

文章编号: 1001-0920(2011)09-1367-06

## 一种改进的基于概率假设密度滤波的多目标跟踪方法

林晓东<sup>a</sup>, 朱林户<sup>b</sup>, 王 瑛<sup>a</sup>

(空军工程大学 a. 工程学院, b. 理学院, 西安 710038)

**摘要:** 针对概率假设密度 (PHD) 滤波使用聚类方法提取目标状态时, 会出现结果不准确, 且 PHD 滤波无法给出状态到航迹关联的问题, 提出一种在目标状态中加入标签的方法来实现状态到航迹的关联. 该方法对权值较大的标签, 通过两次确认来剔除杂波干扰, 得到比传统 PHD 滤波更精确的状态估计. 在提取目标状态时, 只对相同标签的粒子进行处理, 避免使用聚类方法. 通过与传统 PHD 算法的仿真对比表明, 改进算法具有较好的跟踪性能.

**关键词:** 随机有限集统计理论; 多目标跟踪; 概率假设密度滤波; 粒子滤波; 数据关联

中图分类号: TP391

文献标识码: A

## Improved probability hypothesis density (PHD) filter for multi-target tracking

LIN Xiao-dong<sup>a</sup>, ZHU Lin-hu<sup>b</sup>, WANG Ying<sup>a</sup>

(a. Engineering College, b. Science College, Air Force Engineering University, Xi'an 710038, China. Correspondent: LIN Xiao-dong, E-mail: lxd219@163.com)

**Abstract:** To investigate the problem of poor result when the probability hypothesis density (PHD) filter uses clustering technique to extract the target states and the PHD filter keeps no track association, an improved method of the PHD filter is proposed, which inserts a tracking label in the target state. The improved method confirms the label with biggish weight two times to eliminate the influence of clutter, which provides more exact target states than the standard PHD filter. In the states extract step, the improved method only deals with the particle with the same label to avoid using clustering technique. Simulations are presented to compare the performance of the improved method with that of the standard PHD filter. The results show the better tracking performance of the improved method.

**Key words:** finite set statistics theory; multi-target tracking; probability hypothesis density filter; particle filter; data association

### 1 引言

目前的多目标跟踪方法大致可分为两类: 一类是传统的以数据关联为基础的多目标跟踪方法. 数据关联是这类方法的核心, 也是这类方法的难点, 直到现在也没有得到有效的处理方法. 目前比较常用和得到广泛认同的方法有: 概率数据关联 (PDA), 联合概率数据关联 (JPDA) 和多假设数据关联 (MHT) 等. 另一类是基于随机有限集统计理论 (FISST) 的多目标跟踪方法, 如概率假设密度 (PHD) 滤波. 这类方法是近年来出现的, 通过对目标和观测集合的整体处理, 避免了数据关联. 这类算法理论性较强, 能解决复杂环境下数目变化的多目标跟踪问题<sup>[1]</sup>.

FISST 通过把多传感器观测和多目标状态表示成随机有限集, 可将多传感器多目标系统表示成一个

全局的单传感器单目标系统, 从而可将单传感器单目标跟踪方法, 平行地推广到多传感器多目标跟踪问题. 2003 年, Mahler 提出了 PHD 滤波, 也称为“一阶统计矩”滤波器. 它使用多目标随机集后验概率密度的一阶统计量, 近似替代多目标后验概率密度函数, 以此来近似估计目标数目和目标状态<sup>[2]</sup>.

PHD 滤波避免了传统多目标跟踪方法的数据关联, 但 PHD 滤波在采用聚类方法提取目标状态时, 需要将粒子归类, 这在高杂波环境下或目标数目估计不准确的情况下, 会造成目标状态估计不准确. 因此, 从这个意义上而言, 传统多目标跟踪算法数据关联的复杂性, 部分转移到 PHD 滤波状态提取这一过程<sup>[3]</sup>. 另外, PHD 滤波只给出目标状态的估计值, 而无法知道所估计的状态来自哪条航迹, 即无法给出状态到航

收稿日期: 2010-05-17; 修回日期: 2010-07-13.

作者简介: 林晓东(1982—), 男, 博士生, 从事随机集理论的多目标跟踪研究; 朱林户(1950—), 男, 教授, 博士生导师, 从事概率度量空间、随机集理论等研究.

迹的关联. 这给一些后续处理(如目标识别和态势评估)带来不便.

针对上述问题, 在后来的研究中, 许多学者致力于将状态到航迹关联的功能加入 PHD 滤波中, 这些做法大致可分为两类: 一类是对 PHD 滤波的结果进行处理<sup>[3-4]</sup>. 例如, 文献[3]采用的是状态到航迹的关联, 通过关联两相邻时刻 PHD 滤波的结果, 确定当前估计的状态属于前一时刻哪个目标的航迹. [4]采用的是类似于量测到航迹的关联, 利用 PHD 滤波结果指导观测集合的筛选, 剔除其中可能的虚警或杂波观测, 然后把认为来自目标的观测用 MHT 法进行目标跟踪与识别. 此时, PHD 滤波起到剔除杂波的作用. 另一类方法是在目标状态中加入标签以标记目标<sup>[5-6]</sup>. [5]的基本做法是将新生粒子附于相同的标签, 在进行完 PHD 滤波后, 根据滤波结果将粒子聚成  $N$  类, 计算每一类中相同标签的权值之和, 将权值最大的标签所代表的粒子组作为该类的估计值, 并将该标签作为一个轨迹标签. 该方法虽然计算量较小, 但仍需对粒子进行聚类, 可能因聚类的不稳定, 造成最后状态估计不准确. [6]研究了对说话人的跟踪, 它的基本做法是将新生粒子附于不同的标签, 在滤波之后, 检查每个标签的权值, 若大于某个阈值(例如 0.5), 则认为此标签所代表的粒子是目标的一个估计. 该方法避免了聚类分析, 但假设每一观测时刻最多只出现一个新目标, 这在实际应用中不合适.

本文通过实例详细分析了 PHD 粒子滤波过程及其存在的缺陷, 针对这些缺陷, 提出了一种在目标状态中加入标签的方法, 解决了状态到航迹的关联问题, 避免了使用聚类方法提取目标状态. 最后通过仿真实验对比了改进算法与传统 PHD 算法的跟踪性能.

## 2 基于随机集理论框架的多目标跟踪问题

### 2.1 多目标跟踪的随机集模型

在多目标跟踪中, 随着目标的出现、消失, 目标数目及目标状态都是随时间变化的; 由于存在漏检、虚警和杂波, 传感器收集到的观测也是随时间变化的. 在随机集理论框架下, 可将目标状态和传感器观测理解为“随机有限集合”, 而不是通常的变量序列形式, 从而可以更自然、有效地模拟多传感器观测和多目标状态<sup>[1]</sup>.

给定  $k$  时刻状态集  $X_k$ , 则  $k+1$  时刻目标的状态集可用状态空间的随机有限集  $X_{k+1}$  表示为

$$X_{k+1} = S_{k+1|k}(X_k) \cup B_{k+1|k}(X_k) \cup \Gamma_{k+1}. \quad (1)$$

式中:  $S_{k+1|k}(X_k)$  表示  $k$  时刻的状态集  $X_k$  在  $k+1$  时刻仍然存在的目标随机集,  $B_{k+1|k}(X_k)$  表示由  $X_k$  衍生的目标随机集,  $\Gamma_{k+1}$  表示在  $k+1$  时刻瞬间出现的

新目标的随机集. 目标从  $k$  时刻的状态集转移到  $k+1$  时刻的状态集, 可用多目标状态转移密度函数  $f_{k+1}(X_{k+1}|X_k)$  表示.

$k$  时刻的多目标观测根据有限集可描述为

$$Z_k = O_k(X_k) \cup C_k. \quad (2)$$

式中:  $O_k(X_k)$  表示由目标状态集  $X_k$  产生的观测随机集;  $C_k$  表示由杂波引起的观测随机集.  $k$  时刻的观测集可用多目标联合似然函数  $g_k(Z_k|X_k)$  表示.

类似于单目标跟踪的 Bayes 滤波理论, 基于随机集的多目标跟踪预测和更新方程分别为

$$f_{k+1|k}(X|Z^{(k)}) = \int f_{k+1|k}(X|W) f_{k|k}(W|Z^{(k)}) \delta W, \quad (3)$$

$$f_{k+1|k+1}(X|Z^{(k+1)}) = \frac{g_{k+1}(Z_{k+1}|X) f_{k+1|k}(X|Z^{(k)})}{\int g_{k+1}(Z_{k+1}|X) f_{k+1|k}(X|Z^{(k)}) \delta X}. \quad (4)$$

### 2.2 多目标跟踪的 PHD 滤波

方程 (3) 和 (4) 中的多目标状态转移密度函数和传感器似然函数, 在目标数较多时计算量很大<sup>[7]</sup>. 因此, Mahler 提出用 PHD 滤波来近似实现<sup>[2]</sup>.

PHD  $D_\Xi$  表示随机有限集  $\Xi$  的一阶矩, 它是由下式定义的:

$$D_\Xi(x) = \mathbb{E} \left[ \sum_{y \in \Xi} \delta_y(x) \right] = \int \sum_{y \in \Xi} \delta_y(x) f_\Xi(X) \delta X. \quad (5)$$

在多目标跟踪问题中,  $D_\Xi(x_0)$  表示在  $x_0$  点期望的目标密度;  $\int D_\Xi(x) dx$  表示出现在  $S$  内期望目标数. 而  $D_\Xi(x)$  的极值, 给出了目标的状态估计.

PHD 滤波包括预测和更新两步, 其推导过程可参考文献 [2], 本文直接给出公式.

PHD 预测方程为

$$(\Phi_{k|k-1}\alpha)(x) = \int \phi_{k|k-1}(x, \xi) \alpha(\xi) \lambda(d\xi) + \gamma_k(x). \quad (6)$$

式中:  $\phi_{k|k-1}(x, \xi) = e_{k|k-1}(\xi) f_{k|k-1}(x|\xi) + b_{k|k-1}(x|\xi)$ ;  $\gamma_k$  为  $k$  时刻新出现的随机有限集  $\Gamma_k$  的 PHD;  $b_{k|k-1}(\cdot|\xi)$  为随机有限集  $B_{k|k-1}(\{\xi\})$  的 PHD, 即由前一时刻状态为  $\xi$  的目标所衍生的随机有限集的 PHD;  $e_{k|k-1}(\xi)$  为  $k-1$  时刻状态为  $\xi$  的目标在  $k$  时刻仍然存在的概率;  $f_{k|k-1}(\cdot|\cdot)$  为单目标状态转移密度函数;  $g_k(\cdot|\cdot)$  为单目标似然函数.

PHD 更新方程为

$$(\Psi_k\alpha)(x) = \left[ v(x) + \sum_{z \in Z_k} \frac{\psi_{k,z}(x)}{\kappa_k(z) + \langle \psi_{k,z}, \alpha \rangle} \right] \alpha(x). \quad (7)$$

式中:  $v(x) = 1 - P_D(x)$ ,  $\kappa_k(z) = \lambda_k c_k(z)$ ,  $\psi_{k,z}(x) = P_D(x) g_k(z|x)$ ,  $c_k$  为杂波的概率密度,  $\langle f, h \rangle = \int f(x) h(s) \lambda(dx)$ ,  $\lambda_k$  为每一观测时刻的平均杂波数

量,  $P_D$  为传感器的检测概率.

### 2.3 PHD 的粒子滤波实现

方程 (6) 和 (7) 的积分很难求解, 一般采用粒子滤波对 PHD 加以实现<sup>[8-9]</sup>, 简要描述如下:

假设初始时刻 (即  $k = 0$ ), 给定一组粒子  $\{w_k^{(i)}, x_k^{(i)}\}_{i=1}^{L_k}$  表示 PHD  $D_k$ , 则  $k > 0$  时刻的 PHD 及目标状态估计可由以下步骤得到:

#### 1) 预测

$$\tilde{x}_k^{(i)} \sim \begin{cases} q_k(\cdot | x_{k-1}^{(i)}, Z_k), & i = 1, 2, \dots, L_{k-1}; \\ p_k(\cdot | Z_k), & i = L_{k-1} + 1, \dots, L_{k-1} + J_k. \end{cases}$$

式中:  $q_k(\cdot | x_{k-1}^{(i)}, Y_k)$  可取为单目标的状态转移密度函数  $f_{k|k-1}(\cdot | x_{k-1}^{(i)}, Z_k)$ ;  $p_k(\cdot | Z_k)$  为新生目标的概率密度函数, 可取为观测区域内的均匀分布.

计算粒子的权重 (包括转移粒子的权重和新生粒子的权重)

$$\tilde{w}_{k|k-1}^{(i)} = \begin{cases} \frac{\phi_k(\tilde{x}_k^{(i)}, x_{k-1}^{(i)})}{f_{k|k-1}(\tilde{x}_k^{(i)} | x_{k-1}^{(i)}, Z_k)} w_{k-1}^{(i)}, & i = 1, 2, \dots, L_{k-1}; \\ \frac{r_k(\tilde{x}_k^{(i)})}{J_k p_k(\tilde{x}_k^{(i)} | Z_k)}, & i = L_{k-1} + 1, \dots, L_{k-1} + J_k. \end{cases}$$

#### 2) 更新. $k$ 时刻收到新观测 $Z_k$ , 对权重进行更新.

对每个  $z \in Z_k$ , 计算  $C_k(z) = \sum_{j=1}^{L_{k-1}+J_k} \psi_{k,z}(\tilde{x}_k^{(j)}) \tilde{w}_{k|k-1}^{(j)}$ ,

对  $i = 1, 2, \dots, L_{k-1} + J_k$ , 更新粒子权重

$$\tilde{w}_k^{(i)} = \left[ 1 - P_D(\tilde{x}_k^{(i)}) + \sum_{z \in Z_k} \frac{\psi_{k,z}(\tilde{x}_k^{(i)})}{\kappa_k(z) + C_k(z)} \right] \tilde{w}_{k|k-1}^{(i)}.$$

#### 3) 重采样. 计算估计目标数 $\tilde{N}_{k|k} = \sum_{j=1}^{L_{k-1}+J_k} \tilde{w}_k^{(j)}$ ,

对粒子集  $\{\tilde{w}_k^{(i)} / \tilde{N}_{k|k}, \tilde{x}_k^{(i)}\}_{i=1}^{L_{k-1}+J_k}$  进行重采样, 得到新的粒子集  $\{w_k^{(i)} / \tilde{N}_{k|k}, x_k^{(i)}\}_{i=1}^{L_k}$ .

#### 4) 目标状态提取:

① 目标数  $\hat{N}_k = [\hat{N}_{k|k}]$ ,  $[\cdot]$  表示取最近的整数;

② 将粒子分成  $\hat{N}_k$  个集合  $S_{i,k} (i = 1, 2, \dots, \hat{N}_k)$ , 即  $\hat{N}_k$  类, 对于任意的  $i$  有  $S_{i,k} \cap S_{j,k} = \emptyset, i \neq j$ ;

③ 对每个  $i$  求  $S_{i,k}$  的中心  $\hat{x}_{i,k}$ , 则  $\{\hat{x}_{i,k}\}_{i=1}^{\hat{N}_k}$  为所估计的目标状态.

## 3 PHD 粒子滤波过程及其缺陷的详细分析

### 3.1 仿真环境假设

假设观测区域为  $S = [0, 400] \times [0, 400]$ , 采用雷达进行探测. 每一时刻出现的目标数服从参数  $\lambda_b = 0.1$  的泊松分布,  $k$  时刻存在的目标在  $k + 1$  时刻仍然存在的概率为  $e_{k+1|k} = 0.98$ , 传感器检测率  $P_D = 0.99$ , 目标状态为  $(x, y, \dot{x}, \dot{y})^T$ ,  $(x, y)$  为目标位置信息,  $(\dot{x}, \dot{y})$  为目标速率信息. 目标运动模型为

$$X_k = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} X_{k-1} + \begin{bmatrix} T^2/2 & 0 \\ 0 & T^2/2 \\ T & 0 \\ 0 & T \end{bmatrix} \begin{bmatrix} v_{1,k} \\ v_{2,k} \end{bmatrix}. \quad (8)$$

式中:  $v_{1,k}$  和  $v_{2,k}$  为相互独立的噪声向量, 均服从均值为 0 的正态分布, 标准差分别为 1 和 0.1.

雷达的观测模型为  $Z_k = (\theta, R)^T + V_k$ , 其中目标距离  $R = \sqrt{(x - x_r)^2 + (y - y_r)^2}$ ; 角度  $\theta = \arctan \frac{x - x_r}{y - y_r}$ ,  $(x_r, y_r)$  为雷达的位置坐标;  $V_k = (V_k^\theta, V_k^R)^T$ ,  $V_k^\theta$  和  $V_k^R$  是相互独立的噪声向量, 均服从均值为 0 的正态分布,  $\sigma_\theta = 0.05$ ,  $\sigma_R = 2$ . 假设每个观测时刻杂波的数目服从  $\lambda_c = 10$  的泊松分布, 且杂波均匀分布在平面  $S$  内.

### 3.2 PHD 粒子滤波过程分析

假设在  $k-1$  时刻目标的状态集为  $X_{k-1} = \{x_{k-1}^{(1)}, x_{k-1}^{(2)}\}$ , 它由一组粒子  $X_{k-1,w} = \{w_{k-1}^{(i)}, x_{k-1}^{(i)}\}_{i=1}^{L_{k-1}}$  表示. 对于  $X_{k-1,w}$  里的每个粒子  $x_{k-1}^{(i)}$ , 产生一个 0-1 分布的随机数  $u_1$ , 若  $u_1 > 1 - e_{k|k-1}(x_{k-1}^{(i)})$ , 则表示  $x_{k-1}^{(i)}$  在  $k$  时刻继续存在. 假设这组粒子只有两个, 即

$$x_{k-1}^{(1)} = [225.9, 2.2, 117.9, 1.63]^T,$$

$$x_{k-1}^{(2)} = [150.8, 1.3, 100.4, 0.5]^T.$$

初始权重为  $w_{k-1}^{(1)} = w_{k-1}^{(2)} = 0.5$ . 由运动模型 (8), 可得到  $k$  时刻状态的预测值为

$$\tilde{x}_{k|k-1}^{(1)} = [229.6, 3.2, 115.6, -1.29]^T,$$

$$\tilde{x}_{k|k-1}^{(2)} = [151.3, 3.3, 102.1, 1.7]^T.$$

预测权重为 ( $i = 1, 2$ )

$$\tilde{w}_{k|k-1}^{(i)} = w_{k-1}^{(i)} \cdot e_{k|k-1}(x_{k-1}^{(i)}) = 0.5 \times 0.98 = 0.49.$$

接下来随机生成在观测区域内均匀分布的一组粒子, 以表示  $k$  时刻可能出现的新目标. 为简单说明, 这里只产生两个新粒子, 即

$$x_{\text{new},k}^{(1)} = [192, 4.3, 144, 0.7]^T,$$

$$x_{\text{new},k}^{(2)} = [96.8, 2.2, 288, -0.34]^T,$$

其权重均为 0.5. 故  $k$  时刻预测状态和权重分别为

$$\tilde{X}_{k|k-1} = \{\tilde{x}_{k|k-1}^{(1)}, \tilde{x}_{k|k-1}^{(2)}, x_{\text{new},k}^{(1)}, x_{\text{new},k}^{(2)}\},$$

$$\tilde{w}_{k|k-1} = \{0.49, 0.49, 0.5, 0.5\}.$$

对于预测的目标状态  $\tilde{X}_{k|k-1}$ , 由观测方程可以得到预测的观测值  $\tilde{Z}_{k|k-1}$ . 先产生一个 0-1 分布的随机数  $u_2$ , 若  $u_2 > 1 - P_D$ , 则表示目标被探测到, 代入观测模型可得到预测的量测值为

$$\tilde{Z}_{k|k-1} = \{(0.82, 313.6)^T, (0.65, 254.1)^T,$$

$$(0.66, 311.3)^T, (0.26, 398.3)^T\}^T.$$

假设  $k$  时刻目标的真实状态为

$$\begin{aligned}x_k^{(1)} &= [227.8, 2.8, 120.5, 1.9]^T, \\x_k^{(2)} &= [154.3, 3.1, 101.0, 0.69]^T.\end{aligned}$$

$k$  时刻, 传感器实际收集到的量测为  $Z_k = [z_1, z_2, z_3, z_4, z_5]$ , 其中  $z_1 = [0.797, 317.6]^T$ ,  $z_2 = [0.651, 254.1]^T$  为来自真实目标  $x_k^{(1)}$  和  $x_k^{(2)}$  的量测 (带有一定的测量误差); 而  $z_3 = [2.9, 331.3]^T$ ,  $z_4 = [0.3, 214.5]^T$ ,  $z_5 = [0.95, 180.2]^T$  为传感器的观测噪声. 经过 PHD 更新步骤后, 得到的权重为  $w_{k|k} = [0.9663, 0.9960, 0, 0]$ , 其中 0 表示权重非常小, 约等于 0, 则经滤波更新后, 得到目标数估计为

$$N = 0.9663 + 0.9960 + 0 + 0 = 1.9623 \approx 2.$$

因此, 根据目标数目估计值可将  $\tilde{X}_k$  聚成两类, 从而求得目标状态的估计值.

由 PHD 滤波后得到的权重  $w_{k|k}$  可以看出, 预测的状态  $\tilde{x}_{k|k-1}^{(1)}$ ,  $\tilde{x}_{k|k-1}^{(2)}$  的权重接近于 1, 说明在  $\tilde{x}_{k|k-1}^{(1)}$ ,  $\tilde{x}_{k|k-1}^{(2)}$  点处各有一个目标.

若碰巧噪声  $z_4 = [0.7, 308]^T$ , 与新生粒子  $x_{\text{new},k}^{(1)}$  的量测值相近, 此时 PHD 滤波结果为  $w_{k|k} = [0.966, 0.996, 0.544, 0]$ , 目标数目估计为

$$N = [0.966 + 0.996 + 0.544 + 0] = [2.5061] = 3.$$

此时, 出现虚假目标, 聚类时影响估计精度.

### 3.3 PHD 粒子滤波存在的缺陷

通过分析, 可得 PHD 滤波存在两方面缺陷:

1) 目标数目估计不稳定造成跟踪结果不精确. 实际计算中, 新生粒子是在观测区域内随机生成的, 有可能出现某个虚警  $z_k$  碰巧与其中一个或多个新生粒子的量测值相近, 此时会出现虚假目标, 聚类时影响估计精度. 这种情况虽带有一定的偶然性, 但为了尽快发现新目标, 在预测过程中通常产生很多新生粒子, 因此这种偶然性便会成为经常性, 给计算结果带来很大的误差.

2) 聚类算法误差较大. PHD 滤波更新后, 得到目标数目估计, 然后通过聚类提取目标状态. 在状态提取之前, 先进行重采样, 这样可将权重很小的杂波剔除, 便于粒子的聚类分析. 但在重采样后, 有些不属于目标的杂波仍可能被剔除, 造成不属于目标的粒子也被聚到目标类, 使得结果精度不高. 这种情况在高杂波环境下显得更加严重.

## 4 改进的 PHD 粒子滤波方法

### 4.1 算法描述

针对上述缺陷, 本文提出一种改进的 PHD 滤波算法, 即引入轨迹标签的方法. 将目标状态表示为  $(x, y, \dot{x}, \dot{y}, L)^T$ ,  $L$  为标签, 此时, 目标的运动模型为

$$X_k = \begin{bmatrix} 1 & 0 & T & 0 & 0 \\ 0 & 1 & 0 & T & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} X_{k-1} + \begin{bmatrix} T^2/2 & 0 \\ 0 & T^2/2 \\ T & 0 \\ 0 & T \\ 0 & 0 \end{bmatrix} \begin{bmatrix} v_{1,k} \\ v_{2,k} \end{bmatrix}. \quad (9)$$

该方法的基本原理是基于 PHD 滤波较好地剔除杂波性能<sup>[3-4]</sup>, 即对于某个粒子, 若传感器接收到的量测集合中, 没有与该粒子的观测值相近的量测, 则经过 PHD 滤波更新后, 该粒子的权值将非常小, 因此, 很容易在重采样过程中将该粒子剔除掉. 文献[4]通过仿真实验验证了 PHD 滤波剔除杂波的性能. 在本文 3.2 节的 PHD 滤波过程分析中也可以看出, 经更新后, 粒子  $x_{\text{new},k}^{(1)}$  和  $x_{\text{new},k}^{(2)}$  的权值非常小, 即相对于预测的权值减小了很多, 因为在量测集合  $Z_k$  中没有与它们相近的量测.

该方法正是利用 PHD 滤波这一性能, 对每个粒子更新后的权值进行判断, 判断条件为

$$\beta = \frac{w_{k|k}^{(i)}}{w_{k|k-1}^{(i)}} = \left[ 1 - P_D + \sum_{z \in Z_k} \frac{\psi_{k,z}(\tilde{x}_k^{(i)})}{\kappa_k(z) + C_k(z)} \right] > r. \quad (10)$$

式中:  $w_{k|k-1}^{(i)}$  表示粒子  $i$  预测的权重,  $w_{k|k}^{(i)}$  表示粒子  $i$  更新后的权重.

基本思路是: 将每个新生粒子附于不同的标签, 在进行完 PHD 滤波更新后, 通过判断条件(10)对粒子进行分类, 直到确认为代表目标的粒子后, 才进行目标状态输出. 具体步骤如下:

1)  $k = 1$  时刻, 在 PHD 滤波更新后, 将  $\beta > r$  的粒子的标签存入一个集合, 称为可能轨迹标签集合  $\text{MayLableSet}$ , 表示集合里的标签所代表的粒子可能是真实目标的估计. 这要在下一时刻进一步确认, 若是杂波的标签, 则在下一时刻将被剔除.

2)  $k > 1$  时刻, 在进行完 PHD 滤波更新后, 需要对  $k-1$  时刻的可能标签进一步确认, 即对每一个  $\text{MayLable}_i \in \text{MayLableSet}_{k-1}$ , 将所有标签为  $\text{MayLable}_i$  的粒子的权值相加, 若其值大于阈值  $w_{\text{true}}$  (可取为 0.5), 则认为该标签是真实轨迹标签, 放入真实轨迹标签集合  $\text{TrueLableSet}_k$ .

3) 对每个标签  $\text{TrueLable}_i \in \text{TrueLableSet}_{k-1}$ , 若该标签所代表粒子的权值之和仍大于  $w_{\text{true}}$ , 说明该轨迹在  $k$  时刻仍然存在, 将标签  $\text{TrueLable}_i$  放入  $\text{TrueLableSet}_k$ .

4) 对每个  $\text{TrueLable}_j \in \text{TrueLableSet}_k$ , 将该标签的所有粒子作为目标  $j$  的一组估计, 从而可直接求得目标  $j$  的状态, 而不必采用聚类算法.

5) 在第4)步进行完后,对剩下的粒子再次检查,将 $\beta > r$ 的粒子的标签放入可能轨迹标签集合MayLableSet<sub>k</sub>,待k+1时刻确认.

6) 对于同一个标签,若其在可能轨迹标签集合里出现的次数多于一定值(例如5次),而一直未能达到加入真实轨迹标签集合的条件,则将此标签所代表的粒子全部删除.

7) 重复步骤2)~6),直到跟踪结束.

这里,步骤6)的做法是因为,在可能轨迹标签集合出现多次而未能加入真实轨迹标签集合的标签,说明它不是来源于杂波,而是来源于已被发现的目标.对这类标签的处理方法有两种:一是将其关联到真实轨迹标签,然后将该标签替换成已存在的真实轨迹标签,这种做法计算量较大;另一种是将其删除,这可能导致估计精度下降.

### 4.2 仿真结果比较

仿真环境如3.1节所述.取阈值 $r = 0.1$ ,每个目标使用粒子数为1000.在传感器检测率分别为 $P_D = 0.99$ 和 $P_D = 0.80$ 两种情况下,将改进算法与传统PHD算法的仿真结果进行对比.图1,图2分别为传感器检测率 $P_D = 0.99$ ,杂波密度 $\lambda_c = 10$ 时,传统PHD滤波算法和改进算法的x方向估计值.




图1 传统PHD算法的x方向估计值( $P_D = 0.99$ )




图2 改进算法的x方向估计值( $P_D = 0.99$ )

由图1可以看出,传统算法在杂波较多的情况下,出现许多虚假目标,从而导致目标状态估计值偏差较大.由图2可以看出,改进算法由于剔除杂波的影响,很少出现虚假目标,跟踪精度较高.

图3,图4分别为检测率 $P_D = 0.80$ ,杂波密度 $\lambda_c = 10$ 时,传统算法和改进算法的x方向估计值.




图3 传统PHD算法的x方向估计值( $P_D = 0.80$ )




图4 改进算法的x方向估计值( $P_D = 0.80$ )

由图3,图4可以看出,当传感器漏检时,改进算法需要比传统PHD算法多花费至少一个观测时刻才能重新跟上目标.由图2和图4可以看出,改进算法在目标刚出现的时刻,无法立即发现目标.

用Wasserstein距离表示多目标的估计误差<sup>[10]</sup>.图5给出了传感器检测率 $P_D = 0.80$ , $\lambda_c = 10$ 时,100次蒙特卡洛仿真结果.




图5 改进算法与传统算法平均误差距离比较

由图5可以看出,在第1个目标出现的时刻 $k = 13$ ,改进算法没有目标状态估计值,因此,在 $k = 13$ 时刻改进算法的目标估计集为空集,误差为零;在后续新目标出现的时刻,改进算法的误差距离大于传统PHD算法,这是由于在目标刚出现的时刻,改进算法未能即时跟上目标,因此,在这些时刻目标估计数目小于实际目标数目,导致误差距离较大.

为了更全面地比较两种算法的性能,各进行100次蒙特卡洛仿真.表1所示为杂波密度 $\lambda_c = 10$ ,不同检测率下的Wasserstein距离平均值比较;表2为检测率 $P_D = 0.99$ ,不同杂波密度下的Wasserstein距离平均值比较.

表 1 不同检测率下,改进算法与传统算法平均误差比较

$P_D$	改进 PHD 滤波	传统 PHD 滤波
0.99	18.235 6	38.325 8
0.90	27.126 6	42.286 5
0.80	36.077 6	46.127 3
0.70	53.740 3	51.661 1

表 2 不同杂波密度下,改进算法与传统算法平均误差比较

$\lambda_c$	改进 PHD 滤波	传统 PHD 滤波
20	20.863 9	42.342 9
30	23.525 2	46.269 9
40	26.836 9	55.587 4
50	31.943 0	76.523 1

由表 1 可以看出,当检测率较高时,改进算法的跟踪精度高于传统算法;当传感器的检测率低于一定值时,在本文的仿真条件下,当检测率  $P_D = 0.70$  时,改进算法的误差大于传统算法。

由表 2 的仿真数据可以看出,传统 PHD 算法受杂波的影响较大,这是由于传统算法在高杂波环境下,会出现较多的虚假目标;而改进算法在杂波密度较高的环境下,仍具有较高的跟踪精度。

## 5 结 论

通过实例分析了 PHD 粒子滤波存在的缺陷. 基于 PHD 滤波较好地剔除杂波性能,通过在目标状态中加入标签的方法改进了 PHD 滤波. 仿真结果表明:

- 1) 检测率较高时,改进算法在高杂波环境下,能得到比传统 PHD 滤波更高的跟踪精度;
- 2) 得到目标状态估计后,可通过标签知道所估计的状态来自哪条航迹,实现了目标状态到航迹的关联;
- 3) 在提取目标状态时,只对相同标签的粒子进行处理,避免了使用聚类方法。

改进算法在实现上述功能的同时,也造成了新目标不容易被即时发现的问题,这在一定程度上限制了算法的应用范围. 另外,算法中阈值采用的是经验值,如何选择合适的阈值需要进一步研究。

## 参考文献(References)

- [1] Mahler R. Statistical multisource multitarget information fusion[M]. Norwood, MA: Artech House, 2007.
- [2] Mahler R. Multitarget Bayes filtering via first-order multitarget moment[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.
- [3] Lin L, Bar-Shalom Y, Kirubarajan T. Track labeling and PHD filter for multitarget tracking[J]. IEEE Trans on Aerospace and Electronic Systems, 2006, 42(3): 778-795.
- [4] Panta K, Vo B-N, Singh S, et al. Probability hypothesis density filter versus multiple hypothesis tracking[C]. Proc of SPIE, Signal Processing, Sensor Fusion and Target Recognition XIII. Bellingham, 2004, 5429: 284-295.
- [5] Panta K, Vo B, Singh S. Improved probability hypothesis (PHD) filter for multitarget tracking[C]. Proc of the Int Conf on Intelligent Sensing and Information Processing. Bangalore, 2005: 213-218
- [6] Ma W-K, Vo B-N, Singh S, et al. Tracking an unknown time-varying number of speakers using TDOA measurements: A random finite set approach[J]. IEEE Trans on Signal Processing, 2006, 9: 3291-3304.
- [7] Vo B-T, Vo B-N, Cantoni A. Bayesian filtering with random finite set observations[J]. IEEE Trans on Signal Processing, 2008, 56(4): 1313-1326.
- [8] Vo B-N, Singh S, Ma W-K. Tracking multiple speakers with random sets[C]. Proc of IEEE Int Conf on Acoust, Speech, Signal Process. Montreal, 2004, 2: 357-360.
- [9] Vo B-N, Singh S, Doucet A. Sequential Monte Carlo methods for multi-target filtering with random finite sets[J]. IEEE Trans on Aerospace and Electronic Systems, 2005, 41(4): 1124-1245.
- [10] 田淑荣, 王国宏, 何友. 多目标跟踪的概率假设密度粒子滤波[J]. 海军航空工程学院学报, 2007, 22(4): 417-430. (Tian S R, Wang G H, He Y. Multi-target tracking with probability hypothesis density particle filter[J]. J of Naval Aeronautical Engineering Institute, 2007, 22(4): 417-430.)
- [9] 胡劲松, 王虹. 三级供应链应对突发事件的价格折扣契约研究[J]. 中国管理科学, 2007, 15(3): 103-107. (Hu J S, Wang H. The price discount contract analysis of three-level supply chain under disruption[J]. Chinese J of Management Science, 2007, 15(3): 103-107.)
- [10] Chandra C, Grabis J. Inventory management with variable lead-time dependent procurement cost[J]. Omega-International J of Management Science, 2008, 36(5): 877-887.
- [11] Petruzzi N C, Maqbool Dada. Pricing and the newsvendor problem: A review with extensions[J]. Operations Research, 1999, 47(2): 183-194.

(上接第1366页)