

## 箱粒子PHD演化网络群目标跟踪算法

宋骊平<sup>†</sup>, 刘宇航, 程 轩

(西安电子科技大学 电子工程学院, 西安 710071)

**摘要:** 群演化网络模型对群结构的构建和实时更新提供了良好的实现方式. 针对粒子概率假设密度(SMC-PHD)滤波算法存在运算量大的问题, 提出一种基于箱粒子概率假设密度(BP-PHD)滤波的演化网络群目标跟踪算法. 将群演化网络模型得到的群结构信息反馈回BP-PHD滤波过程中, 从而实现群目标的跟踪和群数目的估计. 对比实验表明, 所提出算法可以在保证跟踪效果的同时减少计算量, 并且在杂波密集的条件下具有更好的跟踪精度和鲁棒性.

**关键词:** 演化网络模型; 群目标跟踪; 箱粒子滤波; 概率假设密度

**中图分类号:** TP273

**文献标志码:** A

## Box-particle evolution network PHD filter for group targets tracking

SONG Li-ping<sup>†</sup>, LIU Yu-hang, CHENG Xuan

(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

**Abstract:** The evolving network model provides a better method to deal with the structure of groups, including the formation and real-time update. The box-particle evolution networks probability hypothesis density(PHD) filter for group targets tracking is proposed to improve the increase of computational effort about a sequential Monte Carlo(SMC) PHD filter. The proposed algorithm obtains information of group targets which is combined with BP-PHD and evolving network models, and then feeds back the information to the filter. Consequently, the algorithm realizes the tracking and number estimation of group targets. Comparative experiments show that, the proposed algorithm is more effective than the SMC-PHD filter, especially in high clutter environments.

**Keywords:** evolving network model; group targets tracking; box-particle filter; probability hypothesis density(PHD)

### 0 引言

随着目标跟踪技术的不断发展,跟踪场景的复杂度也不断提高,尤其是密集多目标跟踪领域,跟踪对象通常由相同或相似运动状态的多个目标组成,并且对外表现出一种群组特征,同时会涉及群组的分裂与合并等情况,例如:弹道导弹的头体和碎片分离前后的跟踪和威胁评估等,此类跟踪问题就是群目标跟踪. 群目标跟踪是在近代目标跟踪的基础上,借鉴编队目标队形跟踪的方法,将数据关联和态势关联相统一的跟踪方法. 群目标跟踪打破了目标数量、密集程度和量测与目标对应关系的限制,具有一定的态势认知能力<sup>[1-2]</sup>. 20世纪90年代,Salmond等<sup>[3]</sup>提出了群和扩展目标跟踪的概念,主要方法是用贝叶斯多假设方法和粒子滤波相结合的方式实现目标跟踪;随后,在21世纪初期,Gning等<sup>[4-5]</sup>将蒙特卡洛方法的粒子

滤波实现形式进行了进一步的完善,并逐渐提出了群演化网络模型以及非线性估计等概念,使得粒子滤波在群目标跟踪领域得到了迅速的发展. 随着实际应用中场景的日益复杂,为了保证粒子滤波的跟踪效果需要采用数目更多的粒子,随之而来的是计算量的增大. 为了解决因为粒子数增大带来的问题,在21世纪初期提出了箱粒子滤波的概念<sup>[6]</sup>.

箱粒子滤波是最近兴起的一种基于区间分析的滤波算法,将粒子滤波与区间分析相结合,为基于随机集的滤波提供了新的实现方法,尤其适用于区间量测条件下的目标跟踪问题. 量测过程一般存在3种不确定因素: 1)统计不确定性,这是由随机量测噪声引起的,即传统点量测; 2)集合论不确定性,对于具有未知分布和偏差的量测,为了描述其有界误差,需将其建模为多维区间,即区间量测; 3)数据关联不确定性,

收稿日期: 2016-11-08; 修回日期: 2017-02-08.

基金项目: 国家自然科学基金项目(61372003); 国家自然科学基金青年项目(61301289).

作者简介: 宋骊平(1975—),男,副教授,博士,从事信号与信息处理、目标定位与跟踪等研究; 刘宇航(1992—),男,硕士生,从事群目标跟踪方法的研究.

<sup>†</sup>通讯作者. E-mail: lpsong@xidian.edu.cn

这是由传感器的漏检和虚警引起的,或者在复杂的分布式观测系统中经常存在未知的同步偏差或系统时延等,导致得到的量测数据以区间的形式出现<sup>[7]</sup>. 对于以区间形式出现的这种非传统量测即区间量测而言,采用区间分析的方法对其建模和描述更为切合. Gning等<sup>[8]</sup>提出了单目标伯努利箱粒子滤波算法,将箱粒子理论引入目标跟踪领域;随后, Schikora等<sup>[9]</sup>结合随机集滤波提出了箱粒子PHD算法,这种算法只需用很少的粒子便可达到与传统粒子PHD滤波相近的跟踪效果,大大降低了计算复杂度. 在传统粒子滤波方面,文献[10]用箱粒子替换原来的粒子,并对比基于广义似然函数加权的粒子滤波算法,都有较好的表现,但并未采用多目标跟踪的PHD滤波算法.

本文采用区间分析的方法解决群目标问题,用区间量测解决实际应用中的量测不确定性问题,能够在大大降低计算复杂度的同时保证跟踪效果. 群目标跟踪不同于传统多目标跟踪,因为群目标跟踪不仅要维持群内个体目标的轨迹,还要对不同的目标依据状态信息进行建模以及不断构建和更新群结构. 针对不同的目标运动场景,还会存在一种部分可分辨的群目标,主要是由于群内目标比较密集,并且传感器的分辨力不够充分,导致群内的个体目标是部分可分辨的<sup>[11]</sup>. 此外,群的合并与分裂也是群目标跟踪问题的关键,群演化网络模型为群结构的构建和实时更新提供了较好的实现方式. 本文将箱粒子PHD算法应用到群目标跟踪中,对群目标进行预测更新,并与群演化网络模型相结合,将得到的群结构信息反馈回箱粒子PHD算法迭代过程中,从而实现群目标的跟踪和群数目的估计. 对比实验表明,相比于粒子PHD滤波算法,本文提出的算法可以在保证跟踪效果的同时提高运算效率.

## 1 演化网络模型

群演化网络模型是由顶点与边构成的一张实时更新的图,其中顶点表示目标,边则用来对应目标之间的关系,假设 $N$ 个目标构成了一个顶点集合 $\mathbf{V} = \{v_1, \dots, v_N\}$ ,用边 $E(i, j) = (v_i, v_j)$ 表示两个目标之间的关系,因此整个群结构可以表示为 $\mathbf{G} = (\{v_1, \dots, v_N\}, E)$ . 为了定量地描述目标之间的关系,可将满足某种判别准则的目标划分到同一个群中,当且仅当两个目标之间的关系满足条件时,可以认为它们同属于一个群<sup>[12]</sup>. 例如:通过计算不同目标之间位置和速度的马氏距离,与队形的门限进行对比,判定哪些目标属于一个连通的分支,同属于一个

连通分支的这些目标可以被视为一个群. 所以也可以用 $\mathbf{G}_t = \{g_1, \dots, g_{n_G}\}$ 描述整体的群网络结构,其中 $g_i$ 代表第 $i$ 个连通的分支,即第 $i$ 个子群, $n_G$ 则代表当前时刻 $\mathbf{G}$ 内子群的个数.

### 1.1 模型初始化 $f_I$

假设在 $t = 0$ 时刻,目标的数目 $N$ 以及它们各自的状态是已知的.  $N$ 个目标构成了一个顶点集合 $\mathbf{V} = \{v_1, \dots, v_N\}$ ,其中 $v_i$ 中包含第 $i$ 个目标的初始状态信息 $x_{0,i}$ 和方差信息 $\mathbf{P}_{0,i}$ . 模型初始化的主要步骤为:计算集合 $\mathbf{V}$ 中的任意两个不同顶点的马氏距离 $d_{i,j}(i, j = 1, 2, \dots, N; i \neq j)$ ,与之前选定好的门限值 $\varepsilon$ 作比较,落入预设门限内的边的信息保存在 $E$ 中,最后得到初始化的群结构 $\mathbf{G}_0 = (\{v_1, \dots, v_N\}, E)$ .

### 1.2 边的更新

由于群目标所涉及的目标数目相对较多,建立模型时顶点集中的元素也较多,计算边更新时的运算量较大. 为了降低计算量,文献[12]提出了一种结合前一时刻群结构信息的算法,根据 $\mathbf{G}_{t-1}$ 的信息,抽取每个子群 $g$ 的中心状态 $\mathbf{O}^g = \left(\frac{1}{n_g}\right) \sum_{v_k \in g} x_k^g$ 和子群内所有目标的平均协方差矩阵 $\mathbf{P}^g = \left(\frac{1}{n_g}\right) \sum_{v_k \in g} \mathbf{P}_k^g$ ,其中 $n_g$ 表示子群 $g$ 内目标的个数. 然后由 $n_G$ 个抽取出来的子群中心状态和平均均方差矩阵构成一个顶点集合 $\mathbf{V}' = \{v'_1, \dots, v'_{n_G}\}$ ,根据初始化模型中的方法,依据合适的门限 $\varepsilon'$ 形成一个新的群结构 $\mathbf{G}' = (\{v'_1, \dots, v'_{n_G}\}, E')$ ,通过 $\mathbf{G}'$ 找出邻近的子群,对邻近子群中的节点进行更新,避免了不相关子群之间节点的更新,从而提高了计算效率.

### 1.3 新节点的加入

当有新的节点加入时,同样需要计算新节点 $v_{\text{new}}$ 与其他节点之间的马氏距离,从而得到新节点的边的信息. 为了能够减少运算量,参考边更新时的群结构 $\mathbf{G}' = (\{v'_1, \dots, v'_{n_G}\}, E')$ ,计算 $v_{\text{new}}$ 和子群 $g_i$ 的中心状态 $\mathbf{O}^{g_i}$ 与协方差矩阵 $\mathbf{P}^{g_i}$ 之间的马氏距离. 与预设门限进行比较,若满足条件,则新节点被划分到对应的子群 $g_i$ 中,否则,新节点则被认为是一个单独的子群.

### 1.4 节点的删除

节点的删除是整个群演化网络模型中相对简单的部分,如果模型中一段时间内获取的量测信息中没有关于节点 $v_D$ 的信息,则 $v_D$ 被视为一个消亡目标对应的节点,节点删除部分的功能便是删除消亡目标节点以及该节点所对应的边的信息.

## 2 箱粒子PHD滤波器

传统的量测可通过统计形式进行描述,表现为所谓的点量测.然而在实际应用中,特别是复杂的分布式观测系统中,由于经常存在未知的系统延时、有界偏差量测和未知的同步偏差等,使得量测结果常被未知分布的区间误差所影响<sup>[7]</sup>.针对这种非传统量测,采用区间分析更为合理.箱粒子滤波的主要思想是在状态空间中采用最大误差已知、具有一定大小且大小可控的箱粒子代替传统的点粒子拟合目标的后验概率密度,从而进行滤波处理.用量测箱粒子表示具有最大误差边界的区间量测,对于量测分布未知与箱粒子区域内量测是否来自于目标有着更好的适应性.在复杂场景中还可通过将区域划分为一个个排列整齐的矩形箱来标记落入范围内的所有量测,从而大大简化了系统复杂度.

在处理区间量测时,箱粒子滤波具有与粒子滤波相似的预测和更新步骤,然而也存在不同的地方.在预测步骤中,箱粒子通过非线性转移函数传递后,很难得到一个规则的箱体,不规则的箱体增加了计算复杂度,因此,引入包含函数将传递后的预测区域转化为规则的箱粒子<sup>[13]</sup>.粒子滤波量测更新步骤需要计算似然函数,而箱粒子更新的似然函数是由预测箱和量测箱的重叠面积与预测箱面积的比值确定的.由于每个规则的箱粒子都包含冗余信息,需要根据每个箱粒子和量测箱的重叠关系进行收缩.重采样步骤用来防止箱粒子退化,保证箱粒子多样性,在箱粒子滤波中经常采用随机子划分重采样方法<sup>[14]</sup>.

在多目标跟踪中,随机有限集理论被广泛应用,由于目标数目和量测数目都是随机过程,目标的状态集合与量测集合可以分别表示为两个随机有限集合,即

$$\mathbf{X}_k = \{\mathbf{x}_{k,1}, \dots, \mathbf{x}_{k,N_k}\} \in F(\chi), \quad (1)$$

$$\mathbf{Z}_k = \{\mathbf{z}_{k,1}, \dots, \mathbf{z}_{k,M_k}\} \in F(\psi). \quad (2)$$

其中:  $N_k$  为  $k$  时刻目标数;  $\mathbf{x}_{k,i}$  ( $i = 1, 2, \dots, N_k$ ) 为目标  $i$  的状态;  $\mathbf{z}_{k,j}$  ( $j = 1, 2, \dots, M_k$ ) 为量测  $j$  在量测空间  $F(\psi)$  上的量测矢量,包含真实量测和杂波量测;  $M_k$  为  $k$  时刻得到的量测数目.

类比于传统量测,针对非传统量测可将量测集表示为

$$\mathbf{r}_k = \{[\mathbf{z}]_{k,1}, \dots, [\mathbf{z}]_{k,M_k}\} \in F(\mathbf{I}\mathbf{Z}). \quad (3)$$

其中:  $[\mathbf{z}]$  为区间分析的表示形式,在一维空间中包含区间长度的信息,在二维空间中包含矩形箱的信息;  $\mathbf{I}\mathbf{Z}$  为观测空间;  $M_k$  为  $k$  时刻所得到的量测数目之

和.

类比随机向量的期望值,可以得到随机集后验分布的一阶矩<sup>[15]</sup>,并将它命名为概率假设密度 (PHD). 本文主要研究的是群目标跟踪中箱粒子PHD和群演化网络模型的应用,故采用区间数据对随机集进行处理.

PHD滤波器主要包含预测和更新两部分,预测部分可通过如下公式实现:

$$f_{k|k-1}(\mathbf{x}_{k-1}) = b(\mathbf{x}_k) + \int p_s(\mathbf{x}_{k-1})p(\mathbf{x}_k|\mathbf{x}_{k-1})f_{k-1|k-1}(\mathbf{x}_{k-1})d\mathbf{x}_{k-1}. \quad (4)$$

其中:  $b(\mathbf{x}_k)$  为  $k$  时刻新生目标的强度函数,  $p_s(\mathbf{x}_{k-1})$  为目标存活概率,  $p(\mathbf{x}_k|\mathbf{x}_{k-1})$  为单个目标的转移概率密度. 更新步骤的公式如下:

$$f_{k|k}(\mathbf{x}_k) \cong F(\mathbf{Z}|\mathbf{x}_k)f_{k|k-1}(\mathbf{x}_k), \quad (5)$$

$$F(\mathbf{Z}|\mathbf{x}_k) = 1 - p_D(\mathbf{x}_k) + \sum_{\mathbf{z} \in \mathbf{Z}_k} \frac{p_D(\mathbf{x}_k)p(\mathbf{z}|\mathbf{x}_k)}{\lambda c(\mathbf{z}) + \int p_D(\mathbf{x}_k)p(\mathbf{z}|\mathbf{x}_k)f_{k|k-1}(\mathbf{x}_k)d\mathbf{x}_k}. \quad (6)$$

其中:  $p_D(\mathbf{x}_k)$  为目标在  $k$  时刻被检测到的概率,  $p(\mathbf{z}|\mathbf{x}_k)$  为量测的似然函数,  $c(\mathbf{z})$  为杂波的概率分布,  $\lambda$  为平均杂波数目.

## 3 箱粒子PHD演化网络群目标跟踪算法

### 3.1 群目标运动模型和量测模型

1) 群内个体目标的运动模型假定为CV模型<sup>[16]</sup>,在二维空间中,目标状态的给出方式如下:

$$\mathbf{x}_k = \mathbf{F}\mathbf{x}_{k-1} + \Gamma\boldsymbol{\omega}_k. \quad (7)$$

其中: 目标状态转移矩阵  $\mathbf{F} = \text{diag}(\mathbf{F}_1, \mathbf{F}_1)$ ,  $\mathbf{F}_1 = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}$ ; 状态噪声的转移矩阵  $\Gamma = \begin{bmatrix} T^2/2 & T & 0 & 0 \\ 0 & 0 & T^2/2 & T \end{bmatrix}$ ,  $T$  为采样时间间隔;  $\boldsymbol{\omega}_k$  为过程噪声.

2) 假设量测空间  $\mathbf{Z} \subseteq \mathbf{R}_{n_z}$ ,  $t$  时刻第  $i$  个目标的点量测  $\mathbf{z}_{t,i} \in \mathbf{Z}$  可以表示如下:

$$\mathbf{z}_{t,i} = \mathbf{H}\mathbf{x}_{k-1} + \boldsymbol{\nu}_k. \quad (8)$$

其中: 目标量测矩阵  $\mathbf{H} = \text{diag}(\mathbf{H}_1, \mathbf{H}_1)$ ,  $\mathbf{H}_1 = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$ ; 量测噪声  $\boldsymbol{\nu}_k$  服从高斯分布,且协方差矩阵已知. 本文采用箱粒子滤波处理区间量测数据  $[\mathbf{z}] \subset \mathbf{Z}$ , 可将其理解为一个模糊区间覆盖了点量测  $\mathbf{z}_{t,i}$ , 因此可用  $t$  时刻的有限集表示量测集合  $\mathbf{Z}_t$ :  $\mathbf{Z}_t = \{[\mathbf{z}_{t,i}], \dots, [\mathbf{z}_{t,N}]\} \in F(\mathbf{Z})$ , 其中  $F(\mathbf{Z})$  表示区间量测子集空间.

将个体目标的运动模型和演化网络模型相结合,

可以得到群目标模型,使得目标状态和群结构之间建立起必要的联系,从而可以在滤波过程的目标估计结果中动态地得到群结构信息。

### 3.2 算法基本流程

针对目标量测非精确的情况,传统粒子滤波过程需要更多的粒子来保证精度,从而导致计算量增大且不利于实时跟踪。因此,本文引入箱粒子滤波以解决区间量测下的群目标跟踪,将传统的SMC-PHD滤波中的点粒子用箱粒子代替得到BP-PHD滤波,同时对群的整体结构应用演化网络模型进行更新。本文算法的基本流程如下。

#### 3.2.1 初始化

在初始化中,假设 $k-1$ 时刻存活箱粒子集为 $\{w_{k-1}^{\text{pre},(i)}, [\mathbf{x}_{k-1}^{\text{pre},(i)}]\}_{i=1}^{N_{k-1}}$ ,在前一时刻的量测周围进行采样,生成新的箱粒子补充到原有的粒子集中。由于每个时刻均有新的箱粒子补入,前一时刻每个量测产生的新箱粒子数目如下:

$$N_{k,\text{new}}^{(j)} = \left\lceil \frac{N_{k,\text{new}}}{m_{k-1}} \right\rceil, j = 1, 2, \dots, m_{k-1}. \quad (9)$$

其中: $\lceil x \rceil$ 为向上取整, $N_{k,\text{new}}$ 为量测数目, $m_{k-1}$ 为 $k-1$ 时刻的量测数目。新粒子的权值分配如下:

$$w_{k-1}^{\text{bir},(i)} = \frac{\text{Pr}_{B,k}([\mathbf{x}])}{N_{k,\text{new}}}, i = N_k + 1, \dots, N_{k,\text{new}}, \quad (10)$$

$\text{Pr}_{B,k}([\mathbf{x}])$ 为新生概率。初始化中箱粒子集合由两部分组成,存活箱粒子集和补入的箱粒子集,即

$$\begin{aligned} & \{w_{k-1}^{(i)}, [\mathbf{x}_{k-1}^{(i)}]\}_{i=1}^{N_k} = \\ & \{w_{k-1}^{\text{pre},(n)}, [\mathbf{x}_{k-1}^{\text{pre},(n)}]\}_{n=1}^{N_{k-1}} \cup \{w_{k-1}^{\text{bir},(m)}, [\mathbf{x}_{k-1}^{\text{bir},(m)}]\}_{m=1}^{N_{k,\text{new}}}, \end{aligned} \quad (11)$$

$k$ 时刻更新后箱粒子总数可以表示为

$$N_k = N_{k-1} + N_{k,\text{new}}.$$

模型初始化时,根据初始状态 $\mathbf{X}_0$ 得到初始时刻的顶点集合 $\mathbf{V}_0$ ,参照 $f_I$ 中的方法,计算 $\mathbf{V}_0$ 中任意两个目标顶点之间的马氏距离,与选定好的门限值 $\varepsilon$ 作比较,根据比较结果形成初始化群结构 $\mathbf{G}_0$ 。由于BP-PHD算法中采用的是区间量测,得到初始化的顶点集合时需要进行箱粒子的点化操作 $\mathbf{x}' = \text{mid}([\mathbf{x}_{k-1}^{(i)}])$ ,其中 $\text{mid}([\mathbf{x}])$ 表示返回当前箱粒子 $\mathbf{x}$ 的中心状态,从而得到初始时刻的目标群结构 $\mathbf{G}_0$ 。

#### 3.2.2 预测

通过状态转移方程进行状态预测,粒子的权值表示如下:

$$[\mathbf{x}_{k|k-1}^{(i)}] = [f_{k|k-1}][\mathbf{x}_{k-1}^{(i)}] + [\boldsymbol{\omega}_k], i = 1, 2, \dots, N_k; \quad (12)$$

$$w_{k|k-1}^{(i)} = \text{Pr}_{S,k}[\mathbf{x}_{k-1}^{(i)}]w_{k-1}^{(i)}, i = 1, 2, \dots, N_k. \quad (13)$$

其中: $[f_{k|k-1}]$ 为包含函数, $[\boldsymbol{\omega}_k]$ 为 $k$ 时刻噪声的区间量测, $\text{Pr}_{S,k}$ 为目标存活概率。

#### 3.2.3 更新

假设有服从参数为 $\lambda$ 的杂波均匀地分布在监控区域内, $k$ 时刻粒子权值更新如下:

$$\begin{aligned} w_k^{(i)} = & (1 - \text{Pr}_{D,k}([\mathbf{x}_{k|k-1}^{(i)}]))w_{k|k-1}^{(i)} + \\ & \sum_{j=1}^{m_k} \frac{g_k([\mathbf{z}_j][\mathbf{x}_{k|k-1}^{(i)}])\text{Pr}_{D,k}([\mathbf{x}_{k|k-1}^{(i)}])}{\lambda_{k/k-1}([\mathbf{z}_j])} w_{k|k-1}^{(i)}, \end{aligned} \quad (14)$$

其中 $\text{Pr}_{D,k}$ 为检测概率。在箱粒子滤波中采用了一种特殊的似然函数<sup>[9]</sup>对检测到的部分进行更新,即

$$g_k([\mathbf{z}_j][\mathbf{x}_{k|k-1}^{(i)}]) = \frac{|[h_{cp}([\mathbf{x}_{k|k-1}^{(i)}], [\mathbf{z}_j])]|}{|[\mathbf{x}]|}, \quad (15)$$

$$\begin{aligned} \lambda_{k/k-1}([\mathbf{z}_j]) = & \lambda_c([\mathbf{z}_j]) + \sum_{i=1}^{N_{k-1} + N_{k,\text{new}}} g_k([\mathbf{z}_j][\mathbf{x}_{k|k-1}^{(i)}]) \times \\ & \text{Pr}_{D,k}([\mathbf{x}_{k|k-1}^{(i)}])w_{k|k-1}^{(i)}. \end{aligned} \quad (16)$$

在更新步骤中,对箱粒子的预测状态进行约束,其中预测箱和量测箱主要有两种位置关系:非重叠和重叠。非重叠部分在滤波过程中被舍弃,而后者则根据 $[h_{cp}([\mathbf{x}_{k|k-1}^{(i)}], [\mathbf{z}_j])]$ 进行约束传播<sup>[6]</sup>, $|[\mathbf{x}]|$ 表示区间 $[\mathbf{x}]$ 在二维状态空间的长度,其约束方法如下:

$$[\mathbf{x}] = [\mathbf{x}] \cap [\mathbf{x}_z], [\mathbf{y}] = [\mathbf{y}] \cap [\mathbf{y}_z]. \quad (17)$$

如式(17)所示,通过在二维空间两个维度上各自取交集的方式,得到约束传播之后的结果。

#### 3.2.4 重采样

更新之后得到的箱粒子集要保持其多样性,因此必须进行重采样操作。箱粒子的数目比较少,并且都是以区间的形式呈现,所以不同于粒子滤波,箱粒子的重采样既要避免收敛过快,又要防止其过分发散。因此,采用现有的随机子划分的重采样方法,在预测步骤中需要根据前一时刻的量测位置实时加入新的箱粒子<sup>[7]</sup>,以解决BP-PHD算法中箱粒子集的多样性。

#### 3.2.5 群结构更新与反馈

对重采样之后得到的箱粒子集合进行初步的状态提取,将提取出的结果按照群演化网络模型中边的更新步骤进行分群操作,从而得到更新之后的群结构 $\mathbf{G}_k$ ,进一步得到各个目标在 $k$ 时刻的联系和目标与子群的所属关系以及 $k$ 时刻的子群 $\mathbf{g}$ 的数目 $n_{\mathbf{G}}$ 。

将箱粒子集合 $\{w_k^{(i)}, [\mathbf{x}_k^{(i)}]\}_{i=1}^{N_k}$ 中同属于一个子群 $\mathbf{g}$ 中的目标状态根据当前时刻的群信息进行修正,

根据更新之后的群结构信息将属于同一个子群内所有目标的运动速度统一,从而将滤波过程中因为预测和更新时噪声对目标状态带来的影响进行合理的修正,以完成群结构信息的反馈,进一步得到包含了群结构信息的新的箱粒子集合  $\{w_k^{(i)}, [\mathbf{x}_{G_k}^{(i)}]\}_{i=1}^{N_k}$ .

### 3.2.6 目标状态提取

对得到的箱粒子集合  $\{w_k^{(i)}, [\mathbf{x}_{G_k}^{(i)}]\}_{i=1}^{N_k}$  进行点化得到目标区间状态的中心,状态估计结果为

$$\hat{\mathbf{x}} = \sum_{i=1}^{N_k} w_k^{(i)} \cdot \text{mid}([\mathbf{x}_{G_k}^{(i)}]). \quad (18)$$

根据状态估计结果,结合当前时刻估计的群数量进行  $k$ -means 聚类,从而得到  $k$  时刻的群中心状态.

## 4 仿真实验与分析

为了验证本文提出的箱粒子PHD演化网络群目标跟踪算法的性能,设计了群目标跟踪的仿真实验,模拟了群目标的合并与分裂等场景.实验采用两种群目标滤波算法:SMC-PHD和BP-PHD.使用OSPA距离作为滤波性能的评价指标<sup>[17]</sup>.

模拟一个大小为  $A = [\pm 500] \text{ m} \times [\pm 500] \text{ m}$  且分布有随机噪声的二维观测区域,区域中有8个目标,运动时长为40s,运动过程中会有群的分裂与合并.目标状态方程和量测方程分别如式(7)和(8)所示.采样时间间隔  $T = 1$ ,过程噪声  $\omega_k$  的标准差  $\sigma_x = \sigma_y = 0.05$ ,量测噪声  $\nu_k$  的标准差  $\sigma_x = \sigma_y = 2.5$ ,目标的存活概率  $\text{Pr}_{S,k} = 0.99$ .OSPA距离参数设置为  $p = 2, c = 70$ .箱粒子区间量测  $[z]_k = [h_k(\mathbf{x}) + \nu_k - 0.5\Delta, h_k(\mathbf{x}) + \nu_k + 0.5\Delta]$ ,区间长度  $\Delta = [14, 24]^T$ .粒子PHD滤波算法中每一个时刻保留3000个粒子,且每个时刻补入新粒子数为8个;而本文提出的算法中每一个时刻保留35个箱粒子,并在上一时刻量测位置附近补入2个箱粒子.

目标的真实运动状态如表1所示,表1中的“~”表示目标速度发生变化的时刻所对应的位置信息.目标的真实运动轨迹和一次蒙特卡罗(MC)仿真的跟踪结果如图1所示.图1中的实线表示目标在二

维空间的真实运动轨迹,“◁”表示BP-PHD滤波跟踪结果,“○”表示SMC-PHD滤波跟踪结果,“·”表示真实的群中心轨迹.




图1 目标运动轨迹和跟踪结果

本文采用50次MC仿真的结果来验证算法的平均运行效果.仿真条件与上述条件一致,设置平均杂波数目  $r = 2$ ,跟踪结果和评价指标如图2和图3所示.




图2 群目标数估计结果




图3 OSPA距离

### 1) 性能指标与结果分析.

由图2可看出,两种滤波算法对群目标数目的估计在大部分时刻都与真实值一致.在群合并时刻(13s)附近,真实群目标数与群目标数估计结果有一个时刻的延迟,而群分裂时刻(30s)的群目标数存在过估的情况.群合并时刻的误差主要是因为真实目标轨迹合并前一时刻,两个群分别保持着各自群中心对应的速度,直到两个群的合并,即在两个群中心基本重合时因其保持各自的速度而超过演化网络模型分群的速度门限,从而导致真实群目标数目比滤波结果的群目标数目滞后了一个时刻;而图2中个别时刻出现不同程度的目标数目过估是因受到杂波的影响.

表1 目标运动参数

	2~12s	13~29s	30~40s
1		$[-400, 20, 400, -23]$	
2		$[400, -7, 470, -23]$	
3		$[-400, 20, 410, -23]$	
4		$[405, -7, 470, -23]$	
5		$[-400, 22, -300, 15]$	
6		$[-405, 22, -300, 15]$	
7	$[-400, 22, -300, 15]$		$[\sim, 18, \sim, -15]$
8	$[-400, 20, 0, 14]$	$[\sim, 20, \sim, -23]$	

由图3可看出,两种滤波器的OSPA距离比较接近,SMC-PHD滤波器滤波跟踪结果的误差稍小于BP-PHD滤波器,但通过比较两种滤波器的平均运行时间(如表2所示)可以看出,BP-PHD滤波器比SMC-PHD滤波器有着更高的计算效率,这也是引入箱粒子滤波的优势所在。

表2 两种算法所需粒子数和平均运行时间

滤波器类型	BP-PBH	SCM-PHD
存活粒子数目	35	3000
补入粒子数目	2	8
运行时间/s	110	357

2) 杂波数与(箱)粒子数对两种算法的影响。

在相同的实验条件下,本文进一步仿真分析了杂波数目对两种算法的影响;然后,在保证杂波数目不变的情况下分析了箱粒子数目对本文算法跟踪精度的影响;最后分析了在相同条件下,两种算法在不同(箱)粒子数目时的运行时间。

由图4可以看出,随着杂波数目的不断增加,两种滤波算法的平均OSPA距离都会逐渐增大,但从图中曲线可以看出,箱粒子滤波算法的平均OSPA距离曲线的斜率要小于传统粒子滤波算法,即面对杂波密集的场景,箱粒子滤波算法有着更好的表现。主要原因是:箱粒子滤波算法中采用区间分析的方式处理目标的状态信息,对于量测的不确定性有着更好的适应能力;用箱粒子代替点粒子进行迭代更新时,在上一时刻区间量测周围产生的箱粒子对下一时刻的目标具有检测作用;在计算似然函数更新(箱)粒子步骤时,传统粒子滤波算法会针对当前时刻得到的每一个点量测都分配一个权值,将所有杂波量测的信息按照不同的权值代入更新过程中,而箱粒子滤波采用预测箱和量测箱的重叠面积来计算似然函数,使得一部分杂波分配到的权值为零而不参与更新,从而规避掉一些杂波带来的影响。所以在杂波环境密集的条件下,箱粒子滤波对杂波的过滤作用使得箱粒子滤波比传统粒子滤波具有更好的鲁棒性。

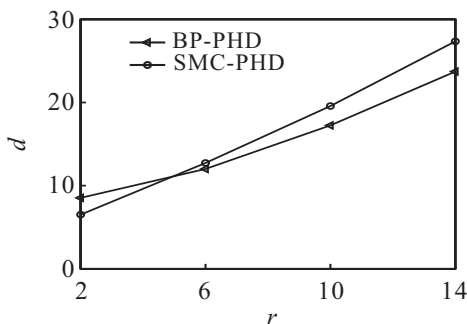


图4 杂波数对平均OSPA距离的影响

图5给出了箱粒子滤波算法平均OSPA距离随着箱粒子数目的变化规律(仿真时杂波数目保持不变 $r = 2$ )。由图5可看出,随着箱粒子数目的不断增加,BP-PHD算法的平均OSPA距离逐渐减小,即箱粒子数目增加可以提高算法的跟踪精度。这是由于箱粒子数目越多,对后验概率密度函数的拟合越准确,因此跟踪精度越高。

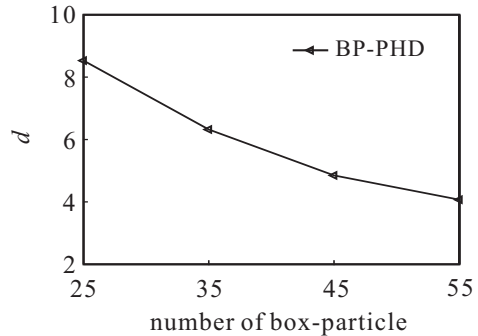


图5 箱粒子数目对平均OSPA距离的影响

表3和表4分析了BP-PHD和SMC-PHD两种算法的平均运行时间和(箱)粒子数目的关系。可以看出,随着粒子或者箱粒子数目的增加,两种算法的平均运行时间都随之增加,但箱粒子滤波算法的运行时间远小于传统粒子滤波算法。结合图5可知:随着箱粒子数目的不断增加,在提高跟踪精度的同时算法运行时间会有所增加,因此在实际应用中应该权衡计算效率与精度以便选取合适的(箱)粒子数目。

表3 BP-PHD算法平均运行时间

箱粒子数	25	35	45	55
运行时间/s	99	110	128	145

表4 SMC-PHD算法平均运行时间

粒子数	2000	2500	3000	3500
运行时间/s	288	399	357	394

5 结论

本文提出了基于箱粒子PHD滤波演化网络的群目标跟踪算法。该算法将箱粒子PHD滤波和演化网络模型相结合,将群的结构信息反馈到滤波过程中,使得群目标整体与群内个体之间保持必要的联系,保证个体目标正确估计的同时对每一个时刻的群目标的整体进行有效地估计,尤其是群结构分裂或者合并的复杂情况。该算法能够对群目标动态地进行识别与划分,从而稳定地估计群目标的状态信息。在实际应用中,可以动态地根据所跟踪目标的运动形式作出准确的处理。与传统粒子PHD滤波算法的多次实验仿真对比得出:本文提出的算法与SMC-PHD滤波算法的跟踪结果精度相近,但前者的计算效率有着明

显的优势;本文提出的算法在密集杂波环境下,跟踪精度与性能均优于SMC-PHD滤波算法.因此,在杂波较为密集的群目标跟踪中,用BP-PHD代替SMC-PHD具有明显的优势.

#### 参考文献(References)

- [1] 耿文东,王元钦,董正宏.群目标跟踪[M].北京:国防工业出版社,2014:1-25.  
(Geng W D, Wang Y Q, Dong Z H. Group-targets tracking[M]. Beijing: National Defend Industry Press, 2014: 1-25.)
- [2] 权太范.目标跟踪新理论与技术[M].北京:国防工业出版社,2009:1-16.  
(Quan T F. Target tracking: Advanced theory and techniques[M]. Beijing: National Defend Industry Press, 2009: 1-16.)
- [3] Salmond D J, Gordon N J. Group and extended object tracking[C]. Proc of IEE Colloquium on Target Tracking. London, 1999: 1-4.
- [4] Gning A, Mihaylova L, Maskell S, et al. Evolving networks for group object motion estimation[C]. Proc of IET Seminar on Target Tracking and Data Fusion: Algorithms and Applications. Birmingham, 2008: 99-106.
- [5] Gning A, Mihaylova L, Maskell S, et al. Ground target group structure and state estimation with particle filtering[J]. Proc of Int Conf Inf Fusion, 2008, 20(3): 1-8.
- [6] Abdallah F, Gning A, Bonnifait P. Box particle filtering for nonlinear state estimation using interval analysis[J]. Automatica, 2008, 44(3): 807-815.
- [7] 宋骊平,严超,姬红兵,等.基于箱粒子的多扩展目标PHD滤波[J].控制与决策,2015,30(10):1759-1765.  
(Song L P, Yan C, Ji H B, et al. PHD filter for tracking multiple extended targets using box particle[J]. Control and Decision, 2015, 30(10): 1759-1765.)
- [8] Gning A, Ristic B, Mihaylova L. Bernoulli particle/box-particle filters for detection and tracking in the presence of triple measurement uncertainty[J]. IEEE Trans on Signal Process, 2012, 60(5): 2138-2151.
- [9] Schikora M, Gning A, Mihaylova L, et al. Box-particle PHD filter for multi-target tracking[C]. Proc of the 15th Int Conf on Information Fusion. Wachtberg, 2012: 106-113.
- [10] 李振兴,刘进忙,李松,等.基于箱式粒子滤波的群目标跟踪算法[J].自动化学报,2015,41(4):786-798.  
(Li Z X, Liu J M, Li S, et al. Group targets tracking algorithm based on box particle filter[J]. Acta Automatica Sinica, 2015, 41(4): 786-798.)
- [11] 连峰,韩崇昭,刘伟峰,等.基于SMC-PHDF的部分可分辨的群目标跟踪算法[J].自动化学报,2010,36(5):732-741.  
(Lian F, Han C Z, Liu W F, et al. Tracking partly resolvable group targets using SMC-PHDF[J]. Acta Automatica Sinica, 2010, 36(5): 732-741.)
- [12] Gning A, Mihaylova L, Maskell S, et al. Group object structure and state estimation with evolving networks and Monte Carlo methods[J]. IEEE Trans on Signal Processing, 2011, 59(4): 1383-1395.
- [13] Gning A, Ristic B, Mihaylova L, et al. An introduction to box particle filtering[J]. IEEE Signal Processing Magazine, 2013, 30(4): 166-171.
- [14] 赵雪刚,宋骊平,姬红兵.量化量测条件下的交互多模型箱粒子滤波[J].西安电子科技大学学报,2014,41(6):38-44.  
(Zhao X G, Song L P, Ji H B. Interacting multiple model box particle filter with quantitative measurements[J]. J of Xidian University, 2014, 41(6): 38-44.)
- [15] Schikora M, Gning A, Mihaylova L, et al. Box-particle probability hypothesis density filtering[J]. IEEE Trans on Aerospace and Electronic Systems, 2014, 50(3): 1660-1672.
- [16] Li X R, Jilkov V. A survey of maneuvering target tracking, Part I: Dynamic models[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1333-1364.
- [17] 刘伟峰,文成林.随机集多目标跟踪性能评价指标比较与分析[J].光电工程,2010,37(9):14-20.  
(Liu W F, Wen C L. Performance comparison and analysis of multitarget tracking indices based on random set[J]. Opto-Electronic Engineering, 2010, 37(9): 14-20.)

(责任编辑:孙艺红)