

基于随机集的 RBPF 多目标关联跟踪算法

赵 欣^{1,2}, 姬红兵¹, 杨柏胜¹

(1. 西安电子科技大学电子工程学院, 陕西西安 710071; 2. 中国航天科技集团公司第四研究院 401 所, 陕西西安 710071)

摘 要: 针对大量杂波环境下数量变化的纯角度多目标航迹关联跟踪问题, 提出一种新的基于 Rao-Blackwellized 粒子采样 (RBPF) 航迹关联的高斯混合概率假设密度 (GMPHD) 滤波算法. 算法首先利用 GMPHD 在每时刻对多个目标组成的随机集合进行估计; 然后利用基于随机有限集的 RBPF 对 GMPHD 所得到的目标集合进行检测和关联, 有效解决 GMPHD 算法中无法进行多目标航迹识别的弊端; 最后通过对所有粒子的融合完成航迹区分和估计. 实验结果表明, 提出方法比起目前经典的随机集 Label-PHD 关联跟踪算法, 可以更有效的对数量未知的多目标航迹进行区分和关联估计, 同时算法的跟踪性能及稳定性要好于 Label-PHD 算法.

关键词: Rao-Blackwellized 粒子滤波; 多目标跟踪; 概率假设密度滤波; 航迹关联

中图分类号: TP302.7 **文献标识码:** A **文章编号:** 0372-2112 (2011) 04-0505-06

Rao-Blackwellized Particle Filter Based on Random Finite Sets Theory for Multi-Target Association and Tracking

ZHAO Xin^{1,2}, JI Hong-bing¹, YANG Bai-sheng¹

(1. Xidian University, Xi'an, Shaanxi 710071, China; 2. CASC 401 Academy, Xi'an, Shaanxi 710071, China)

Abstract: Due to the difficulty in association and estimation of multi-target tracks in the presence of data association uncertainty, clutter, noise and miss-detection. In this paper, a novel data association probability hypothesis density (PHD) filter for multi-target tracking based on Rao-Blackwellized particle filter (RBPF) algorithm is proposed. Firstly, the Gaussian mixture probability hypothesis density (GMPHD) filter has been proposed to estimate the set of all targets at every time step. Secondly, the data-association functionalities of RBPF can be incorporated with the PHD filter to produce the track-valued estimates of individual targets. Simulation results show that the proposed algorithm is more robust and accurate than Label-PHD algorithm which is very prevalent in the PHD tracking domains, also the proposed algorithm can estimate and distinguish each target more effective.

Key words: Rao-Blackwellized particle filter; multi-target tracking; probability hypothesis density filter (PHD); track-to-track association

1 引言

多目标环境下, 由于目标出现、消失及新目标衍生, 每时刻目标数目会发生改变. 此外, 观测信息的不确定性, 如漏检、虚警等都给目标跟踪制造了较大困难. 跟踪多个目标, 特别是实时、有效地跟踪数目变化的多个目标, 一直是学术界和工程应用的研究热点和难点. 到目前为止, 大量的学者已对该问题做了深入研究并取得了一些研究成果, 其中包括传统的最近邻标准滤波法 (NNSF)、联合概率数据关联滤波法 (JPDAF)、多假设跟踪法 (MHT)^[1]等, 其中 NNSF 和 JPDAF 不能跟踪数量变化的多个目标; MHT 在目标数目较多, 目标之间距离较

近或观测环境较为复杂的情况下时, 很难准确估计出目标的个数, 降低了目标跟踪精度.

近几年, 越来越多专家开始尝试利用随机有限集^[2,3] (RFS, Random Finite Set) 理论来解决多目标跟踪问题. 其中最具有代表性的是 Mahler 提出的概率假设密度滤波 (PHD, probability hypothesis density)^[2], 该滤波算法将复杂的多目标状态空间的运算转换为单目标状态空间内的运算, 避免了多目标跟踪中复杂的数据关联问题, 在保证精度的同时, 提高了算法实时性, 具有很高的理论和实用价值. 目前 PHD 实现方法主要包括粒子滤波 PHD^[4] 和高斯混合 PHD (GMPHD, Gaussian mixture PHD)^[5]. 这两种方法均是在 RFS 的理论框架下, 对整个

目标集合的处理,避免了复杂的目标航迹关联,但给一些后处理,如目标行为识别,目标身份识别以及最后的姿态估计等带来了较大困难.针对此,专家提出粒子滤波 PHD 结合 MHT 的方法和 PHD 结合多维分配算法的方法^[6].通过对粒子的分析和模糊聚类来保持目标航迹的连续性,由于聚类算法在粒子滤波 PHD 中的不可靠性,直接影响了这类方法的跟踪识别性能.基于 GM-PHD 的目标航迹识别比较流行的有 Clark 提出 Label-PHD^[7]方法,该方法的优点是简单,计算量小,缺点是每次航迹保持和识别时没有用到当前的观测信息,当杂波干扰较多或目标出现交叉时,经常会形成大量的虚假航迹,无法有效的保证航迹的连续性.

针对上述问题,文章提出基于随机集的 RBPF 多目标关联跟踪算法.算法首先通过 PHD 滤波对多个目标进行预跟踪处理,再设计相应的随机集 RBPF,对 PHD 滤波结果进行航迹识别和关联.仿真结果表明,提出的算法较之经典的 Label-PHD 算法,能够更好的识别和保持目标航迹,即使在目标出现交叉的时刻也能达到很好的跟踪识别精度,体现出较高的精确度和较强的鲁棒性.

2 基于随机集目标跟踪模型

在多目标运动系统中,目标状态集和观测集可分别用随机有限集 $X_k = \{x_{k,1}, \dots, x_{k,N_k}\} \in F(\chi)$ 和 $Y_k = \{y_{k,1}, \dots, y_{k,M_k}\} \in F(\Psi)$ 表示,其中 $F(\chi)$ 和 $F(\Psi)$ 分别是状态空间 χ 和观测空间 Ψ 上全部有限子集的集合, N_k 和 M_k 分别表示 k 时刻目标数目和观测数目.针对直接对 X_k 和 Y_k 的联合概率密度进行处理的复杂度高、计算量大的问题, Mahler 提出了将分类和跟踪融为一体的严格 PHD 数学模型^[2].

该模型中,对于在状态空间 χ 上的一个概率分布函数为 $P(X)$ 的目标随机集 X ,定义其 PHD 为 $D(x)$,它满足:

$$\int |X \cap S| P(dX) = \int_S D(x) dx \quad (1)$$

上式表明 $D(x)$ 在目标区域 S 上的积分等于集合 X 中在该区域内的元素个数均值.如果集合 X 中总的元素个数为 $\hat{N} = \text{round} \left(\int D(x) dx \right)$,则 $D(x)$ 的局部最大值点对应于 X 中 \hat{N} 个元素的值.通过文献^[2]给出的随机集 PHD 迭代公式,即可进行多目标数目及状态估计.

3 基于随机集的 RBPF 的关联方法

PHD 滤波算法仅能估计出每时刻所有目标组成的集合,不能识别其中单个目标,即不能够估计出单个目标的完整航迹.针对此,文章提出了一种基于有限集合

的 RBPF 航迹识别关联算法,将 PHD 滤波结果 \hat{X}_k 作为 RBPF 的伪观测输入,令 $\hat{X}_k = \hat{Y}_k$,再利用 RBPF 进行航迹检测关联和估计.算法框架见图 1.




图1 基于RBPF-PHD的多目标航迹估计算法框图

文章对 RBPF 算法的一般应用进行了拓展,将检测关联和滤波划分为两个不同的处理部分,由于检测和关联的方程并不确定的,可划分为非线性处理部分,用粒子滤波进行估计;目标的状态矢量可划分为线性的或近似线性部分,利用统计滤波方法,如卡尔曼滤波(KF)、扩展卡尔曼滤波(EKF)等进行估计^[9].

3.1 RBPF 中每个粒子表示

文献^[8]采用了无限集理论进行 RBPF 滤波,算法虽可以较好的估计出变化的目标数目,但仍然无法识别和保持每个目标的完整航迹.文章在此基础上,提出了基于有限随机集的 RBPF 关联滤波算法,即认为每时刻目标数目是个有限的随机变量.这样,每时刻采样粒子 $Pa_k^{(i)} (i = 1 \sim N_p)$ 为

$$\begin{aligned} & \{c_k^{(i)}, e_k^{(i)}, M_k^{(i)}, P_k^{(i)}\} \\ & = \{c_k^{(i)}, e_k^{(i)}, M_{S,k}^{(i)}, M_{B,k}^{(i)}, P_{S,k}^{(i)}, P_{B,k}^{(i)}\} \\ & = \{c_k^{(i)}, e_k^{(i)}, m_{k,1}^{(i)} \sim m_{k,N_{S,k}}^{(i)}, m_{k,N_{S,k}+1}^{(i)} \sim m_{k,N_{S,k}+N_{B,k}}^{(i)}, P_{k,1}^{(i)} \\ & \quad \sim P_{k,N_{S,k}}^{(i)}, P_{k,N_{S,k}+1}^{(i)} \sim P_{k,N_{S,k}+N_{B,k}}^{(i)}\} \end{aligned} \quad (2)$$

其中 N_p 为采样粒子数, $m_{k,1}^{(i)} \sim m_{k,N_{S,k}}^{(i)}$, $P_{k,1}^{(i)} \sim P_{k,N_{S,k}}^{(i)}$ 分别表示 $k-1$ 到 k 时刻依然存活的目标集合 $\{M_{S,k}^{(i)}, P_{S,k}^{(i)}\}$ 中每个目标的状态均值和状态协方差矩阵, $N_{S,k}$ 为存活目标数. $m_{k,N_{S,k}+1}^{(i)} \sim m_{k,N_{S,k}+N_{B,k}}^{(i)}$, $P_{k,N_{S,k}+1}^{(i)} \sim P_{k,N_{S,k}+N_{B,k}}^{(i)}$ 分别为 k 时刻新生目标集合 $\{M_{B,k}^{(i)}, P_{B,k}^{(i)}\}$ 中对应每个目标的状态均值和状态协方差矩阵, $N_{B,k}$ 为新生目标数.在不考虑航迹分裂的情况下目标数目为

$$N_k = N_{S,k} + N_{B,k} \quad (3)$$

粒子中的 $e_k^{(i)}$ 表示 k 时刻所有目标的可见程度,即

$$e_k^{(i)} = (e_{k,1}^{(i)} \sim e_{k,N_k}^{(i)}) \quad (4)$$

其中每个元素 $e_{k,n}^{(i)} (n = 1 \sim N_k)$ 是个 0-1 取值的数,值为 1 表示目标可见,为 0 表示不可见.

$c_k^{(i)}$ 表示 k 时刻所有目标的关联指示数,即

$$c_k^{(i)} = (c_{k,1}^{(i)} \sim c_{k,\hat{M}_k}^{(i)}) \quad (5)$$

其中每个元素 $c_{k,m}^{(i)} (\hat{m} = 1 \sim \hat{M}_k)$ 表示 k 时刻观测随机集合中元素 \hat{m} 来自哪条目标航迹, \hat{M}_k 表示该观测随机集合中的元素个数.一般用 $w_k^{(i)}$ 表示每个粒子 i 所对应的权值.

3.2 非线性模型建立

非线性模型是指可见度指示数和关联指示数的采

样模型,通过一个联合马尔可夫链可将两个变量的联合概率密度函数表示为

$$p(\mathbf{e}_k, \mathbf{c}_k | \mathbf{e}_{k-1}^{(i)}) = p(\mathbf{c}_k | \mathbf{e}_k) p(\mathbf{e}_k | \mathbf{e}_{k-1}^{(i)}) \quad (6)$$

通过对 \mathbf{e}_k 和 \mathbf{c}_k 分别进行粒子采样得到 $\mathbf{e}_{k,n-1}^{(i)}$ 和 $\mathbf{c}_k^{(i)}$ ($i = 1 \sim N_p$). 为方便实际应用,作者采用序贯处理方式将通过 PHD 所得目标集合中的元素作为新的观测逐个送入 RBPF,进行目标检测、关联和滤波. 对于每一个序贯子步,式(6)可表示为

$$\begin{cases} p(\mathbf{e}_{k,\hat{m}}, \mathbf{c}_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}-1}^{(i)}) = p(\mathbf{c}_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}}) p(\mathbf{e}_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}-1}^{(i)}), & 1 < \hat{m} \leq \hat{M}_k \\ p(\mathbf{e}_{k,1}, \mathbf{c}_{k,1} | \mathbf{e}_{k-1, \hat{M}_{k-1}}^{(i)}) = p(\mathbf{c}_{k,1} | \mathbf{e}_{k,1}) p(\mathbf{e}_{k,1} | \mathbf{e}_{k-1, \hat{M}_{k-1}}^{(i)}), & \hat{m} = 1 \end{cases} \quad (7)$$

其中, $\mathbf{e}_{k,\hat{m}-1}^{(i)} = (\mathbf{e}_{k,1}^{(i)} \sim \mathbf{e}_{k,N_{k,\hat{m}-1}}^{(i)})$ 表示 k 时刻第 $\hat{m}-1$ 子步中 $\mathbf{e}_{k,\hat{m}-1}^{(i)}$ 的第 i 个采样值.

3.2.1 关于目标可见程度 e_k 的采样模型

任意 k 时刻得到的每个观测,可能来自杂波、上时刻已存目标或是某一区域的新目标. 在序贯处理中,对第 \hat{m} 个序贯子步, $\mathbf{e}_{k,\hat{m}}$ 的维数与目标数都是变量. 由此可建立每个子步的 $\mathbf{e}_{k,\hat{m}}$ 采样模型(包括新生模型和消失模型).

(1)如果新目标的可见程度,即新目标的出现概率为 P_B ,同时将一组新目标送入目标集合.

(2)如果某一目标从最近一次被观测到该目标消失的时间间隔服从 gamma 分布^[8],即

$$t_d \sim \text{Gamma}(t_d | \alpha, \beta) \quad (8)$$

其中 α 和 β 是 gamma 分布函数的参数.

如果已存目标的检测概率均为 P_D ,通常认为目标的消失数量不会超过观测数量,这样每个子步最多只有一个旧目标消失,一个新目标出现. 由此可列出 $\mathbf{e}_{k,\hat{m}}$ 所有可能的组合及对应的概率密度

$$\begin{cases} p(\mathbf{e}_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}-1}^{(i)}) = \prod_{n=1}^{N_{k,\hat{m}-1}} p(\mathbf{e}_{k,n} | \mathbf{e}_{k,n}^{(i)}) \prod_{n'=N_{k,\hat{m}-1}+1}^{N_{k,\hat{m}-1}+N_{B,k}} p(\mathbf{e}_{k,n'}), & \hat{m} > 1 \\ p(\mathbf{e}_{k,1}) = \prod_{n=1}^{N_{k-1}} p(\mathbf{e}_{k,n} | \mathbf{e}_{k-1, N_{k-1}}^{(i)}) \prod_{n'=N_{k-1}+1}^{N_{B,k}+N_{k-1}} p(\mathbf{e}_{k,n'}), & \hat{m} = 1 \end{cases} \quad (9)$$

其中 $N_{k,\hat{m}-1}$ 表示第 $\hat{m}-1$ 个序贯子步所估计的目标个数,且有 $N_k = N_{k,\hat{M}_k}$.

3.2.2 关于关联指示系数 c_k 的采样

假设关联指示系数的概率密度是一阶马尔可夫链,即 $p(c_k, \hat{M}_k | c_{k-1} \sim c_k, \hat{M}_{k-1})$. 关联指示系数的先验联合概率为 $p(\mathbf{c}_k) = p(c_{k,1} \sim c_k, \hat{M}_k)$, 由于很难直接对其进行采样,可将其表示为

$$p(c_{k,1} \sim c_k, \hat{M}_k) = \prod_{\hat{m}=2}^{\hat{M}_k} p(c_{k,\hat{m}} | c_{k,1} \sim c_k, \hat{m}-1) \quad (10)$$

在任意 k 时刻,利用序贯处理的思想,每个序贯子步只用一个观测进行目标关联和状态更新、只对一个关联指示系数 $c_{k,\hat{m}}$ 采样. 根据贝叶斯迭代原理, $c_{k,\hat{m}}$ 的后验重要性密度可表示为

$$\begin{cases} p(c_{k,1} | \hat{\mathbf{x}}_{k,1}, \mathbf{e}_{k,1}^{(i)}) \propto p(\hat{\mathbf{x}}_{k,1} | \mathbf{e}_{k,1}^{(i)}, c_{k,1}) p(c_{k,1} | \mathbf{e}_{k,1}^{(i)}), & \hat{m} = 1 \\ p(c_{k,\hat{m}} | \hat{\mathbf{x}}_{k,\hat{m}}, c_{k,1:\hat{m}-1}, \mathbf{e}_{k,\hat{m}}^{(i)}) \propto p(\hat{\mathbf{x}}_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}}^{(i)}, c_{k,1:\hat{m}-1}, c_{k,\hat{m}}) \cdot p(c_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}}^{(i)}, c_{k,1:\hat{m}-1}), & 1 < \hat{m} \leq \hat{M}_k \end{cases} \quad (11)$$

其中

$$\begin{cases} p(c_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}}^{(i)}, c_{k,1:\hat{m}-1}) = \frac{1}{1 + \text{NUM}_{k,\hat{m}}}, & \mathbf{e}_{k,\hat{m}}^{(i)} = 1 \text{ and } c_{k,\hat{m}} \neq c_{k,1:\hat{m}-1}^{(i)} \\ p(c_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}}^{(i)}, c_{k,1:\hat{m}-1}) = 0, & \text{other} \end{cases} \quad (12)$$

$$\begin{cases} p(\hat{\mathbf{x}}_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}}^{(i)}, c_{k,1:\hat{m}-1}, c_{k,\hat{m}}) = \frac{1}{V_f}, & c_{k,\hat{m}} = 0 \\ p(\hat{\mathbf{x}}_{k,\hat{m}} | \mathbf{e}_{k,\hat{m}}^{(i)}, c_{k,1:\hat{m}-1}, c_{k,\hat{m}}) = \text{KF}_{\hat{h}}(\hat{\mathbf{x}}_{k,\hat{m}}, \text{Pa}_{k|k-1,\hat{m}}^{(i)}, c_{k,\hat{m}}, \mathbf{H}_k, \mathbf{R}_k), & c_{k,\hat{m}} \neq 0 \end{cases} \quad (13)$$

式中 $\text{NUM}_{k,\hat{m}} = |\mathbf{e}_{k,\hat{m}}^{(i)} > 0|$, 表示当前存活的所有目标, V_f 表示杂波存在的区域, $\text{KF}_{\hat{h}}(\cdot)$ 表示 KF 的观测似然估计, \mathbf{H}_k 和 \mathbf{R}_k 表示 KF 的观测矩阵和协方差矩阵,可以通过之前的 PHD 滤波得到^[6].

3.3 线性模型建立

线性模型是针对于粒子中目标状态预测和更新,状态预测可分为已存目标状态预测和新生目标预测,其中已存目标部分可通过统计滤波的状态方程一步预测得到;当之前的 PHD 滤波集合不为空时,在上一步得到的粒子中直接加入新生目标集合,便完成对新目标的预测,即

$$\begin{cases} \text{Pa}_{k|k-1,1}^{(i)} \leftarrow \text{Pa}_{k|k-1,0}^{(i)} \cup \{M_{B,k}^{(i)}, P_{B,k}^{(i)}\}, & \hat{m} = 1 \\ \text{Pa}_{k|k-1,\hat{m}}^{(i)} \leftarrow \text{Pa}_{k|\hat{m}-1}^{(i)} \cup \{M_{B,k}^{(i)}, P_{B,k}^{(i)}\}, & 1 < \hat{m} \leq \hat{M}_k \end{cases} \quad (14)$$

其中 $\text{Pa}_{k|k-1,0}^{(i)}$ 表示在序贯子步开始前时,对上一时刻粒子一步预测, $\text{Pa}_{k|k-1,\hat{m}}^{(i)}$ 表示在第 \hat{m} 个序贯子步中对上一子步估计粒子的预测. 目标状态的更新是在目标可见度和关联指示系数采样的基础上,结合观测随机集中的元素 $\hat{\mathbf{y}}_{k,\hat{m}}$,传统滤波对每个粒子中与 $\hat{\mathbf{y}}_{k,\hat{m}}$ 相关联的目标状态进行更新^[9].

3.4 所有粒子的结果的融合估计

当所有的观测都对目标状态进行更新后,对目标的可信程度 $\mathbf{e}_{k,\hat{M}_k}^{(i)}$ 进行加权求和的融合,即

$$\mathbf{E}S_k = (es_{k,1}, \dots, es_{k,N_k})^T = \text{round}\left(\sum_{i=1}^{N_k} w_k^{(i)} \cdot \mathbf{e}_{k,M_k}^{(i)}\right) \quad (15)$$

其中 $\mathbf{E}S_k$ 表示可见度向量, 元素 $es_{k,n}$ 表示了目标航迹 n 的可见程度, 是个 0-1 取值的数, $n = 1 \sim N_k$. 此时, 可具体设定一个目标出现阈值 ψ_b 和消失阈值 ξ_d (一般均选择相等的两个值), 当 $es_{k,ns} > \xi_d, ns = 1 \sim N_{S,k}$ 时, 认为相应目标消失, 将对应的目标从所有粒子中删除并结束该目标航迹, 同时令 $N_{S,k} = N_{S,k} - 1$. 当 $es_{k,nb} > \psi_b, nb = N_{S,k} \sim (N_{S,k} + N_{B,k})$ 时, 认为新目标出现, 在所有粒子中确认该新生目标, 此时令 $e_{k,nb}^{(i)} = 1$. 最后的权值计算比较容易, 具体公式可参见文献[8].

对目标可见度融合之后, 便可进行目标状态的融合, 此时一般有两种融合选择. 第一种是选出权值最大的粒子作为最终的状态估计结果, 另一种是按照权值对所有粒子的中的目标状态进行加权求和, 这样便完成了当前时刻每条目标航迹的估计.




图3 目标在x方向的真实运动轨迹




图4 目标在y方向的真实运动轨迹




图5 目标在z方向的真实运动轨迹

设目标的状态矢量为 $\mathbf{x}_k = (l_{x,k}, \dot{l}_{x,k}, l_{y,k}, \dot{l}_{y,k}, l_{z,k}, \dot{l}_{z,k})^T$, 采用文献[1]中介绍的直线运动模型, 其中设 $\sigma_w = 10\text{ms}^{-2}$ 为噪声的标准差. 假设目标的新生随机集合服从 Poisson 分布, 其 PHD 为

$$\gamma_k(\mathbf{x}) = 0.1(N(\mathbf{x}; \mathbf{m}_\gamma^{(1)}, \mathbf{P}_\gamma) + N(\mathbf{x}; \mathbf{m}_\gamma^{(2)}, \mathbf{P}_\gamma)) \quad (16)$$

其中 $\mathbf{m}_\gamma^{(1)} = (-400, 0, 100, 0, 100, 0)^T \text{m}$,

$$\mathbf{m}_\gamma^{(2)} = (900, 0, 800, 0, 100, 0)^T \text{m},$$

$$\mathbf{P}_\gamma = \text{diag}((100, 200, 100, 200, 100, 200)) \text{m}^2.$$

设目标的状态矢量为 $\mathbf{x}_k = (l_{x,k}, \dot{l}_{x,k}, l_{y,k}, \dot{l}_{y,k}, l_{z,k}, \dot{l}_{z,k})^T$, 采用文献[1]中介绍的直线运动模型, 其中设 $\sigma_w = 10\text{ms}^{-2}$ 为噪声的标准差. 假设目标的新生随机集合服从 Poisson 分布, 其 PHD 为

$$\gamma_k(\mathbf{x}) = 0.1(N(\mathbf{x}; \mathbf{m}_\gamma^{(1)}, \mathbf{P}_\gamma) + N(\mathbf{x}; \mathbf{m}_\gamma^{(2)}, \mathbf{P}_\gamma)) \quad (17)$$

其中 $\mathbf{m}_\gamma^{(1)} = (-400, 0, 100, 0, 100, 0)^T \text{m}$,

$$\mathbf{m}_\gamma^{(2)} = (900, 0, 800, 0, 100, 0)^T \text{m},$$

$$\mathbf{P}_\gamma = \text{diag}((100, 200, 100, 200, 100, 200)) \text{m}^2.$$

仿真采用三个相同的纯角度被动传感器进行观

4 仿真与分析

4.1 仿真背景

该小节通过对三维空间中一定区域内的若干目标的航迹估计, 比较文章提出的算法与经典的 Label-PHD 算法. 假设空间中有若干个目标相继出现, 如图 2 所示, 图中“*”表示目标的起始点, 图 3~图 5 分别给出了目标在不同方向上的运动情况.




图2 目标真实运动轨迹

测, 通过观测交叉定位得到关于目标的位置量测^[10]. 三个传感器的位置分别为 $S_1(-200, 200, -100) \text{m}$, $S_2(0, 300, 250) \text{m}$, $S_3(500, 800, 1000) \text{m}$. 设三个传感器的测角误差均为 $\sigma_{S_i} = (\sigma_{S_i, \theta}, \sigma_{S_i, \beta}) = (6, 6) \text{mrad}$. 同时令传感器的检测概率均为 $P_d = 0.98$, 设杂波的 PHD 为 $\kappa_k(\mathbf{y}) = \lambda_c V_f U(\mathbf{y})$, 其中参数 $\lambda_c = 1.59 \text{rad}^{-2}$, $U(\cdot)$ 表示杂波区域 V_f 上的均匀分布函数, $V_f = [-\pi/2, \pi/2] \text{rad} \times [-\pi/2, \pi/2] \text{rad}$. 设目标消失模型的参数 α, β 分别为 1 和 0.15, ξ_d 和 ψ_b 均等于 0.5, 目标转移概率 $P_{S_i, k|k-1} = 0.98$, RBPF 中采样粒子数为 120.

4.2 仿真结果与分析

图 6、7 分别给出了两种算法在相同的观测条件下, 对于空间中相继出现的多个目标的跟踪情况. 从图中可明显看到, 在该实验情况下, 经典的 Label-PHD 算法会将大量的虚假高斯项标记为目标航迹, 产生了大量多余航迹, 当目标个数增多或目标之间距离较为接近时, 如图中的第 30~50 个采样时间内, Label-PHD 算法难以完整标记和保持某个目标航迹. 而本文提出的基于随机集有限 RBPF 的 PHD 关联跟踪可以较完整准确的区分和保持各个目标的航迹.




图6 Label-PHD在三个方向的目标估计运动轨迹




图7 RBPF-PHD在三个方向的目标估计运动轨迹

图 8 给出了两种算法在相同的观测条件下,对图 2 所示的空间中相继出现的多个目标进行跟踪时,每时刻目标数目的估计情况.从图中可明显看到,在该实验情况下,本文作者所提算法结合了当前时刻的信息进行航迹关联,能更好的剔除 PHD 滤波中多余的高斯项,较准确的估计出目标的数目.另外,如图 8 所示, RBPF-PHD 关联滤波在每次目标消失时都会有估计延时的情况,如第 30, 40 和 50 等采样时刻,这是由 γ 消失模型的参数 α 、 β 决定的,为了防止某时刻由于目标的漏检所导致的目标航迹结束,而保留一次当前目标的航迹. γ 消失模型的参数 α 、 β 可以根据传感器检测性能以及当前的检测跟踪环境进行不同的调整,反应出该算法一定的适应性和灵活性.

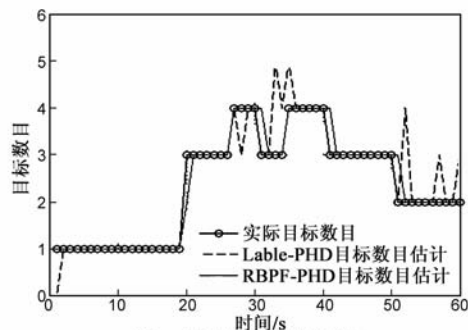


图8 目标数目估计情况

表 1 给出了两种算法每时刻得到的目标估计集合中,所有目标估计集合和真实目标组成集合之间脱靶距离,这里的脱靶距离选择为 Wasserstein 距离^[4].通过表 1 可看出在文中所统计的不同观测噪声情况下,由于 RBPF 在对 PHD 所估计出的目标集合进行关联区分时加入了当前的新的信息,所以文章提出的算法均比 Label-PHD 算法的跟踪误差小,鲁棒性强.

表 1 还统计了两种算法的平均单次运行时间, Label-PHD 算法是通过与高斯混合 PHD 中的所有混合高斯项进行标记,进而识别不同的目标航迹,这种方法没有考虑到当前的新的观测信息,操作比 RBPF-PHD 简单,运行时间较短.而 RBPF-PHD 相当于进行了二次关联滤波来区分不同的目标航迹,计算量要稍大于 Label-PHD 算法.但操作运行时间仍然在有效的范围之内,可以完成对目标的实时跟踪.

表 1 两种方法脱靶距离随观测噪声变化情况及平均单次运行时间 (表为 100 次 Monte Carlo 实验结果)

$\sigma_{\theta} = \sigma_{\beta}$ (rad)	Label-PHD 脱靶距离均值 (m)	RBPF-PHD 脱靶距离均值 (m)
0.002	15.9617	12.5703
0.004	31.0789	15.8912
0.006	46.4582	22.3254
0.008	70.8938	29.8258
平均单次运行时间/s	16.23	29.35

5 结论


针对纯角度多传感器系统中数量变化的多目标航迹关联跟踪问题,文章中提出一种基于随机有限集的 RBPF 关联滤波方法,并将该方法用于 GMPHD 中进行多目标的航迹检测与关联.算法首先利用 GMPHD 对大量杂波环境下数量变化的多个目标进行估计,得到关于目标的集合;为了使每时刻 GMPHD 估计集合中的目标相互关联,完成对于每个目标完整的航迹区分和估计,利用一种新的随机有限集 RBPF 处理思路,采用其中的粒子滤波对 GMPHD 的估计结果进行检测和关联、卡尔曼滤波进行二次滤波,并通过之后对变维粒子的融合完成整个航迹区分和估计.另外文章提出的随机有限集 RBPF 本身作为一种单独的算法可用于杂波或目标数量较少情况下的多目标检测跟踪.文章最后的实验结果表明,作者提出的算法在跟踪性能及航迹关联区分等方面,都要好于经典的 Label-PHD 算法.文章只对 RBPF 在 PHD 多目标跟踪数据关联中的应用作了初步探索, RBPF 中某些参数的设置缺乏指导,如何设置参数、对算法进行优化以降低算法执行时间,进一步提高关联正确率是作者今后需要开展的工作.

参考文献

- [1] Bar shalom Y, LI X. Multitarget_ Multisensor Tracking: Principles and Techniques[M]. Storrs, CT: YBS Publishing, 1995.
- [2] Mahler R P S. Multitarget bayes filtering via first-order multitarget moments[J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4): 1152 – 1178.
- [3] 徐晓滨, 文成林, 刘荣利. 基于随机集理论的多源信息统一表示与建模方法[J]. 电子学报, 2008, 36(6): 1174 – 1181.
The Unified method of describing and modeling multisource information based on random set theory [J]. Acta Electronica Sinica, 2008, 36(6): 1174 – 1181.
- [4] Shoenfeld Peter S. A particle filter algorithm for the multi-target probability hypothesis density[J]. Signal Processing, Sensor Fusion, and Target Recognition XIII, 2004: 315 – 325.
- [5] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091 – 4104.
- [6] Panta K, Vo Ba Ngu, Singh S. Novel data association schemes for the probability hypothesis density filter [J]. IEEE Transactions on Aerospace and Electronic Systems, 2007, 43(2): 556 – 570.
- [7] Clark D E, Panta K, Vo B N, The GM-PHD filter multiple target tracker [A]. 9th International Conference on Information Fusion [C]. Florence: IEEE, 2006. 1 – 8.
- [8] Simo Särkkä, Aki Vehtari, Jouko Lampinen. Rao-Blackwellized particle filter for multiple target tracking [J]. Information Fusion, 2007, 8(1): 2 – 15.
- [9] Julier S J, Uhlmann J K. A new extension of the Kalman filter to nonlinear systems [J]. Signal Processing, Sensor Fusion, and Target Recognition VI, 1997, 3068: 182 – 193.
- [10] Liu H, Dou L H, Pan F, Dong L X. Research on data associa-

tion in three passive sensors network [A]. 2007 IEEE International Conference on Control and Automation, ICCA, 2007 [C]. Guangzhou: IEEE, 2007. 3235 – 3238.

作者简介:



赵欣女, 1984年1月出生于陕西榆林. 2006年毕业于西安电子科技大学生物医学专业, 获工学学士学位, 2009年毕业于西安电子科技大学模式识别与智能系统专业, 获工学硕士学位, 其后进入中国航天集团公司四院401所工作. 主要从事于多传感器信息融合, 动力测控技术方面的研究工作.

E-mail: zhao_xin1984@126.com



姬红兵男, 1963年6月出生于陕西榆林. 1983年获西北电讯工程学院(现西安电子科技大学)雷达工程专业工学学士学位. 1989年1月获该校电路、信号与系统专业工学硕士学位. 1999年7月获该校信号与信息处理专业博士学位, 教授、博士生导师、中国电子学会高级会员、IEEE会员、校模式识别与智能系统学科带头人、校学术委员会常委. 现为西安电子科技大学发展

规划处处长、“211工程”办公室主任. 长期从事信号与信息处理、模式识别与智能系统方面的研究和教学工作. 主要研究方向为: 光电信息处理、智能信息处理、被动多传感器定位与跟踪、雷达目标识别与分类、微弱信号检测与识别、医学影像处理等.

E-mail: hbji@xidian.edu.cn



杨柏胜男, 1980年出生于辽宁铁岭. 2003年毕业于西安电子科技大学电子信息专业, 获工学学士学位, 2006年毕业于西安电子科技大学信号与信息处理专业, 获工学硕士学位, 2006年至今在西安电子科技大学模式识别与智能系统专业攻读博士学位. 主要从事多传感器优化布站、目标跟踪、非线性滤波等方面的研究.