

DOI: 10.7652/xjtuxb201710018

# 箱粒子广义标签多伯努利滤波的目标跟踪算法

苗雨, 宋骊平, 姬红兵

(西安电子科技大学电子工程学院, 710071, 西安)

**摘要:** 针对序列蒙特卡罗广义标签多伯努利滤波(SMC-GLMB)算法计算效率低、实时性差的问题,提出了箱粒子广义标签多伯努利滤波的目标跟踪(Box-GLMB)算法。该算法使用带标签的随机有限集描述多目标的状态,包括目标的位置和速度,并且对每个目标用互不相同的标签进行区分;然后利用箱粒子滤波算法近似单目标状态的概率密度,即用一组带权值的均匀分布拟合单目标状态概率密度;最后通过广义标签多伯努利滤波对多目标状态的概率密度进行预测与更新,从多目标状态后验概率密度中估计单目标的位置与速度,根据目标的标签可以实现航迹跟踪。Box-GLMB 算法结合了箱粒子滤波与 GLMB 算法的优势,能够跟踪目标航迹,同时提高计算效率。仿真结果表明,Box-GLMB 算法可以有效估计目标状态以及跟踪目标航迹,相比于 SMC-GLMB 算法,计算效率提升了 62%。

**关键词:** 目标跟踪;随机有限集;广义标签多伯努利滤波;箱粒子滤波

**中图分类号:** TN953   **文献标志码:** A   **文章编号:** 0253-987X(2017)10-0107-06

## Target Tracking Method with Box-Particle Generalized Label Multi-Bernoulli Filtering

MIAO Yu, SONG Liping, JI Hongbing

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

**Abstract:** A target tracking method with box-particle generalized label multi-Bernoulli filtering (Box-GLMB) is proposed to address the problem that the sequential Monte Carlo generalized label multi-Bernoulli filter (SMC-GLMB) has low computation efficiency and weak real-time performance. A random finite set with labels is employed to describe states of multi-targets, including positions and velocities of targets, and targets are distinguished by different labels. Then the box-particle filter algorithm is used to approximate the probability density of single target, that is, the probability density of single target is approximated by weighted uniform distributions. Multi-target densities are predicted and updated by using the generalized label multi-Bernoulli filter (GLMB). Target states are estimated from posterior probability density and trajectories of targets are tracked by labels. The proposed method combines the advantages of the box-particle filter and the generalized label multi-Bernoulli filter. Box-GLMB filter is able to track trajectories and to improve computational efficiency at the same time. Simulation results show that the proposed filter effectively estimate states of targets and track trajectories. A comparison with the SMC-GLMB filter show that the proposed filter increases 62%

computational efficiency.

**Keywords:** target tracking; random finite set; generalized labeled multi-Bernoulli filter; box-particle filter

在现代军事领域中,实时地跟踪多目标状态与航迹对于多目标的识别和打击具有重要的意义。近年来,基于随机有限集(RFS)的多目标跟踪算法因其可以避免量测与目标的数据关联,提高目标跟踪的实时性而备受关注。其中,多目标多伯努利滤波算法<sup>[1]</sup>因其在状态提取过程中不需要进行聚类运算,能够有效地降低计算复杂度而受到广泛研究<sup>[2]</sup>,但该算法仅能估计目标状态与数量,不能跟踪目标航迹。为了解决随机有限集下多目标航迹跟踪问题,Vo等人将多假设跟踪思想与RFS理论相结合,定义了带标签的RFS,提出了广义标签多伯努利滤波(GLMB)算法<sup>[3]</sup>,并给出该算法的序列蒙特卡罗(SMC)实现形式,即序列蒙特卡罗广义标签多伯努利滤波(SMC-GLMB)算法<sup>[4]</sup>。该算法可在估计多目标状态的同时跟踪不同目标的航迹,但由于SMC使用较多的粒子进行运算,因此运算效率较低。尽管通过K最短路径算法与最优分配算法可以在一定程度上降低SMC-GLMB算法的计算量,但仍然不能满足实时性需求。

文献[5]结合了序列蒙特卡罗算法和区间分析方法<sup>[6-7]</sup>,提出了箱粒子的概念。箱粒子可以解释为状态空间中具有一定大小的非零多维区间<sup>[8]</sup>,可代替SMC算法中精确的点粒子进行滤波,用均匀分布代替狄拉克分布拟合目标状态的后验概率密度。由于箱粒子滤波具有所需粒子数少、运算速度快的优势,因此得到国内外学者越来越广泛的研究<sup>[9-10]</sup>。

针对SMC-GLMB算法运算效率低的问题,本文将箱粒子滤波算法融入GLMB算法,提出箱粒子广义标签多伯努利滤波。首先,使用带标签的随机有限集描述多目标的状态,包括单目标的位置和速度,并且对每个目标用互不相同的标签进行区分;然后利用箱粒子滤波算法近似单目标状态的概率密度,即用一组带权值的均匀分布拟合单目标状态概率密度;最后通过广义标签多伯努利滤波对多目标状态的概率密度进行预测与更新,从更新后的多目标状态概率密度中估计单目标的位置与速度,并且由于单目标的标签互不相同可以实现航迹跟踪。本文算法可以在有效估计目标状态以及跟踪目标航迹的同时,减少运算所需粒子数量,缩短运行时间,提高算法的实时性。

## 1 问题描述

随机有限集(RFS)是若干随机变量的集合,集合中随机变量的个数即集合的势也是随机的<sup>[11]</sup>。某时刻多目标状态可以表示成随机有限集 $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ ,其中 $\mathbf{x}_i$ 为单目标状态, $N$ 为目标数量。给 $X$ 中每一个目标 $\mathbf{x}_i$ 添加一个互不相同的标签 $l_i \in L$ 进行区分, $L$ 为标签值空间,则 $X = \{(\mathbf{x}_1, l_1), (\mathbf{x}_2, l_2), \dots, (\mathbf{x}_n, l_n)\}$ 称为带标签的RFS。该时刻的量测也可以表示为随机有限集 $Z = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_M\}$ ,其中 $M$ 为量测数量。多目标状态集 $X$ 的后验概率密度可以通过多目标贝叶斯递推算法得到。

GLMB滤波算法采用带标签的RFS实现多目标状态估计与航迹跟踪,但由于该算法的计算量大,使得算法的实时性难以提高。

## 2 广义标签多伯努利滤波

多目标跟踪的核心就是通过贝叶斯公式递推目标状态的后验概率密度,但在贝叶斯递推公式中存在复杂的积分运算,使得后验概率密度函数递推运算难以实现。广义标签多伯努利RFS的后验概率密度在贝叶斯递推过程中能保持相同的形式,从而能够避免积分求解<sup>[3]</sup>。广义标签多伯努利RFS的概率密度可以表示为如下形式

$$\pi(X) = \Delta(X) \sum_{h \in \mathbf{H}} \omega_h(\varphi(X)) \prod_{(\mathbf{x}, l) \in X} p_h(\mathbf{x}, l) \quad (1)$$

$$\Delta(X) = \begin{cases} 1, & \text{card}(X) = \text{card}(\varphi(X)) \\ 0, & \text{card}(X) \neq \text{card}(\varphi(X)) \end{cases} \quad (2)$$

式中: $\mathbf{H}$ 为索引空间; $h$ 为索引; $\omega_h(\cdot)$ 为权值函数; $p_h(\mathbf{x}, l)$ 是索引为 $h$ 时目标的概率密度;函数 $\varphi(\cdot)$ 表示映射, $\varphi(X)$ 为 $X$ 对应的标签值集合; $\Delta(X) = 1$ 表示集合 $X$ 中各元素的标签互异; $\text{card}(X)$ 表示求集合 $X$ 的势,即元素数量。

设 $k-1$ 时刻的多目标后验概率密度具有式(1)形式,则 $k$ 时刻的预测概率密度为

$$\pi_{k|k-1}(X_k) = \Delta(X_k) \cdot$$

$$\sum_{h \in \mathbf{H}} \omega_{k|k-1,h}(\varphi(X_k)) \prod_{(\mathbf{x}, l) \in X_k} p_{k|k-1,h}(\mathbf{x}, l) \quad (3)$$

式中: $\omega_{k|k-1,h}(\cdot)$ 表示索引 $h$ 的预测权值函数; $p_{k|k-1,h}(\mathbf{x}, l)$ 表示索引为 $h$ 时,目标 $(\mathbf{x}, l)$ 的预测概率密度。

若 $(\mathbf{x}, l)$ 为存活目标,则 $p_{k|k-1,h}(\mathbf{x}, l)$ 的计算公式为

$$p_{k|k-1,h}(\mathbf{x}, l) = \frac{\int p_s(\mathbf{x}', l) f(\mathbf{x} | \mathbf{x}', l) p_{k-1,h}(\mathbf{x}', l) d\mathbf{x}'}{\int p_s(\mathbf{x}', l) p_{k-1,h}(\mathbf{x}', l) d\mathbf{x}'} \quad (4)$$

式中: $p_s(\mathbf{x}', l)$ 为存活概率; $f(\mathbf{x} | \mathbf{x}', l)$ 为转移密度。

若 $(\mathbf{x}, l)$ 为新生目标,则 $p_{k|k-1,h}(\mathbf{x}, l) = p_\Gamma(\mathbf{x}, l)$ ,  $p_\Gamma(\mathbf{x}, l)$ 为新生目标概率密度。

设 $k$ 时刻的量测集为 $Z = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_M\}$ ,  $M$ 为量测个数,则 $k$ 时刻的多目标后验概率密度为

$$\pi_k(X_k | Z) = \Delta(X_k) \cdot$$

$$\sum_{h \in H} \sum_{\theta \in \Theta} \omega_{k,h,\theta}(\varphi(K_k)) \prod_{(\mathbf{x}, l) \in X_k} p_{k,h,\theta}(\mathbf{x}, l | Z) \quad (5)$$

$$p_{k,h,\theta}(\mathbf{x}, l | Z) = \frac{p_{k|k-1,h}(\mathbf{x}, l) \psi(\mathbf{x}, l; \theta)}{\int p_{k|k-1,h}(\mathbf{x}', l) \psi(\mathbf{x}', l; \theta) d\mathbf{x}'} \quad (6)$$

$$\psi(\mathbf{x}, l; \theta) = \begin{cases} \frac{p_D(\mathbf{x}, l) g(\mathbf{z}_{\theta(l)} | \mathbf{x}, l)}{\kappa(\mathbf{z}_{\theta(l)})}, & \theta(l) > 0 \\ 1 - p_D(\mathbf{x}, l), & \theta(l) = 0 \end{cases} \quad (7)$$

式中: $\theta$ 定义了一个映射, $\theta: \mathbf{L} \rightarrow \{0, 1, \dots, M\}$ 描述了标签空间 $\mathbf{L}$ 中的标签与量测的对应关系; $\Theta$ 为映射空间; $\omega_{k,h,\theta}(\cdot)$ 表示更新后的权值函数; $\psi(\mathbf{x}, l; \theta)$ 为似然函数, $p_D(\mathbf{x}, l)$ 为检测概率, $g(\mathbf{z}_{\theta(l)} | \mathbf{x}, l)$ 表示量测 $\mathbf{z}_{\theta(l)}$ 是由目标 $(\mathbf{x}, l)$ 产生的似然函数; $\kappa(\mathbf{z}_{\theta(l)})$ 为杂波密度函数。

文献[4]指出,广义标签多伯努利 RFS 的概率密度可以由参数集 $\{(L_h, \omega_h, p_h(\mathbf{x}, l))\}_{h=1}^H$ 描述,其中 $L_h$ 表示索引为 $h$ 时目标标签的集合, $H$ 为索引总数量。

序列蒙特卡罗算法(SMC)的本质是用一组狄拉克分布 $\delta$ 来近似目标状态的概率密度,目标状态概率密度的计算公式为

$$p(\mathbf{x}) = \sum_{i=1}^N \omega_i \delta_{x_i}(\mathbf{x}) \quad (8)$$

式中: $p(\mathbf{x})$ 表示目标状态的概率密度; $N$ 为狄拉克分布的数量; $\omega_i$ 为第 $i$ 个狄拉克分布的权值。

SMC-GLMB 算法的关键步骤是用一组带权值的狄拉克分布 $\delta$ 近似 GLMB 中的单目标概率密度 $p_h(\mathbf{x}, l)$ 。SMC-GLMB 算法的详细步骤见文献[4]。SMC-GLMB 算法需要大狄拉克分布量运算,这加剧了 SMC-GLMB 算法计算复杂度高的问题。

### 3 箱粒子广义标签多伯努利滤波

#### 3.1 箱粒子滤波

箱粒子滤波基于区间分析方法,区间分析是用区间变量代替点变量的数学运算<sup>[12]</sup>。在区间分析中,一维闭合区间变量定义为

$$[x] = [x_{\min}, x_{\max}] = \{x \in \mathbf{R} \mid x_{\min} \leq x \leq x_{\max}\} \quad (9)$$

式中: $x_{\min}$ 为变量 $x$ 的最小值; $x_{\max}$ 为变量 $x$ 的最大值。式(9)表明,变量 $x$ 取 $[x_{\min}, x_{\max}]$ 中任意一个值的概率相同,即变量 $x$ 取值服从均匀分布。 $n$ 维闭合区间变量定义为 $[\mathbf{x}] = [x_1] \times [x_2] \times \dots \times [x_n]$ ,这个多维区间变量称作一个箱粒子。

由于箱粒子可以看作均匀概率密度函数的支撑集,所以箱粒子滤波是用一组加权的均匀分布拟合后验概率密度函数。目标状态 $\mathbf{x}$ 的概率密度函数可表示为<sup>[5]</sup>

$$p(\mathbf{x}) = \sum_{i=1}^N \omega_i U_{[x_i]}(\mathbf{x}) \quad (10)$$

式中: $U_{[x]}$ 表示箱粒子 $[\mathbf{x}]$ 作为支撑集的均匀分布函数。该式表明随机变量 $\mathbf{x}$ 的概率密度可由一组带权值的箱粒子集 $\{(\omega_i, [\mathbf{x}_i])\}_{i=1}^N$ 表示。

区间收缩<sup>[7]</sup>是箱粒子滤波算法的关键步骤,区间收缩通过解决约束满足问题实现。约束满足问题的解集为

$$S = \{\mathbf{x} \in [\mathbf{x}] \mid f(\mathbf{x}) = \mathbf{0}\} \quad (11)$$

式中: $\mathbf{f} = [f_1, f_2, \dots, f_n]^T$ ;  $\mathbf{x} = [x_1, x_2, \dots, x_n]$ 。约束满足问题就是要找到一个最小体积的 $[\mathbf{x}]'$ ,这个 $[\mathbf{x}]'$ 包含 $[\mathbf{x}]$ 中所有 $\mathbf{x}$ 且满足 $f(\mathbf{x}) = \mathbf{0}$ ,即 $S \subseteq [\mathbf{x}]' \subseteq [\mathbf{x}]$ ,区间收缩就是用 $[\mathbf{x}]'$ 代替 $[\mathbf{x}]$ 。

#### 3.2 广义标签多伯努利的箱粒子实现

本文利用箱粒子对概率密度函数近似,得到箱粒子广义标签多伯努利滤波算法,其递推步骤如下。

(1)预测。假设 $k-1$ 时刻多目标概率密度的参数集为 $\{(L_{k-1,h}, \omega_{k-1,h}, p_{k-1,h}(\mathbf{x}, l))\}_{h=1}^{H_{k-1}}$ ,其中 $p_{k-1,h}(\mathbf{x}, l)$ 由一组带权值的箱粒子 $\{(\omega_{k-1,i}, [\mathbf{x}_{k-1,i}])\}_{i=1}^{N(l)}$ 表示,即

$$p_{k-1,h}(\mathbf{x}, l) = \sum_{i=1}^{N(l)} \omega_{k-1,i} U_{[\mathbf{x}_{k-1,i}]}(\mathbf{x}) \quad (12)$$

式中: $N(l)$ 表示目标 $(\mathbf{x}, l)$ 的箱粒子数量。此时, $k$ 时刻的预测概率密度参数集为 $\{(L_{k|k-1,h}, \omega_{k|k-1,h}, p_{k|k-1,h}(\mathbf{x}, l))\}_{h=1}^{H_{k|k-1}}$ 。预测标签集 $L_{k|k-1,h}$ 、预测权值 $\omega_{k|k-1,h}$ 以及分量总数 $H_{k|k-1}$ 的计算公式均与文献[4]中相同。 $p_{k|k-1,h}(\mathbf{x}, l)$ 的计算通过箱粒子滤波

实现。当目标 $(\mathbf{x}, l)$ 为存活目标时,预测概率密度函数为

$$p_{k|k-1,h}(\mathbf{x}, l) = \sum_{i=1}^{N(l)} p_s(\mathbf{x}, l) \omega_{k-1,i} U_{[\mathbf{x}_{k|k-1,i}]}(\mathbf{x}) \quad (13)$$

$$[\mathbf{x}_{k|k-1,i}] = [f][\mathbf{x}_{k-1,i}] + [\mathbf{v}], i=1, \dots, l \quad (14)$$

式中: $[f]$ 表示状态转移函数 $f$ 的包含函数<sup>[5,8]</sup>;  $[\mathbf{v}]$ 表示过程噪声的区间。当目标 $(\mathbf{x}, l)$ 为新生目标时,预测概率密度函数为

$$p_{k|k-1,h}(\mathbf{x}, l) = \sum_{i=1}^{N_{\Gamma}(l)} \omega_{\Gamma,i} U_{[\mathbf{x}_{\Gamma,i}]}(\mathbf{x}) \quad (15)$$

式中: $N_{\Gamma}(l)$ 为新生目标箱粒子数; $\omega_{\Gamma,i} = 1/N_{\Gamma}(l)$ 为新生目标箱粒子的权值; $[\mathbf{x}_{\Gamma,i}]$ 为新生目标箱粒子的状态。

(2)更新。假设 $k$ 时刻的量测集为 $Z = \{[\mathbf{z}_1], [\mathbf{z}_2], \dots, [\mathbf{z}_M]\}$ ,其中 $[\mathbf{z}_i]$ 表示第 $i$ 个量测值,该量测值为一个多维区间,并非传统的点量测值,则 $k$ 时刻的多目标后验概率密度参数集为 $\{(L_{k,h}, \omega_{k,h}, p_{k,h}(\mathbf{x}, l|Z))\}_{h=1}^{H_k}$ 。若 $p_{k|k-1,h}(\mathbf{x}, l)$ 由一组带权值的箱粒子集 $\{(\omega_{k|k-1,i}, [\mathbf{x}_{k|k-1,i}])\}_{i=1}^{N(l)}$ 表示,则目标 $(\mathbf{x}, l)$ 的后验概率密度函数为

$$p_{k,h}(\mathbf{x}, l|Z) = \sum_{i=1}^{N(l)} \omega_{k,i} U_{[\mathbf{x}_{k,i}]}(\mathbf{x}) \quad (16)$$

$$\omega_{k,i} = \frac{\psi'([\mathbf{x}_{k|k-1,i}], l; \theta(l))}{\sum_{i=1}^{N(l)} \omega_{k|k-1,i} \psi'([\mathbf{x}_{k|k-1,i}], l; \theta(l))} \omega_{k|k-1,i} \quad (17)$$

$$\psi'([\mathbf{x}_{k|k-1,i}], l; \theta(l)) = \begin{cases} \frac{p_D(\mathbf{x}, l) g'([\mathbf{z}_{\theta(l)}] | [\mathbf{x}_{k|k-1,i}], l)}{\kappa([\mathbf{z}_{\theta(l)}])}, & \theta(l) > 0 \\ 1 - p_D(\mathbf{x}, l), & \theta(l) = 0 \end{cases} \quad (18)$$

$$g'([\mathbf{z}_{\theta(l)}] | [\mathbf{x}_{k|k-1,i}], l) = \prod_{j=1}^n \frac{|[\mathbf{x}_{k,i}(j)]|}{|[\mathbf{x}_{k|k-1,i}(j)]|} \quad (19)$$

式中: $n$ 为箱粒子状态维数; $[\mathbf{x}_{k,i}(j)]$ 表示取 $n$ 维区间 $[\mathbf{x}_{k,i}]$ 的第 $j$ 维; $|[\mathbf{x}_{k,i}(j)]|$ 表示一维区间 $[\mathbf{x}_{k,i}(j)]$ 的长度; $[\mathbf{x}_{k,i}]$ 由 $[\mathbf{x}_{k|k-1,i}]$ 经过区间收缩步骤得到<sup>[5,8]</sup>,当 $[\mathbf{z}_{\theta(l)}] \cap [h]([\mathbf{x}_{k|k-1,i}]) + [\mathbf{w}] \neq \emptyset$ 时,需要将 $[\mathbf{x}_{k|k-1,i}]$ 收缩为 $[\mathbf{x}_{k,i}]$ ,其中 $[h]$ 是量测函数 $h$ 的包含函数, $\mathbf{w}$ 为量测噪声的区间,当 $[\mathbf{z}_{\theta(l)}] \cap [h]([\mathbf{x}_{k|k-1,i}]) + [\mathbf{w}] \neq \emptyset$ 时, $[\mathbf{x}_{k,i}] = [\mathbf{x}_{k|k-1,i}]$ ,但 $g'([\mathbf{z}_{\theta(l)}] | [\mathbf{x}_{k|k-1,i}], l) = 0$ ,即箱粒子权值 $\omega_{k,i} = 0$ 。通过收缩步骤可以使箱粒子保持合适的体积,提高滤波精度<sup>[5,8]</sup>。 $p_{k,h}(\mathbf{x}, l|Z)$ 由箱

粒子集 $\{(\omega_{k,i}, [\mathbf{x}_{k,i}])\}_{i=1}^{N(l)}$ 表示,参数集中其他参数更新计算参见文献[4]。

(3)箱粒子重采样。在箱粒子滤波算法中,箱粒子退化问题同样存在,因此重采样步骤必不可少。箱粒子滤波重采样首先按照箱粒子的权值计算采样次数,由于箱粒子数量较少,因此不同于粒子滤波重采样,箱粒子不能直接复制权值大的箱粒子,否则箱粒子将会快速退化。箱粒子重采样采用随机子划分策略<sup>[5]</sup>,根据得到的状态箱粒子重采样的次数 $m$ ,以相同的概率选取状态的一个维度,将箱粒子划分为 $m$ 个相等大小的子区间。

(4)目标数估计。 $k$ 时刻的势分布如下

$$\rho_k(n) = \sum_{h=1}^{H_k} \omega_{k,h} \delta_n(\text{card}(L_{k,h})), n = 0, \dots, N_{\max} \quad (20)$$

目标数估计采用最大后验(MAP)估计准则

$$\hat{N}_k = \arg \max \rho_k(n) \quad (21)$$

(5)目标状态估计与航迹估计。目标状态估计公式如下

$$\hat{h} = \arg \max \omega_{k,h} \delta_{N_k}(\text{card}(L_{k,h})) \quad (22)$$

$$\hat{\mathbf{x}}_j = \sum_{i=1}^{N(l)} \omega_{k,i} \text{mid}([\mathbf{x}_{k,i}]), j = 1, \dots, \hat{N}_k \quad (23)$$

式中: $\text{mid}(\cdot)$ 表示取区间中心值函数; $\hat{\mathbf{x}}_j$ 为单目标的状态估计值,则估计的目标集为 $\hat{X} = \{(\hat{\mathbf{x}}_j, l_j)\}_{j=1}^{\hat{N}_k}$ ,  $l_j$ 为 $\hat{\mathbf{x}}_j$ 的标签,根据目标的标签能够估计出目标的航迹。

## 4 仿真结果与分析

本节对本文算法进行 MATLAB 仿真实验,实验环境为 i3-2120 3.3 GHz CPU, 4 GB RAM, MATLAB 2011。实验比较了 SMC-GLMB 与 Box-GLMB 在相同的场景下对多目标跟踪的性能。

监控区域 $[100 \text{ m}, 500 \text{ m}] \times [200 \text{ m}, 200 \text{ m}]$ 内有4个目标,目标的状态为 $[x, \dot{x}, y, \dot{y}]^T$ ,其中 $(x, y)$ 表示目标的位置, $(\dot{x}, \dot{y})$ 为目标的速度。目标的初始状态分别为 $[392 \text{ m}, -7 \text{ m/s}, 145 \text{ m}, -4 \text{ m/s}]^T$ 、 $[50 \text{ m}, 10 \text{ m/s}, 120 \text{ m}, -3 \text{ m/s}]^T$ 、 $[0 \text{ m}, 13 \text{ m/s}, 80 \text{ m}, -3.3 \text{ m/s}]^T$ 、 $[200 \text{ m}, 10 \text{ m/s}, -50 \text{ m}, 0 \text{ m/s}]^T$ ,存活时间分别为 $1 \sim 50 \text{ s}$ 、 $10 \sim 24 \text{ s}$ 、 $14 \sim 34 \text{ s}$ 、 $20 \sim 38 \text{ s}$ 。新生目标随机集可用标签伯努利参数集 $\pi_{\Gamma} = \{r_{\Gamma}^{(i)}, p_{\Gamma}^{(i)}\}_{i=1}^3$ 表示,其中新生目标的概率为 $r_{\Gamma}^{(i)} = 0.02$ ,新生目标的概率密度服从高斯分布 $p_{\Gamma}^{(i)} = N(\mathbf{x}; \mathbf{m}_{\Gamma}^{(i)}, \mathbf{P}_{\Gamma})$ ,其中3个新生目标初始状态为 $\mathbf{m}_{\Gamma}^{(1)} = [50 \text{ m}, 0 \text{ m/s}, 120 \text{ m}, 0 \text{ m/s}]^T$ 、 $\mathbf{m}_{\Gamma}^{(2)} = [0 \text{ m}, 0 \text{ m/}$

$s, 80 \text{ m}, 0 \text{ m/s}]^T, \mathbf{m}_r^{(3)} = [200 \text{ m}, 0 \text{ m/s}, -50 \text{ m}, 0 \text{ m/s}]^T$ , 方差为  $\mathbf{P}_r = \text{diag}([100 \text{ m}^2, 25 (\text{m/s})^2, 100 \text{ m}^2, 25 (\text{m/s})^2])$ 。目标的状态方程和量测方程分别为

$$\mathbf{x}_k = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{x}_{k-1} + \begin{bmatrix} \frac{T^2}{2} & T & 0 & 0 \\ 0 & 0 & \frac{T^2}{2} & T \end{bmatrix}^T \mathbf{v}_k \quad (24)$$

$$\mathbf{z}_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \mathbf{x}_k + \mathbf{w}_k \quad (25)$$

式中:  $T=1 \text{ s}$  为采样周期;  $\mathbf{v}_k$  为过程噪声;  $\mathbf{w}_k$  为量测噪声。过程噪声方差和量测噪声方差分别为  $\mathbf{Q} = \text{diag}([1.5^2, 1.5^2]) \text{ m}^2$  和  $\mathbf{R} = \text{diag}([1.5^2, 1.5^2]) \text{ m}^2$ 。

实验中两种算法使用的量测均采用区间形式, 区间长度为  $11 \text{ m}$ , SMC-GLMB 似然函数计算采用了广义似然函数<sup>[1]</sup>。杂波数服从参数均值为 2 的泊松分布, 杂波在监控区域内均匀分布。目标存活概率和检测概率均为 0.98。本文进行了 100 次蒙特卡罗仿真实验, 实验结果如图 1~3 所示。

图 1 给出了目标运动的真实轨迹与区间量测对比。图 2 给出了本文算法在  $x$  轴和  $y$  轴方向上的跟踪效果。从图 2 中可以看出, Box-GLMB 算法能够有效跟踪目标航迹。




图 1 目标运行的真实轨迹与区间量测

图 3 给出了 SMC-GLMB 算法与 Box-GLMB 算法对目标数量的估计。可以看出, 两种算法对目标数量的估计均较为准确, 仅在目标数量减少的时刻估计出现偏差, 但随着算法运行, 能够很快调整估计值。

本文采用航迹最优次模型分配 (OSPAT) 距离<sup>[13]</sup>来对跟踪性能进行评价。该评价指标基于最优次模型分配 (OSPA) 距离, 能同时反映目标状态




图 2 本文 Box-GLMB 算法对目标状态估计与目标航迹跟踪效果




图 3 两种算法的目标数估计与真实值比较

估计与航迹估计的性能。即对于任意两个带标签的集合  $X = \{(\mathbf{x}_1, l_1), \dots, (\mathbf{x}_m, l_m)\}$  和  $Y = \{(\mathbf{y}_1, s_1), \dots, (\mathbf{y}_n, s_n)\}$  (其中  $l$  与  $s$  分别为两集合中元素的标签), 目标的 OSPAT 距离为

$$D_{\text{OSPAT}} = \left[ \frac{1}{n} \min_{\pi \in \Pi_n} \sum_{i=1}^m \tilde{d}^{(c,a)}(\mathbf{x}_i, \mathbf{y}_{\pi(i)}) + (n-m)c^p \right]^{1/p} \quad (26)$$

式中

$$\tilde{d}^{(c,a)}(\mathbf{x}_i, \mathbf{y}_{\pi(i)}) = d^{(c)}(\mathbf{x}_i, \mathbf{y}_{\pi(i)})^p + d^{(a)}(l_i, s_{\pi(i)})^p \quad (27)$$

$$d^{(c)}(\mathbf{x}_i, \mathbf{y}_{\pi(i)}) = \min(c, \|\mathbf{x}_i - \mathbf{y}_{\pi(i)}\|) \quad (28)$$

$$d^{(a)}(l_i, s_{\pi(i)}) = \begin{cases} \alpha, & l_i \neq s_{\pi(i)} \\ 0, & l_i = s_{\pi(i)} \end{cases} \quad (29)$$

其中,  $\Pi_n$  表示集合  $\{1, 2, \dots, n\}$  的全部排列,  $\pi(i)$  表示其中第  $i$  种排列方式,  $c$  为截断距离,  $p$  为距离敏感性参数,  $\alpha$  为航迹匹配错误惩罚因子。本文实验中  $c=300 \text{ m}$ ,  $p=1$ ,  $\alpha=100 \text{ m}$ 。

图 4 给出了两种算法的 OSPAT 距离。由图 4 可以看出: Box-GLMB 算法与 SMC-GLMB 算法均能较好跟踪目标状态与航迹, 两种算法的估计精度相当; 在目标消失时刻, 两种算法的 OSPAT 距离均增大, 其余时刻 Box-GLMB 算法的精度与 SMC-GLMB 算法相似或略低于 SMC-GLMB 算法。




图 4 两种算法的 OSPAT 距离

表 1 给出了两种算法所需粒子数与运行时间。由表 1 可以看出:SMC-GLMB 算法需要 1 050 个粒子,运行时间为 182.71 s;Box-GLMB 算法所需要的箱粒子数仅为 42 个,运行时间为 68.70 s;与 SMC-GLMB 算法相比,Box-GLMB 算法所需运行时间缩短了 62.4%。

表 1 两种算法的运行时间与所需粒子数

| 算法       | 持续粒子数 | 新生粒子数 | 运行时间/s |
|----------|-------|-------|--------|
| SMC-GLMB | 1 000 | 50    | 182.71 |
| Box-GLMB | 40    | 2     | 68.70  |

综上所述,本文所提出的 Box-GLMB 算法可以有效估计目标状态、目标数,同时跟踪多目标航迹,相比于 SMC-GLMB 算法,可以降低计算复杂度,提高算法运算效率,更有利于实时跟踪。

5 结 语

本文采用箱粒子滤波算法实现广义标签多伯努利滤波算法,提出 Box-GLMB 滤波,并给出了算法的计算步骤。仿真实验表明,本文算法能够实现对数目变化的多目标状态的精确估计,并且能够精确跟踪不同目标的航迹;相比与 SMC-GLMB 算法,提高了运算效率,更具实时性。

参考文献:

[1] MAHLER R. Statistical multisource multitarget information fusion [M]. Norwood, MA, USA: Artech House, 2007: 539-682.

[2] 张光华, 连峰, 韩崇昭, 等. 高斯混合扩展目标多伯努利滤波器 [J]. 西安交通大学学报, 2014, 48(10): 9-14.

ZHANG Guanghua, LIAN Feng, HAN Chongzhao, et al. A Gaussian mixture extended-target multi-Bernoulli filter [J]. Journal of Xi'an Jiaotong University,

2014, 48(10): 9-14.

[3] VO B T, VO B N. Labeled random finite sets and multi-object conjugate priors [J]. IEEE Transactions on Signal Processing, 2013, 61(13): 3460-3475.

[4] VO B N, VO B T, PHUNG D. Labeled random finite sets and the Bayes multi-target tracking filter [J]. IEEE Transactions on Signal Processing, 2014, 62(24): 6554-6567.

[5] ABDALAH F, GNING A, BONNIFAIT P. Box particle filtering for nonlinear state estimation using interval analysis [J]. Automatica, 2008, 44(3): 807-815.

[6] JAULIN L. Applied interval analysis [M]. Berlin, Germany: Springer, 2001: 11-43.

[7] ANDREW M. Applied interval analysis: with examples in parameter and state estimation, robust control and robotics [J]. Kybernetes, 2002, 31(5): 117-23.

[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 Transactions on Signal Processing, 2012, 60(5): 2138-2151.

[9] SCHIKOR M, GNING A, MIHAYLOVA L, et al. Box-particle probability hypothesis density filtering [J]. IEEE Transactions on Aerospace and Electronic Systems, 2014, 50(3): 1660-1672.

[10] SONG L, LIANG M, JI H. Box-particle implementation and comparison of cardinalized probability hypothesis density filter [J]. Radioengineering, 2016, 25(1): 177-186

[11] 邱昊, 黄高明, 左炜, 等. 基于标签多伯努利滤波的衍生目标跟踪算法 [J]. 航空学报, 2015, 36(9): 3012-3019.

QIU Hao, HUANG Gaoming, ZUO Wei, et al. Spawned target tracking algorithm based on labeled multi-Bernoulli filtering [J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(9): 3012-3019.

[12] 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): 37-44.

ZHAO Xuegang, SONG Liping, JI Hongbing. Interacting multiple model box particle filter with quantitative measurements [J]. Journal of Xidian University, 2014, 41(6): 37-44.

[13] RISTIC B, VO B N, CLARK D, VO B T. A metric for performance evaluation of multi-target tracking algorithms [J]. IEEE Transactions on Signal Processing, 2011, 59(7): 3452-3457.

(编辑 刘杨)