, 而这种偏差将直接影响滤波器估计精度. 对于由外界扰动的影响而导致量测不确定的多传感器融合系统的估计问题, 一般可通过选取性能相对优越的滤波器、设计噪声方差自适应滤波器以及剔除量测中野值等方式实现<sup>[1]</sup>. 当模型线性以及噪声和初始状态均为高斯独立分布时, 卡尔曼滤波给出了一套实现线性最小方差估计的完整递推求解表达式, 但在很多工程实际中以上假设条件很难满足, 为此人们又提出了一些次优的近似方法, 如解析近似、数值逼近、高斯和滤波等<sup>[2-3]</sup>. 近年来, 伴随着计算机性能不断提升, 基于序贯重要性采样技术和递推贝叶斯理论的粒子滤波(PF), 人们给出了一种处理非线性非高斯问题的有效解决方法. 粒子滤波的基

收稿日期: 2010-11-02; 修回日期: 2011-05-09.

基金项目: 国家自然科学基金项目(60972119, 61170243); 河南省创新人才培养计划(114100510001).

作者简介: 胡振涛(1979—), 男, 讲师, 从事非线性滤波、目标跟踪等研究; 潘泉(1961—), 男, 教授, 博士生导师, 从事复杂系统建模与估计等研究.

本思想是通过一组附带权重的随机采样粒子逼近后验概率分布,理论上可以取得被估计对象的最小方差估计且不受系统非线性强度和噪声类型的约束,因而在信号处理、目标跟踪、故障诊断与图象处理等领域得到了广泛应用<sup>[4-5]</sup>.

目前,对 PF 的研究主要集中在解决粒子退化和重采样后的粒子贫化问题,并取得了一些有意义的成果,如 EPF,UPF,PFMCMC 以及与智能计算相结合的一些改进方法等<sup>[6-8]</sup>.此外,在多传感器系统中,利用 PF 实现集中式和分布式融合已引起学者们的关注,相关成果有集中式粒子滤波(M-PF)以及分布式滤波(S-PF)<sup>[9-10]</sup>等.但是,PF 及以上改进算法取得较好滤波精度的前提在于噪声统计信息精确已知,即对系统运动状态建模非常准确,能够精确获取传感器的量测精度,此时一般不考虑量测环境中的随机扰动,而这种理想条件在实际中很难达到.因此,研究粒子滤波在量测不确定条件下的应用具有重要的现实意义.Djuric 等人<sup>[11]</sup>通过代价函数和风险函数实现粒子权重的合理评价,给出了一种噪声统计信息未知情况下代价评估粒子滤波器(CRPF),以改善对量测噪声先验统计信息的依赖.研究发现,CRPF 在外界扰动影响显著条件下的滤波精度优于 PF,而扰动影响较弱条件下的滤波精度次于 PF,使得 CRPF 缺乏对于环境的自适应性<sup>[11-12]</sup>.Francois 等人<sup>[13]</sup>提出一种基于量测马尔可夫模型切换的多传感器融合粒子滤波算法,但要获取较好的滤波效果依赖于状态转移模型能够匹配不同量测速率的传感器,其应用条件过于苛刻.

基于以上分析,本文提出一种量测不确定条件下多传感器自适应粒子滤波算法(MAPF),通过对含扰动量测辨识和自适应剔除,改善系统状态估计的可靠性和稳定性.对典型非线性系统的仿真结果表明,MAPF 的滤波估计精度明显优于 M-PF 和 S-PF.

## 2 粒子滤波

考虑如下非线性状态空间模型:

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

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

其中:  $\mathbf{x}_k$  和  $\mathbf{z}_k^l$  分别为  $k$  时刻系统状态变量和第  $l$  个传感器量测值;  $f(\cdot)$  和  $h(\cdot)$  分别为系统状态和量测的非线性演化函数;  $\mathbf{e}_k^l$  为第  $l$  个传感器量测的扰动量;  $\mathbf{u}_k$  和  $\mathbf{v}_k^l$  分别为具有独立同分布特性的系统过程噪声和量测噪声序列,其噪声方差分别为  $\mathbf{Q}_k$  和  $\mathbf{R}_k^l$ .

设量测模型  $l$  为服从离散时间、齐次、有限状态的一阶 Markov 链,量测模型空间为  $D = \{1, 2, \dots, d\}$ ,量测模型转移概率为  $\Theta_{a,b}$ ,  $\boldsymbol{\Pi} = [\Theta_1, \Theta_2, \dots, \Theta_d]^T$ ,  $a, b, l, d \in D$ ,转移概率矩阵为  $\boldsymbol{\Pi} = [\Theta_1, \Theta_2, \dots, \Theta_d]^T$ ,

$\Theta_a = [\Theta_{a,1}, \Theta_{a,2}, \dots, \Theta_{a,d}]$ ,且  $\sum_{b=1}^d \Theta_{a,b} = 1$ <sup>[13]</sup>.基于第

$l$  个传感器量测序列的状态估计问题描述可归结为利用所有可能得到的量测  $\mathbf{z}_{1:k}^l = \{\mathbf{z}_1^l, \mathbf{z}_2^l, \dots, \mathbf{z}_k^l\}$  递推地估计出当前时刻系统状态  $\mathbf{x}_k$  的后验概率分布  $p(\mathbf{x}_k | \mathbf{z}_{1:k}^l)$ .具体地,在 PF 中是利用采样粒子  $\mathbf{x}_k^i$  完成对  $p(\mathbf{x}_k | \mathbf{z}_{1:k}^l)$  的逼近,  $\mathbf{x}_k^i$  为后验概率分布中独立抽样得到的样本,  $i = 1, 2, \dots, N$  且  $N \rightarrow \infty$ .然而,由于实际  $p(\mathbf{x}_k | \mathbf{z}_{1:k}^l)$  是未知的,上述过程一般很难实现.

为克服以上困难,通过引入一个容易采样且接近后验概率分布的提议分布  $q(\mathbf{x}_k | \mathbf{z}_{1:k}^l)$ ,并从中抽取一组带权子样,以此来近似后验概率分布.该过程被称为重要性采样.针对 PF 中出现的粒子退化问题,引入了重采样过程.所谓重采样,即在评估粒子权值后,维持粒子总数不变的条件下删减权值低的粒子,复制权值高的粒子.依据蒙特卡罗仿真技术,最终状态估计结果可通过求解重采样后粒子算术平均值获得.

## 3 多传感器自适应粒子滤波算法

在量测不确定条件下,简单地在集中式和分布式结构下引入粒子滤波算法实现非线性状态估计,必然导致以下问题:无论是在集中式结构还是分布式结构中,融合中心所处理的信息都不可避免地包含了整个采样过程中所有扰动的影响;另外,在分布式结构中,由于需要利用每个处理节点的独立量测分别完成局部状态估计过程,必将导致算法计算复杂度的急剧增大.如何实现消除扰动对量测的影响,自适应在线选取有效量测(即无扰动影响的传感器量测)是提升系统估计精度的关键.基于随机采样策略和 PF 中所具有的特殊量测更新方式(重采样),这里研究一种量测不确定条件下多传感器自适应粒子滤波算法.

首先,依据系统先验建模信息并结合  $k-1$  时刻粒子实现  $k$  时刻粒子的采样以及粒子量测预测值计算,即

$$\mathbf{x}_k^i = f(\mathbf{x}_{k-1}^i) + \mathbf{u}_k^i, \quad (3)$$

$$\mathbf{z}_{k/k-1}^i = h(\mathbf{x}_k^i); \quad (4)$$

然后,利用随机采样和  $\Theta_{a,b}$  完成  $k$  时刻每个粒子采用量测模型的预测.具体实现过程如下:已知  $k-1$  时刻第  $i$  个粒子采用的量测模型为  $m_{k-1}^i = a$ ,从  $(0, 1]$  的均匀分布中采样  $\varsigma$ ,当满足

$$\sum_{l=1}^{c-1} \Theta_{a,b} < \varsigma \leq \sum_{l=1}^c \Theta_{a,b},$$

即表示  $k$  时刻第  $i$  个粒子采用的量测模型为  $m_k^i = c$ .在此基础上,依据量测似然度形式实现粒子权重的度量,即

$$\omega_k^i = \omega_{k-1}^i p(\mathbf{z}_k^i | \mathbf{x}_k^i), \quad (5)$$

其中  $z_k^{m_k^i}$  为当前时刻第  $i$  个粒子选取的用于实现量测似然度计算的量测值. 式 (5) 与标准 PF 中的度量粒子权重的区别在于不再依赖于某个固定传感器的量测值, 而是最大可能地选取不含扰动影响的传感器量测数据. 考虑到量测模型随机采样过程中部分粒子采用的量测模型与有效量测模型之间的偏差, 利用重采样所特有的复制大权重粒子、删减小权重粒子的特性实现对这种偏差的修正. 其实现过程通过如下伪代码形式给出:

1) 构造累计分布函数 CDF:

```

 $g_0 = 0$ 
FOR  $i = 1, 2, \dots, N$ 
     $g_i = g_{i-1} + \varpi_k^i$ 
END FOR
    
```

2) 从均匀分布  $\mathcal{U}(0, 1/N)$  抽取起始点  $\lambda_0$

3) 依归一化粒子权重  $\varpi_k^i$  实现重采样

```

FOR  $i = 1, 2, \dots, N$ 
     $\lambda_j = \lambda_0 + (j-1)/N$ 
    WHILE  $\lambda_j > g_i$ 
         $i = i + 1$ 
    END WHILE
     $x_k^j = x_k^i$ 
     $m_k^j = m_k^i$ 
END FOR
    
```

$x_k^j$  表示重采样后的粒子,  $m_k^i$  和  $m_k^j$  分别表示重采样前和重采样后第  $i$  粒子所对应的量测模型. 根据 Monte Carlo 仿真原理和量测模型概率最大化原则, 当前时刻系统状态估计的求解和量测传感器的选取方法如下:

$$\hat{x}_{k/k} = \sum_{j=1}^N x_k^j / N, \tag{6}$$

$$P(l) = \sum_{j=1}^N \delta(l - m_k^j) / N, \tag{7}$$

$$m_k \triangleq \max(P(l)), \tag{8}$$

其中  $P(l)$  所体现的物理含义为量测模型  $l$  在  $k$  时刻为有效量测模型的概率. 由式 (8) 获得每个模型概率后, 当前时刻有效量测模型  $m_k$  即为选取量测模型集中概率值最大的量测模型.

### 4 仿真结果与分析

为验证算法的可行性和有效性, 选用文献 [6] 中的典型非线性系统测试模型进行实验, 并设定确定性扰动和随机性扰动两种量测受扰动影响的场景. 仿真实验中对比了 M-PF, S-PF 和 MAPF 等 3 种算法. 其中 M-PF 为采用量测精度加权融合准则的多传感器集中

式粒子滤波算法, S-PF 为采用滤波误差协方差加权融合的多传感器分布式粒子滤波算法.

$$x_{k+1} = 0.5x_k + \frac{25x_k}{1+x_k^2} + 8\cos(\xi k) + u_k,$$

$$y_k^l = \frac{x_k^2}{20} + v_k^l + e_k^l.$$

该模型也被称为单变量非静态增长模型, 具有强非线性特性. 系统噪声  $u_k$  服从高斯分布, 其噪声统计特性满足  $\mathcal{N}(0, 10)$ ; 量测噪声  $v_k^l$  服从高斯分布, 其噪声统计特性分别为  $\mathcal{N}(0, 1)$  和  $\mathcal{N}(0, 1.2)$ ; 外界扰动  $e_k^l$  的统计特性服从参数为 4 的泊松分布. 确定性扰动对传感器量测值的影响方式设定如下: 1~10 采样时刻, 传感器 1 的量测数据受到扰动影响, 传感器 2 的量测未受到外界扰动的影响; 10~20 采样时刻, 传感器 1 和传感器 2 的量测均未受到外界扰动的影响; 21~30 采样时刻, 传感器 1 的量测未受到外界扰动的干扰, 传感器 2 的量测受到扰动影响. 考虑到扰动影响的连续性, 量测模型状态的转移概率矩阵取为

$$H_1 = \begin{bmatrix} 0.9 & 0.1 \\ 0.1 & 0.9 \end{bmatrix}.$$

随机性扰动对传感器量测数据影响的时刻则没有固定的规律, 任何时刻传感器 1 和传感器 2 的量测都可能受到外界扰动影响, 这里量测模型状态的转移概率矩阵取为  $\begin{bmatrix} 0.7 & 0.3 \\ 0.3 & 0.7 \end{bmatrix}$ . 采样间隔  $\tau = 1$ , Monte Carlo 仿真循环次数为 50, 仿真步数为 30, 采样粒子个数  $N = 300$ , 状态的初始值  $x_0 = 1$ .

图 1 和图 2 分别给出了 50 次 Monte Carlo 仿真第 10 次量测模型的辨识结果. 图中纵坐标的 1 和 2 分别表示传感器 1 在不含外界扰动影响和含外界扰动影响条件下量测模型状态, 纵坐标的 3 和 4 分别表示传感器 2 在不含外界扰动和含外界扰动影响条件下的量测模型状态. “☆”, “○”和“.”分别表示含外界扰动影响的量测模型状态、不含外界扰动影响的量测模型状态以及 MAPF 算法中对这些量测模型的利用情况. 表 1 中的数据定量地给出了各滤波算法状态估计的均方根误差的均值、扰动量测误判率以及平均运行时间结果的比较.

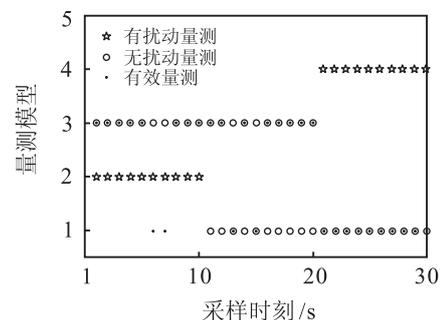


图 1 确定性扰动情况下量测模型辨识

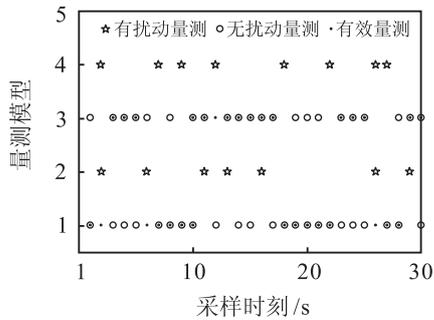


图2 随机性扰动情况下量测模型辨识

表1 确定/随机扰动条件下RMSE的均值、量测误判率及平均运行时间比较

算法	M-PF	S-PF	MAPF
RMSE 均值	4.543/4.871	5.099/5.307	3.680/4.214
量测误判率	0.667/0.486	0.667/0.486	0.899/0.165
算法耗时	1.146/1.015	2.348/2.055	1.507/1.319

由图1和图2可知:在确定性扰动场景下,MAPF仅在第6和第7个采样时刻采用了含扰动影响的传感器1的量测数据,而滤波过程的其他时刻有效量测均采用了两传感器在无扰动影响下的量测数据;在随机性扰动场景下,MAPF仅在第2,第6和第26个采样时刻采用了含扰动影响的传感器1的量测数据,以及在第12个采样时刻采用了含扰动影响的传感器2的量测数据。

由图3和图4给出的仿真结果可知:MAPF的状态估计精度优于M-PF和S-PF,其主要原因在于M-PF和S-PF虽然利用多传感器加权融合方式降低了含扰动量测对估计精度的影响,但滤波过程中毕竟采用了所有含扰动影响的量测数据,而MAPF实现中则最大

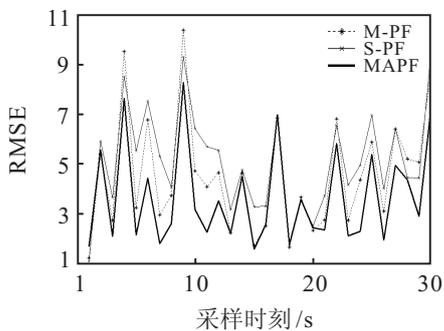


图3 确定性扰动情况下RMSE比较

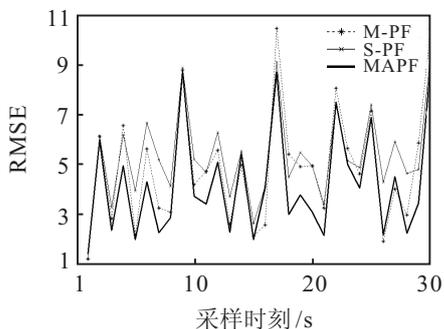


图4 随机性扰动情况下RMSE比较

程度地选取了不含扰动影响的量测数据,因此相对于M-PF和S-PF能够获得更好的滤波精度。

## 5 结论

近年来,PF以其处理非线性非高斯问题所具有的灵活性和可靠性得到了国内外学者的广泛关注。PF利用一组附带权重的采样粒子完成对状态后验概率密度的逼近,其有效性的前提在于对粒子权重的精确度量。但在量测不确定条件下,外界扰动的影响将降低利用量测似然度获得的粒子权重的可靠性和稳定性。针对此类问题,本文给出了一种量测不确定条件下多传感器自适应粒子滤波算法。相对现有的处理方法,本文算法具有以下优势:首先,以PF机理为本文算法的构建基础,使得MAPF具有能够较好地解决非线性非高斯问题的优点;其次,以多传感器融合系统为算法实现的硬件基础,可充分利用多传感器量测中的冗余和互补信息,同时提升算法的应用范围;另外,MAPF实现过程中充分利用了PF中随机采样和重采样的优势,使得算法具有较好的稳定性和实时性;最后,MAPF中采用了标准PF算法,而针对不同的应用背景和特点,可将一些现有的改进PF算法移植于MAPF算法框架,从而使得算法具有较好的可扩展性。

## 参考文献(References)

- [1] 邓自立, 顾磊, 冉陈键. 带相关噪声的观测融合稳态Kalman滤波算法及其全局最优性[J]. 电子与信息学报, 2009, 31(3): 556-560.  
(Deng Z L, Gu L, Ran C J. Measurement fusion steady-state Kalman filtering algorithm with correlated noises and global optimality[J]. J of Electronics and Information Technology, 2009, 31(3): 556-560.)
- [2] Subrata B, Chandrani R. Comparison of estimation techniques using Kalman filter and grid-based filter for linear and non-linear system[C]. Int Conf on Computing: Theory and Applications. Kolkata: IEEE Press, 2007: 516-520.
- [3] Ito K, Xiong K. Gaussian filters for nonlinear filtering problems[J]. IEEE Trans on Automatic Control, 2000, 45(5): 910-927.
- [4] Karlsson R. Particle filter for positioning and tracking applications[D]. Linköping: Department of Electrical Engineering, Linköping University, 2005.
- [5] Blom H A P, Bloem E A. Exact Bayesian and particle filtering of stochastic hybrid systems[J]. IEEE Trans on Aerospace and Electronic Systems, 2007, 43(1): 55-70.
- [6] 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.