

基于多传感器粒子权重优化的两级 Rao-Blackwellized 粒子滤波算法^①

胡振涛^{②*} 付春玲^{**} 刘先省^{*}

(* 河南大学图像处理与模式识别研究所 开封 475001)

(** 河南大学基础实验中心 开封 475001)

摘要 针对粒子滤波(PF)计算量大、粒子退化以及缺乏对多传感器量测系统状态估计的适用性等问题的综合处理,提出了一种基于多传感器粒子权重优化的两级 Rao-Blackwellized 粒子滤波(RBPF)算法。该算法首先采用 Rao-Blackwellized 建模技术实现对估计系统状态演化过程的建模,并结合加权融合策略完成多传感器量测对于粒子权重的优化。其次,通过两级预测更新机制的构建和引入,实现最新量测信息对于当前时刻粒子估计结果的修正。另外,考虑到重采样后粒子多样性枯竭问题,在滤波结果中蕴含冗余和互补信息的提取和利用的基础上,给出了一种粒子多样性增强方法。理论分析和仿真实验验证了此算法的可行性和有效性。

关键词 多源信息融合,非线性估计, Rao-Blackwellized 粒子滤波(RBPF),权重优化

0 引言

随着对感知对象认识的不断深入以及对估计和控制任务要求的日益提高,人们在诸如目标跟踪、故障诊断等复杂系统状态估计过程中越来越难以回避非线性、非高斯和分布式等问题^[1,2]。近年来,基于序贯重要性采样技术和递推贝叶斯理论发展起来的粒子滤波(particle filter, PF)在理论上给出了一种有效处理非线性、非高斯问题的方法,但此方法获取较高估计精度的前提是粒子数目趋于无穷,这必然造成算法计算量急剧增加^[3],此外,为有效改善序贯重要性采样和重采样导致的粒子退化和粒子多样性枯竭现象,必须保障粒子有效采样以及粒子权重合理度量^[4,5]。在降低计算量的研究方面,针对状态可分的一类非线性系统,可利用 Rao-Blackwellised 粒子滤波(RBPF)在状态降维处理基础上构建线性状态分量估计结果和非线性状态分量估计结果之间的反馈机制,使得算法实时性和滤波精度相对于标准 PF 具有明显改善,并已成功应用于机动目标跟踪领域^[6,7]。对于粒子退化和粒子多样性枯竭问题,国内外一些专家学者也相继结合提议分布优

选^[8,9]、马尔可夫蒙特卡洛移动^[10]、核函数构造^[11]以及智能优化^[12]等技术给出了 PF 的改进算法。相对于标准 PF,针对不同具体的应用背景其算法的滤波精度获得一定程度的改善。但以上方法的共同缺陷在于算法构建原理局限在单传感器量测系统,而面向多传感器融合系统自身特点实现 PF 算法设计和应用的研究相对较少,因此限制了 PF 在应用领域和范围上的推广和进一步的拓展。

基于以上分析,在 PF 算法框架下,本文结合 Rao-Blackwellized 建模方法、多源信息融合以及 Kalman 滤波(KF)技术,提出了一种基于多传感器粒子权重优化(multi-sensor particle Weight Optimization)的两级(two-stage)RBPF 算法,简称为 TSRBPF-WO 算法。仿真实验结果表明,该算法在计算量和滤波精度方面明显优于标准 PF 算法,并且在滤波精度方面优于 RBPF 算法。

1 Rao-Blackwellised 粒子滤波(RBPF)

考虑下面具有多传感器量测特性且状态可分的非线性系统:

$$x_{k+1}^p = f(x_k^p) + A_k^L x_k^L + B_k^p u_k^p \quad (1)$$

① 国家自然科学基金(60972119,61170243),河南省创新人才培养计划(114100510001)和河南省青年骨干教师资助计划(2010GGJS-041)资助项目。

② 男,1979 年生,博士;研究方向:多源信息融合,非线性滤波;联系人,E-mail: hzt@henu.edu.cn (收稿日期:2011-11-04)

$$x_{k+1}^l = A_k^l x_k^l + B_k^l u_k^l \quad (2)$$

$$z_{k,j} = h(x_k^p) + v_{k,j}, j = 1, 2, \dots, M \quad (3)$$

式中 x_k^p 和 x_k^l 分别为非线性状态分量和线性状态分量, $x_k = [x_k^p \ x_k^l]^T$ 为系统状态向量。 $f(\cdot)$ 和 A_k^l 分别为非线性状态分量和线性状态分量的状态演化函数。 B_k^p 和 B_k^l 分别为非线性状态分量和线性状态分量的系统噪声矩阵。系统噪声为 $u_k = [u_k^p \ u_k^l]^T$, 且 $u_k^p \sim N(0, Q_k^p)$, $u_k^l \sim N(0, Q_k^l)$ 。 $z_{k,j}$ 为量测向量, j 表示融合系统中传感器的标号。 $h(\cdot)$ 为量测演化函数, 这里仅考虑同质传感器, 因此取相同的数学表达式。量测噪声 $v_{k,j} \sim N(0, \sigma_{k,j}^2)$; 对于公式(1)做进一步变换得

$$\bar{z}_k = x_{k+1}^p - f(x_k^p) = A_k^l x_k^l + B_k^p u_k^p \quad (4)$$

\bar{z}_k 被认为是虚拟量测值, 则式(2)和式(4)中所描述系统为线性高斯的, 因此可以利用 Kalman 滤波对 x_k^l 进行估计, 而对于式(1)和式(3)描述的非线性系统则可以采用 PF 实现对 x_k^p 的估计, 以上即 RBPF 建模和滤波的实现机理^[13]。

2 TSRBPF-WO 算法

2.1 非线性状态分量的两级预测更新机制

在 PF 算法框架下, 粒子有效采样和粒子权重合理度量是获得较好估计精度的两个重要方面。粒子有效采样主要解决在当前时刻粒子采样中引入最新量测信息, 具体实现方式是采用提议分布优选方式。此类方法的实现一般需要引入某个特定次优滤波器, 典型算法如 EPF 和 UPF^[14]。但此类算法的实现需要对每个粒子运行一个次优滤波器, 无疑将导致计算量的急剧膨胀, 尤其当被估计系统状态维数较高时, 计算量的增加更为显著。另外, 次优滤波器一般受限于被估计系统的非线性强度和噪声高斯的假设。造成改进算法缺乏普适性。针对现有提议分布优选方式存在的问题, 本节给出了一种两级预测更新机制。通过两类不同实现贝叶斯估计方法动态结合和滤波增益的构建实现最新量测信息对系统状态估计的直接优化, 进而完成对最新量测信息的利用。图 1 和图 2 分别给出了提议分布优选原理和两

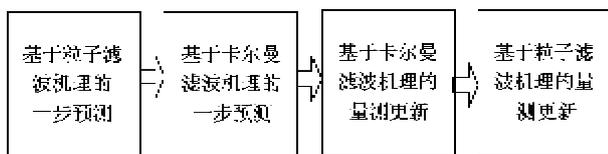


图 1 提议分布优选原理

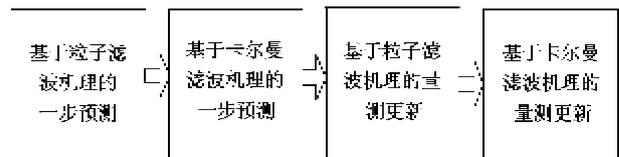


图 2 两级预测更新原理

级预测更新机制, 从而可直观地看出两者在实现上的主要区别。

由图 2 可知, 两级预测更新机制通过滤波增益合理构建实现了量测信息对状态估计的直接优化, 每个采样时刻仅仅需要完成一次求逆运算, 大大简化了计算复杂度。另外, 依据滤波增益实现量测更新步骤被设计在整个滤波流程后端, 有利于减弱量测信息和粒子集中原始信息的损失^[15]。

2.2 多传感器量测下的粒子权重优化策略

在采样粒子数目有限的条件下提升粒子滤波精度的另外一个重要方面是粒子权重的合理度量。粒子权重计算是否精确不仅取决于提议分布的选取形式, 同时受到随机量测噪声的影响。考虑到多传感器融合结构使得单个滤波周期存在多个量测数据, 客观上提供了融合多个量测信息和改善随机量测噪声影响的必要条件, 下面结合多传感器当前时刻的量测数据, 利用加权融合思想给出一种粒子权重的优化策略。首先, 利用第 k 个采样时刻传感器 j 量测计算粒子权重 $\omega_{k,j}^i$ 。粒子权重的表达式为

$$\omega_{k,j}^i = \omega_{k-1,j}^i \frac{1}{\sqrt{2\pi\sigma_{k,j}^2}} \exp\{-[h(x_k^{p,i}) - h(x_k^p) - v_{k,j}]^2 / 2\sigma_{k,j}^2\} \quad (5)$$

由式(5)可知, $\omega_{k,j}^i$ 服从均值为 $\exp(h(x_k^p) + \sigma_{k,j}^2/2)$ 、方差为 $((\exp(\sigma_{k,j}^2) - 1)\exp(2h(x_k^p) + \sigma_{k,j}^2))^2$ 的对数高斯分布^[16]。其次, 计算第 k 个采样周期内采用 $\lambda_{k,j}$ 为权系数融合后粒子 i 的权重 $\hat{\omega}_k^i$ 。其表达式为

$$\hat{\omega}_k^i = \omega_{k-1}^i \sum_{j=1}^M \lambda_{k,j} \frac{1}{\sqrt{2\pi\sigma_{k,j}^2}} \exp\{-[h(x_k^{p,i}) - h(x_k^p) - v_{k,j}]^2 / 2\sigma_{k,j}^2\} \quad (6)$$

根据高斯分布自身具有的性质

$$\sigma_{\hat{\omega}_k^i} = \sqrt{\sum_{j=1}^M (\lambda_{k,j} (\exp(\sigma_{k,j}^2) - 1) \exp(2h(x_k^p) + \sigma_{k,j}^2))^2} \quad (7)$$

经过融合后所得输出 $\hat{\omega}_k^i$ 的期望为各传感器期望的

加权平均值。其中, $\sigma_{\hat{\omega}_k}$ 值越小则表明融合后输出的精度越高, 显然在 $\sigma_{k,j}$ 一定的条件下, 式(7)的值与权 $\lambda_{k,j}$ 的分配密切相关。为了使得融合后精度达到最高, $\sigma_{\hat{\omega}_k}$ 应该达到最小, 结合信息守恒原理 $\sum_{j=1}^M \lambda_{k,j} = 1 (\lambda_{k,j} \geq 0, j = 1, 2, \dots, M)$, $\sigma_{\hat{\omega}_k}$ 计算则可进一步归结为条件求极值的问题, 即已知 $\sigma_{k,j}$ 且满足信息守恒原理条件下, 求 $\lambda_{k,j}$ 的解析解使得 $F(\lambda_{k,1}, \lambda_{k,2}, \dots, \lambda_{k,M}) = \sum_{j=1}^M (\lambda_{k,j} (\exp(\sigma_{k,j}^2) - 1) \exp(2h(x_k^{p,i}) + \sigma_{k,j}^2))^2$ 的值最小, 具体采用拉格朗日乘数法进行求解, 得 $\lambda_{k,j}$ 的表达式

$$\lambda_{k,j} = 1 / (\xi_{k,j}^2 \sum_{j=1}^M 1 / \xi_{k,j}^2) \quad (8)$$

在获得 $\lambda_{k,j}$ 的基础上, 可最终获得融合后 $\sigma_{\hat{\omega}_k}$ 的精度

$$\sigma_{\hat{\omega}_k} = 1 / \sqrt{\sum_{j=1}^M 1 / \xi_{k,j}^2} \quad (9)$$

当各传感器精度不同, 且设最高精度和最低精度分别为 $\sigma_{k,\max}^2$ 和 $\sigma_{k,\min}^2$ 时, 则有

$$\sigma_{\hat{\omega}_k} \leq 1 / \left(\xi_{k,\min}^2 + \sqrt{\sum_{j=1}^{M-2} 1 / \xi_{k,j}^2} \right) \quad (10)$$

由式(10)可知: 在粒子权重优化过程中, 对多传感器分布式结构中获取的量测似然函数采用以上加权融合方式得到的处理结果, 即使精度再差的传感器量测也有利于减小粒子权重方差, 这一结论同时也为应用多传感器量测提升粒子权重精度方法可行性提供了重要的理论依据。

2.3 TSRBPF-WO 算法步骤

结合 RBPF 建模和滤波机理、非线性状态分量的两级预测更新机制以及多传感器量测下的粒子权重优化策略, 下面给出 TSRBPF-WO 算法的具体实现步骤。

(1) PF 框架下状态非线性分量的一步预测

依据系统状态演化方程实现 k 时刻非线性分量粒子 $x_k^{p,i}$ 的采样以及 $x_k^{p,i}$ 量测预测值计算, 并利用量测似然函数实现粒子权重度量。以上过程被认为是在 PF 框架下的状态非线性分量的一步预测。

$$x_k^{p,i} = f(x_{k-1}^{p,i}) + A_{k-1}^p x_{k-1}^{p,i} + B_{k-1}^p u_{k-1}^{p,i} \quad (11)$$

$$z_{k/k-1}^i = h(x_k^{p,i}) \quad i = 1, 2, \dots, N \quad (12)$$

(2) 多传感器量测下粒子权重的优化

利用式(5)计算单传感量测下粒子权重 $\omega_{k,j}^i$, 并依据多传感器量测下的粒子权重优化策略(式(13))实现对粒子权重 $\omega_{k,j}^i$ 的进一步优化。

$$\hat{\omega}_k^i = \omega_{k,j}^i / (\xi_{k,j}^2 \sum_{j=1}^M 1 / \xi_{k,j}^2) \quad (13)$$

(3) KF 框架下状态非线性分量的一步预测

对 $\hat{\omega}_k^i$ 进行归一化处理得权重 ϖ_k^i , 利用 ϖ_k^i 实现 KF 框架下的状态一步预测。

$$x'_{k/k-1} = \sum_{i=1}^N \varpi_k^i x_k^{p,i} \quad (14)$$

$$\bar{z}_{k/k-1} = \sum_{i=1}^N \varpi_k^i z_{k/k-1}^i \quad (15)$$

$$\varepsilon_k^p = z'_k - \bar{z}_{k/k-1} \quad (16)$$

$$z'_k = \sum_{j=1}^M z_{k,j} / (\sigma_{k,j}^2 \sum_{j=1}^M 1 / \sigma_{k,j}^2) \quad (17)$$

$x'_{k/k-1}$ 和 $\bar{z}_{k/k-1}$ 分别表示系统非线性状态分量和量测的一步预测值, ε_k^p 表示残差。为构建滤波增益 K_k^p , 需进一步计算非线性状态分量预测误差协方差 $P_{k/k-1}^p$ 、非线性状态分量与量测的预测误差协方差 $P_{z'}^p$ 以及量测的预测误差协方差(残差协方差) S_k^p 。

$$P_{k/k-1}^p = \sum_{i=1}^N \varpi_k^i [x_k^{p,i} - x'_{k/k-1}] [x_k^{p,i} - x'_{k/k-1}]^T \quad (18)$$

$$P_{z'}^p = \sum_{i=1}^N \varpi_k^i [x_k^{p,i} - x'_{k/k-1}] [z_{k/k-1}^i - \bar{z}_{k/k-1}]^T \quad (19)$$

$$S_k^p = \sum_{i=1}^N \varpi_k^i [z_{k/k-1}^i - \hat{z}_{k/k-1}] [z_{k/k-1}^i - \hat{z}_{k/k-1}]^T + R_k \quad (20)$$

$$R_k = \sum_{j=1}^M \sigma_{k,j}^2 / (\sigma_{k,j}^2 \sum_{j=1}^M 1 / \sigma_{k,j}^2) \quad (21)$$

$$K_k^p = P_{z'}^p (S_k^p)^{-1} \quad (22)$$

(4) PF 框架下状态非线性分量的量测更新

考虑到 PF 实现中粒子退化现象的改善, 引入重采样步骤实现 PF 框架下状态非线性分量的量测更新。重采样后得到一组新的粒子集 $\{x_k^{p,i}, \varpi_k^i\}_{i=1}^N$, 依据蒙特卡罗仿真技术, 非线性状态分量估计 $\bar{x}_{k/k-1}^p$ 可通过求解重采样后粒子算术平均值获得, 计算式为

$$\bar{x}_{k/k-1}^p = \sum_{i=1}^N x_k^{p,i} / N \quad (23)$$

(5) KF 框架下状态非线性分量的量测更新

利用滤波增益 K_k^p 完成最新量测信息对 $\bar{x}_{k/k-1}^p$ 的修正, 最终实现 KF 框架下状态非线性分量的量测更新。

$$\hat{x}_{k/k}^p = \bar{x}_{k/k-1}^p + K_k^p \varepsilon_k^p \quad (24)$$

$$P_{k/k}^p = P_{k/k-1}^p - K_k^p S_k^p (K_k^p)^T \quad (25)$$

$\hat{x}_{k/k}^p$ 和 $P_{k/k}^p$ 分别表示 k 时刻的非线性状态分量估计和非线性状态分量估计的滤波误差协方差。

(6) 粒子多样性提升

为有效改善重采样后的粒子枯竭问题,在合理利用当前时刻滤波结果中蕴含冗余和互补信息的基础上,利用 $\hat{x}_{k/k}^p$ 和 $P_{k/k}^p$ 实现重采样后粒子多样性的提升,具体操作方法如下:

$$\begin{cases} \hat{x}_k^{p,i} = \hat{x}_k^{p,i}, & e_i > \zeta \\ \hat{x}_k^{p,i} = (\hat{x}_k^{p,i} + \hat{x}_{k/k}^p + \sqrt{P_{k/k}^p})/2, & e_i \leq \zeta \end{cases} \quad (26)$$

$e_i \sim U(0,1)$, 为服从 0 至 1 区间均匀分布的随机数。 ζ 为转移控制因子,且 $\zeta \in [0,1]$, 其大小影响着重采样后粒子多样性改善程度。

(7) 线性状态分量的估计

结合式(4)中的虚拟量测,并通过 KF 的预测更新机理实现线性状态分量 $\hat{x}_{k/k}^l$ 的估计。

$$\bar{z}_k = \hat{x}_{k/k}^p - f(\hat{x}_{k-1/k-1}^l) \quad (27)$$

$$\hat{x}_{k/k-1}^l = A_k^l \hat{x}_{k-1/k-1}^l \quad (28)$$

$$P_{k/k-1}^l = A_k^l P_{k-1/k-1}^l (A_k^l)^T + B_k^l Q_k^l (B_k^l)^T \quad (29)$$

$$\varepsilon_k^l = \bar{z}_k - A_k^l \hat{x}_{k/k-1}^l \quad (30)$$

$$S_k^l = A_k^l P_{k/k-1}^l (A_k^l)^T + B_k^l Q_k^l (B_k^l)^T \quad (31)$$

$$K_k^l = P_{k/k-1}^l (A_k^l)^T (S_k^l)^{-1} \quad (32)$$

$$\hat{x}_{k/k}^l = \hat{x}_{k/k-1}^l + K_k^l \varepsilon_k^l \quad (33)$$

$$P_{k/k}^l = P_{k/k-1}^l - P_{k/k-1}^l K_k^l A_k^l \quad (34)$$

其中, $\hat{x}_{k/k-1}^l$ 和 $P_{k/k-1}^l$ 分别是线性状态分量的一步预测值和预测误差协方差阵, ε_k^l 和 S_k^l 分别为残差和残差协方差阵, K_k^l 为滤波增益, $\hat{x}_{k/k}^l$ 和 $P_{k/k}^l$ 分别表示系统线性状态分量的估计值和估计误差协方差阵。

(8) 系统的状态估计

综合非线性状态分量和线性状态分量估计结果最终求解当前时刻系统状态估计 $\hat{x}_{k/k}$:

$$\hat{x}_{k/k} = [\hat{x}_{k/k}^p \quad \hat{x}_{k/k}^l]^T \quad (35)$$

3 仿真实验与分析

为验证算法的可行性和有效性,仿真场景设定为采用精度不同的 3 部两坐标雷达量测数据实现对于 X-Y 平面上运动目标的跟踪,并在相同仿真环境下对 PF、两级 PF (TSPF)、RBPF、两级 RBPF (TSRBPF)、TSRBPF-WO 等 5 种算法状态估计的结果进行比较,其中 TSPF 算法和 TSRBPF 算法分别表示引入了两级预测更新机制的相应改进的 PF 算法和 RBPF 算法。依据目标跟踪系统状态演化自身特点,结合 Rao-Blackwellized 建模,则目标运动方程和量测

方程如下:

$$x_{k+1}^p = Fx_k^p + A_k^l x_k^l + B_k^p u_k^p$$

$$x_{k+1}^l = A_k^l x_k^l + B_k^l u_k^l$$

$$z_{k,j} = [\sqrt{(x_k^p)^2 + (y_k^p)^2} \tan^{-1}(y_k^p/x_k^p)]^T + v_{k,j} \quad j = 1,2,3$$

其中, $x_k^p = [x_k \quad y_k]$, $x_k^l = [\dot{x}_k \quad \dot{y}_k]$, x_k , \dot{x}_k , y_k 和 \dot{y}_k 分别表示目标状态在 X 轴和 Y 轴方向上的位置分量和速度分量; $F = I$, $A_k^l = I$, $I = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$, $B_k^l =$

$$\begin{bmatrix} \tau & 0 \\ 0 & \tau \end{bmatrix}, B_k^p = \begin{bmatrix} \tau^2/2 & 0 \\ 0 & \tau^2/2 \end{bmatrix}$$

采样间隔 $\tau = 1$, 系统噪声 u_k^p 和 u_k^l 采用均值为零,方差为 $0.25I$ 的高斯白噪声;3 部雷达的量测噪声 $v_{k,j}$ 分别采用均值为零,

标准差为 $\begin{bmatrix} R_j^r & 0 \\ 0 & R_j^a \end{bmatrix}$ 的高斯白噪声,其中径向距分

量上 R_j^r 分别取 0.25km、0.15km 和 0.2km,方位角分量上 R_j^a 和 R_j^a 分别取为 0.12° 、 0.15° 和 0.2° 。Monte Carlo 仿真循环次数为 50,仿真步长为 25,采样粒子个数 N 取 5000。

图 3 和图 4 分别给出了在 50 次 Monte Carlo 仿真条件下,5 种算法在 X 轴(水平方向)和 Y 轴(竖直方向)上位置状态的均方根误差 (RMSE) 结果比

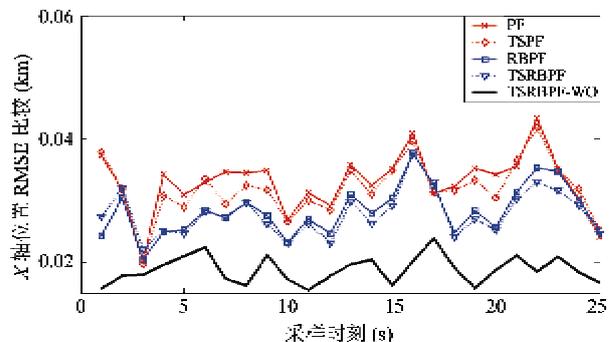


图 3 X 轴方向

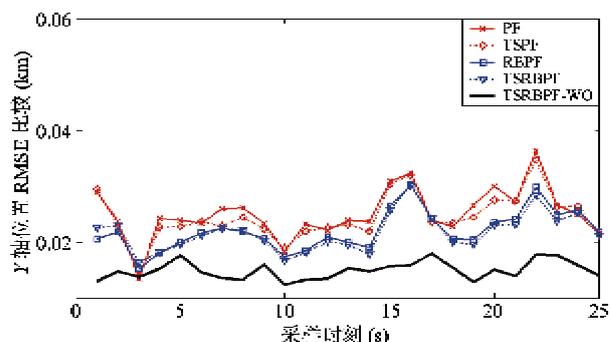


图 4 Y 轴方向

较。由于 PF、TSPF、RBPF 和 TSRBPF 4 种算法的构建和设计前提是单传感器量测系统,因此图中显示的结果相应选取了采用传感器 2 的量测获得的 RMSE,而本文给出的 TSRBPF-WO 算法的设计本身考虑了多传感器量测信息的融合和利用。由图中可以直观看出 RBPF 算法又明显优于 PF 算法,而这两种算法分别引入两级量测更新机制后,其滤波精度又将得到进一步的提升。因此,在单传感器量测信息利用的前提下,TSBPF 算法的 RMSE 曲线更接近坐标轴。但与 TSRBPF-WO 算法比较时,我们发现 TSRBPF-WO 算法的滤波精度相对 TSBPF 算法将再次获得较大的改善,其主要原因就在于通过对多传感器量测信息的合理利用,使得完成滤波实现的采

样粒子权重更加可靠和稳定。表 1 则定量给出了 5 种算法 RMSE 的均值和算法耗时结果,其中对 PF、TSPF、RBPF 和 TSRBPF 算法则分别给出利用 3 个不同传感器量测的 RMSE 均值,其数据则进一步验证了 5 种算法在滤波精度方面的优劣。另外,从算法单次仿真实现的平均运行时间可知,算法耗时最多的是 TSPF,这主要归结于两级预测更新步骤的引入,而在滤波精度上则优于算法耗时次之的标准 PF。5 种算法中耗时最少的是 RBPF 算法,但滤波精度却低于 TSRBPF 算法和 TSRBPF-WO 算法。综合算法的滤波精度和耗时这两个主要度量指标,TSRBPF-WO 算法能够在计算量增加有限的条件下有效提升滤波估计精度。

表 1 基于 50 次 Monte Carlo 仿真条件下 RMSE 的均值和算法耗时比较

算法	X 轴方向(km)			Y 轴方向(km)			算法耗时(s)
	传感器 1 / 传感器 2 / 传感器 3	传感器 1 / 传感器 2 / 传感器 3	传感器 1 / 传感器 2 / 传感器 3				
PF	0.03298 / 0.02781 / 0.02543	0.02513 / 0.02162 / 0.02127		2.5085			
TSPF	0.03196 / 0.02733 / 0.02509	0.02447 / 0.02153 / 0.01926		2.6051			
RBPF	0.02830 / 0.02402 / 0.02259	0.02201 / 0.01908 / 0.01826		1.4413			
TSRBPF	0.02783 / 0.02212 / 0.02153	0.02173 / 0.01718 / 0.01737		1.5263			
TSRBPF-WO	0.01876	0.01493		1.8416			

4 结论

考虑到工程应用的实时性需求,如何在粒子数目有限条件下提升粒子滤波的估计精度,一直是粒子滤波理论研究的热点。针对状态可分的一类非线性系统,结合 Rao-Blackwellized 建模方法、多源信息融合和 KF 技术,本文提出了一种基于多传感器粒子权重优化的两级 RBPF 算法——TSRBPF-WO 算法。构建原理和仿真结果分析表明,相对现有的处理方法,该新算法具有以下优点:首先,利用 Rao-Blackwellized 建模技术对被估计系统状态的分割和建模,从而使其以 RBPF 作为构建算法的基础,相对于 PF 算法,能够在解决非线性、非高斯问题的同时具有较好的实时性能。其次,在粒子采样有效性的提升上采用两级预测更新机制,通过滤波增益合理构建实现了量测信息对状态估计的直接优化,避免了传统提议分布优选类算法优化单个采样粒子造成的算法计算复杂度急剧增大,同时也克服了提议分布优选方式中次优滤波选择不同而造成算法滤波效果的不稳定性问题。此外,采用加权融合方法实现多传感器分布式量测数据利用,使得算法具有对于

量测随机缺失问题不敏感的特性。更最重要的是 TSRBPF-WO 算法直接面向多传感器信息融合系统的设计,极大地拓展了新算法的应用领域。

参考文献

- [1] Ronald P S Mahler. Statistical Multisource-multitarget Information Fusion. Boston, London: Artech House Publishers, 2007. 23-27
- [2] 梁彦,潘泉,杨峰等. 复杂系统的现代估计理论及应用. 北京:科学出版社, 2009. 2-4
- [3] Cappe O, Godsill S J, Moulines E. An overview of existing methods and recent advances in sequential Monte Carlo. *Proceedings of the IEEE*, 2007, 95(5): 899-924
- [4] Li H W, Wang J, Su H T. Improved particle filter based on differential evolution. *Electronics Letters*, 2011, 47(9): 1078-1079
- [5] Gustafsson F. Particle filter theory and practice with positioning applications. *IEEE Aerospace and Electronic Systems Magazine*, 2010, 25(7): 53-82
- [6] Kim J, Park C, Kweon I S. Visual tracking for non-rigid objects using Rao-Blackwellized particle filter. In: *Proceedings of the 2010 IEEE International Conference on Robotics and Automation*, Anchorage, USA, 2010,

- 4537-4544
- [7] Karlsson R. Particle Filter for Positioning and Tracking Applications; [Ph. D dissertation]. Linkoping; Linkoping University Press, 2005. 23-25
- [8] Li L Q, Ji H B, Luo J H. The iterated extended Kalman particle filter. In: Proceedings of the 2005 IEEE International Symposium on Communications and Information Technology, Beijing, China, 2005. 1213-1216
- [9] 祝继华, 郑南宁, 袁泽剑等. 基于中心差分粒子滤波的 SLAM 算法. 自动化学报, 2010, 36(2):249-257
- [10] Zhai Y, Yeary M. Implementing particle filters with metropolis-hastings algorithms. In: Proceedings of the Region 5 Conference: Annual Technical and Leadership Workshop, Oklahoma, USA, 2004. 149-152
- [11] Ntonacci F A, Matteucci M, Migliore D, et al. Tracking multiple acoustic sources in reverberant environments using regularized particle filter. In: Proceedings of the 15th International Conference on Digital Signal Processing, Cardiff, UK, 2007. 99-102
- [12] Seongkeun P, Jae P H, Euntai Kim, et al. A new evolutionary particle filter for the prevention of sample impoverishment. *IEEE Trans on Evolutionary Computation*, 2009, 13(4): 801-809
- [13] Morelande M R, Gordon N. Rao-Blackwellised variable rate particle filters. In: Proceedings of the 12th International Conference on Information Fusion, Washington, USA, 2009. 1-8
- [14] Shi Y, Han C Z, Lian F. The iterated divided difference filter. In: Proceedings of the IEEE International Conference on Automation and Logistics, Qingdao, China, 2008. 1799-1802
- [15] 胡振涛, 潘泉, 杨峰. 基于广义 UT 变换的交互式多模型粒子滤波算法. 电子学报, 2010, 38(6):1143-1148
- [16] Wackerly D O, Mendenhall W, Scheaffer R L. *Advanced Mathematical Statistics*. California: Brooks/Cole Publishing Company, 2007. 213-218

Two-stage Rao-Blackwellised particle filter based on multi-sensor particle weight optimization

Hu Zhentao^{*}, Fu Chunling^{**}, Liu Xianxing^{*}

(^{*}Laboratory of Image Processing & Pattern Recognition, Henan University, Kaifeng 475001)

(^{**}Experiment Teaching Center, Henan University, Kaifeng 475001)

Abstract

Aiming at the comprehensive treatment of particle filters' problems such as large amount of calculations, particle degeneration, and lack of applicability to state estimation for multi-sensor measurement systems, a novel two-stage Rao-Blackwellised particle filter algorithm based on multi-sensor particle weight optimization is proposed. The new algorithm functions as below: Firstly, the Rao-Blackwellised modeling technology is adopted to model the state evolution process of a system needing to estimate, and the weighted fusion strategy is used to optimize the particles' weights by combining with multi-sensor measurement information. Next, through the construction and introduction of a two-stage prediction update mechanism, the estimated result of a current particle is modified by the latest measurement information. In addition, in view of the diversity exhaustion of particles from re-sampling, a new method for enhancement of particle diversity is given by means of the extraction and utilization of redundancy and complementary information from the current filter result. The theoretical analysis and experimental results show the feasibility and efficiency of the proposed algorithm.

Key words: multi-source information fusion, nonlinear estimation, Rao-Blackwellised particle filter (RBPF), weights optimization