

基于箱粒子滤波的混合标签多伯努利跟踪算法

冯新喜, 迟珞珈[†], 王 泉, 苗 露

(空军工程大学 信息与导航学院, 西安 710077)

摘 要: 针对标签多伯努利滤波器在目标处于近邻或目标量测与轨迹关联模糊情况下, 更新步中由于近似产生信息丢失, 导致跟踪效果下降的问题, 引入区间分析技术, 结合标签多伯努利滤波器及广义标签多伯努利滤波器各自的优势, 提出一种箱粒子滤波下的混合标签多伯努利跟踪算法. 建立两种滤波器的参数模型, 通过 Kullback Leibler 散度和熵两项评定标准在两种滤波器间进行切换, 在特殊环境中使用广义标签多伯努利滤波器提高跟踪性能, 在其他环境中使用标签多伯努利滤波器近似降低算法的复杂度, 提高运算效率; 同时基于箱粒子滤波实现混合标签多伯努利算法. 仿真实验表明, 在特定环境中, 与原有滤波算法相比, 所提出的改进算法在保证计算效率的同时, 可提高跟踪的精确度及稳定性.

关键词: 区间分析; 随机有限集; 标签多伯努利; 广义标签多伯努利; Kullback Leibler 散度; 熵
中图分类号: TP273 **文献标志码:** A

A hybrid labeled multi-Bernoulli tracking algorithm based on box particle filter

FENG Xin-xi, CHI Luo-jia[†], WANG Quan, MIAO Lu

(Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract: In view of the problems that the labeled multi-Bernoulli has a decline tracking effect when the targets are close or track-to-measurement association is ambiguous because of the approximate information loss in update step, the interval analysis technology is introduced. Combined with respective advantages of the generalized labeled multi-Bernoulli (GLMB) and labeled multi-Bernoulli (LMB), a hybrid labeled multi-Bernoulli tracking algorithm based on box particle filter (Box-HLMB) is proposed. The GLMB and LMB parameter sets are established. By switch between the GLMB and LMB based on the Kullback Leibler divergence and entropy evaluation criteria, the GLMB is used in the critical environment to improve the tracking performance, LMB approximation is used in other environment to improve the efficiency of operation. The hybrid labeled multi-Bernoulli algorithm is implemented based on box particle filter. The simulation results show that compared with the GLMB and LMB filtering algorithms, the improved algorithm can ensure the computational efficiency, as well as improving the accuracy and stability of the tracking performance.

Keywords: interval analysis; random finite set; labeled multi-Bernoulli; generalized labeled multi-Bernoulli; Kullback Leibler divergence; entropy

0 引 言

近年来, 基于随机有限集 (random finite set, RFS) 理论^[1] 的滤波方法由于能够很好地避免数据关联产生的组合爆炸问题, 受到国内外学者的广泛关注. 经典的 RFS 滤波算法^[2-5] 仅能估计目标的数量和状态, 无法给出多目标的运动轨迹且在低信噪比环境中跟踪效果较差. 为此, 文献 [6] 结合多假设跟踪思想与标签随机有限集理论提出广义标签多伯努利滤波器 (generalised labeled multi-Bernoulli, GLMB), 并通过序贯蒙特卡洛 (sequential Monte Carlo, SMC) 方法实现

该算法^[7]; 随后, 文献 [8] 通过有效近似 GLMB 更新步骤中的后验概率获得了标签多伯努利滤波器 (labeled multi-Bernoulli, LMB); 文献 [9] 表明, LMB 优于概率密度假设滤波器、势概率密度假设滤波器和多伯努利滤波器等经典 RFS 滤波器, 且在提高算法时效性的同时能达到与 GLMB 相近的滤波精度. 但由于 LMB 假设目标统计独立, 只能表示每条轨迹空间分布的不确定性, 不能处理多模势分布的情况, 在目标处于近邻或目标量测与轨迹关联模糊情况下, LMB 会因更新步中的近似产生信息丢失, 导致跟踪效果下

收稿日期: 2018-05-15; 修回日期: 2018-08-26.

基金项目: 国家自然科学基金项目 (61571458).

[†]通讯作者. E-mail: 592255820@qq.com.

降^[8]. 而GLMB使用多假设表示数据关联的不确定性,能够很好地处理特殊环境下的跟踪问题^[9-11],但却存在计算量大、运行效率低的情况.

本文针对上述问题,综合考虑实际战场环境中对算法时效性及跟踪精度的要求,提出一种基于箱粒子滤波的混合标签多伯努利(box-hybrid labeled multi-Bernoulli, Box-HLMB)跟踪算法. 混合标签多伯努利跟踪算法结合LMB及GLMB各自的优势,通过Kullback Leibler散度和熵两项评定标准进行切换,在特殊环境中使用GLMB算法提高跟踪性能,在其他环境中使用LMB近似降低算法的复杂度,提高运算效率. 同时,基于区间分析技术^[12],采用箱粒子滤波^[13]实现算法,进一步提高算法的运行效率. 在特定环境中,将本文算法与GLMB和LMB滤波算法相比,从而验证本文算法的计算效率、跟踪精确度及稳定性.

1 问题描述

1.1 转换准则

GLMB使用多假设思想表示数据关联的不确定性,LMB仅在独立的空间分布轨迹内表示关联的不确定性,因此在目标处于近邻或杂波环境下由于漏检、虚警导致目标量测和轨迹关联模糊的情况下,GLMB具有更好的跟踪精度;而在一般情况下,LMB则具有更好的运行效率. 混合标签多伯努利跟踪算法结合LMB与GLMB滤波器各自的优点,通过Kullback Leibler散度和熵两种转换准则实现两种滤波算法间的自动切换. 其中,Kullback Leibler散度用来评估LMB由于近似产生的误差,熵用来判定跟踪过程中数据关联的不确定性.

1.1.1 Kullback Leibler散度

文献[14]中,LMB由于近似产生势分布信息的丢失,本文选择通过检查LMB近似与GLMB的后验势分布差异判断LMB由于近似产生信息丢失的大小,并使用Kullback Leibler散度这一指标进行评定. Kullback Leibler散度是一种比较概率分布 P 与 Q 差异的量测指标,其定义如下:

$$D_{\text{KL}}(P\|Q) = \sum_i P(i) \cdot \log \frac{P(i)}{Q(i)}. \quad (1)$$

其中: Q 为 P 的近似,当 $P(i) = 0$ 时,第 i 项为0.

GLMB和LMB各自的后验势分布 $\rho_{\text{GLMB}}(n)$ 和 $\rho_{\text{LMB}}(n)$ 的Kullback Leibler散度 $D_{\text{KL}}(\pi(\mathbf{X}))$ 可定义为

$$D_{\text{KL}}(\pi(\mathbf{X})) = D_{\text{KL}}(\rho_{\text{GLMB}} \parallel \rho_{\text{LMB}}). \quad (2)$$

其中: $\mathbf{X} = \{(\mathbf{x}_1, l_1), (\mathbf{x}_2, l_2), \dots, (\mathbf{x}_n, l_n)\}$ 为多目标状态标签随机有限集, \mathbf{x}_i 为单目标状态, l_i 为目标 \mathbf{x}_i 对应的标签轨迹; $\rho_{\text{GLMB}}(n)$ 和 $\rho_{\text{LMB}}(n)$ 参考文献[6, 8]. 当 $D_{\text{KL}} = 0$ 时,表示 $\rho_{\text{GLMB}}(n)$ 与 $\rho_{\text{LMB}}(n)$ 相同,即LMB近似没有引起势分布信息的丢失;当 $D_{\text{KL}} > 0$ 时,表示 $\rho_{\text{GLMB}}(n)$ 与 $\rho_{\text{LMB}}(n)$ 不同,且当 D_{KL} 较大时,表示LMB具有较大的近似误差,此时应切换为具有更高滤波精度的GLMB滤波器.

1.1.2 熵

在存在较大数据关联不确定性但势分布相同的情况下,Kullback Leibler散度无法检测到特殊环境,因此选择熵这一指标用评定数据关联的不确定性. 熵广泛应用于信息理论中,是一种检测信息不确定性的量测指标,其定义如下:

$$H(P) = - \sum_i P(y_i) \log P(y_i), \quad (3)$$

其中 $P(y_i)$ 为事件 y_i 发生的概率. 显然,当 $P(y_i)$ 较小或较大时,熵 $H(P)$ 较小,这一事实可以用来检测较大的量测与轨迹关联不确定性.

量测与轨迹的关联矩阵如下所示:

$$\mathbf{A} = \begin{bmatrix} r^{(l_1, z_1)} & r^{(l_1, z_2)} & \dots & r^{(l_1, z_m)} \\ r^{(l_2, z_1)} & r^{(l_2, z_2)} & \dots & r^{(l_2, z_m)} \\ \vdots & \vdots & \ddots & \vdots \\ r^{(l_n, z_1)} & r^{(l_n, z_2)} & \dots & r^{(l_n, z_m)} \end{bmatrix}, \quad (4)$$

$$r^{(l_i, z_j)} = \sum_{(I_+, \theta) \in F^{(L_+)} \times \Theta_{I_+}} \omega^{(I_+, \theta)}(\mathbf{Z}) 1_{I_+}(l_i) \delta_{\theta}(l_i)(j). \quad (5)$$

其中: $\mathbf{Z} = \{z_1, z_2, \dots, z_m\}$ 为多目标量测随机有限集, z_i 为单目标量测; $r^{(l_i, z_j)}$ 为轨迹 l_i 与量测 z_j 关联的概率. 一个确定的量测由对应的列向量 \mathbf{a}_j 表示,该列向量由一个 $r^{(l_i, z_j)} \approx 1$,其余 $r^{(l_k, z_j)} \approx 0 (k = 1, 2, \dots, i-1, i+1, \dots, n)$ 组成,致使 $H(\mathbf{a}_j)$ 较小. $\pi(\mathbf{X})$ 的熵可表示为

$$H(\pi(\mathbf{X})) = \sum_{j=1}^m H(\mathbf{a}_j). \quad (6)$$

由以上分析可以看出:当熵 $H(\pi(\mathbf{X}))$ 较小时,表明量测与轨迹关联明确;当熵 $H(\pi(\mathbf{X}))$ 较大时,表明量测与轨迹关联不确定性较大,此时应切换为具有更高滤波精度的GLMB滤波器.

1.2 箱粒子滤波

箱粒子滤波采用区间分析技术^[14],区间分析技术的核心思想是用区间变量代替区间内的点变量,运算时直接对区间变量进行处理. 在区间分析

中, $[x] = [x_{\min}, x_{\max}]$ 表示一维闭合区间变量, x_{\min} 为区间下限, x_{\max} 为区间上限, 变量 x 服从均匀分布. 相应的, $[\mathbf{x}] = [x_1] \times [x_2] \times \dots \times [x_n]$ 表示 n 维闭合区间变量, 称这个 n 维区间变量为一个箱粒子.

在箱粒子滤波中, 随机变量 \mathbf{x} 的后验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, 即采用一组加权的均匀分布来拟合, 其表达式为

$$p(\mathbf{x}) = \sum_{i \in N} \omega_i U_{[\mathbf{x}_i]}(\mathbf{x}). \quad (7)$$

其中: $U_{[\mathbf{x}_i]}$ 为箱粒子 $[\mathbf{x}_i]$ 作为支撑集的均匀分布函数, ω_i 为箱粒子 $[\mathbf{x}_i]$ 对应的权值.

2 混合标签多伯努利滤波算法的箱粒子实现

混合标签多伯努利算法在一般环境中使用 LMB 滤波器对目标进行高效跟踪; 当 Kullback Leibler 散度较大或熵较大时, 则切换到具有更高滤波精度的 GLMB 滤波器. 假设多目标之间统计独立, 混合标签多伯努利算法使用多个独立分布的 LMB 及 GLMB 来表示, 其参数集的表达形式为

$$\pi_{\text{GLMB}}^k = \{(w_k^{(l)}, (p_{G,k}^{(l)(i)})_{i \in n_{G,k}})\}_{l \in L_k}, \quad (8)$$

$$\pi_{\text{LMB}}^k = \{(r_k^{(l)}, (p_{L,k}^{(l)(i)})_{i \in n_{L,k}})\}_{l \in L_k}. \quad (9)$$

其中: 目标状态概率密度 $p_{G,k}^{(l)(i)}(\mathbf{x})$ 和 $p_{L,k}^{(l)(i)}(\mathbf{x})$ 用箱粒子的形式表示为 $p_{G,k}^{(l)(i)}(\mathbf{x}) = \sum_{i \in n_{G,k}} \omega_{G,k}^{(l)(i)} U_{[\mathbf{x}_{G,k}^{(l)(i)}]}(\mathbf{x})$,

$$p_{L,k}^{(l)(i)}(\mathbf{x}) = \sum_{i \in n_{L,k}} \omega_{L,k}^{(l)(i)} U_{[\mathbf{x}_{L,k}^{(l)(i)}]}(\mathbf{x}),$$

$n_{G,k}$ 和 $n_{L,k}$ 分别表示 k 时刻 GLMB 和 LMB 分布的目标箱粒子数目. 基于箱粒子滤波的混合标签多伯努利 (Box-HLMB) 后验概率密度可表示为

$$\pi_{\text{HLMB}}^k = \{\pi_{\text{GLMB}}^k, \pi_{\text{LMB}}^k\}. \quad (10)$$

本文基于区间分析技术, 采用箱粒子滤波对混合标签多伯努利算法进行实现, 进一步提高算法的运行效率, 其递推步骤如下.

2.1 预测

Box-HLMB 使用 GLMB 和 LMB 滤波算法分别对 π_{GLMB}^k 和 π_{LMB}^k 进行预测, π_{GLMB}^k 的预测概率密度分布参数集为

$$\pi_{\text{GLMB}}^{k+1|k}(\mathbf{x}) = \{(w_{k+1|k}^{(l)}, (p_{G,k+1|k}^{(l)(i)})_{i \in n_{G,k+1|k}})\}_{l \in L_{k+1|k}}.$$

GLMB 预测后验概率密度 $p_{G,k+1|k}^{(l)(i)}(\mathbf{x})$ 通过箱粒子实现, 表达式为

$$p_{G,k+1|k}^{(l)(i)}(\mathbf{x}) = 1_L(l_+) \sum_{i \in n_{G,k}} p_s^{(l)}(\mathbf{x}) \omega_{G,k}^{(l)(i)} U_{[\mathbf{x}_{[G,k+1|k]}^{(l)(i)}]}(\mathbf{x}) +$$

$$(l_+) \sum_{i \in n_{B,k+1}^{(l)(i)}} \omega_{B,k+1}^{(l)(i)} U_{[\mathbf{x}_{B,i}]}(\mathbf{x}). \quad (11)$$

π_{LMB}^k 的预测概率密度分布参数集为

$$\pi_{\text{LMB}}^{k+1|k}(\mathbf{x}) = \{(r_{L,k+1|k}^{(l)}, (\omega_{L,k+1|k}^{(l)(i)}, [\mathbf{x}_{L,k+1|k}^{(l)(i)}])_{i \in n_{L,k}})\}_{l \in L_k} \cup \{(r_{B,k+1}^{(l)}, (\omega_{B,k+1}^{(l)(i)}, [\mathbf{x}_{B,k+1}^{(l)(i)}])_{i \in n_{B,k+1}^{(l)(i)}})\}_{l \in B_{k+1}}. \quad (12)$$

其中: $[\mathbf{x}_{k+1|k}^{(l)(i)}] = [f][\mathbf{x}_k^{(l)(i)}] + [\mathbf{v}]$, $i = 1, 2, \dots, l$, $[f]$ 为状态转移函数 f 的包含函数^[15]. 其他参数的计算参见文献[7-8].

2.2 更新

在 Box-HLMB 更新步中, 算法使用 GLMB 或者 LMB 进行更新. 当采用 GLMB 对 Box-HLMB 进行更新时, 假设经 2.1 节预测后的分布参数集为 $\pi_{\text{HLMB}}^{k+1|k} = \{(w_{k+1|k}^{(l)}, (p_{k+1|k}^{(l)(i)})_{i \in n_{k+1|k}})\}_{l \in L_{k+1|k}}$, 其中 $p_{k+1|k}^{(l)(i)}$ 由一组带权值的箱粒子集 $(\omega_{k+1|k}^{(l)(i)}, [\mathbf{x}_{k+1|k}^{(l)(i)}])_{i \in n_{k+1|k}}$ 表示. $k+1$ 时刻的 Box-HLMB 分布可以表示为 $\pi(\mathbf{X}) = \{(w_{k+1}^{(l)}, (p_{k+1}^{(l)}))\}_{l \in L_{k+1}}$, 其中参数 $w_{k+1}^{(l)}$ 的更新参见文献[7], 后验概率密度函数 $p_{k+1}^{(l)}$ 的箱粒子更新表达式为

$$p_{k+1}^{(l)}(\mathbf{x}|\mathbf{Z}) = \sum_{i=1}^{n_{k+1}} \omega_{k+1}^{(i)} U_{[\mathbf{x}_{k+1}^{(i)}]}(\mathbf{x}). \quad (13)$$

其中

$$\omega_{k+1}^{(i)} = \frac{\psi'([\mathbf{x}_{k+1|k}^{(i)}]; \theta(l))}{N(l)} \omega_{k+1|k}^{(i)} \frac{\psi'([\mathbf{x}_{k+1|k}^{(i)}]; \theta(l))}{\sum_{i=1}^{n_{k+1|k}} \omega_{k+1|k}^{(i)} \psi'([\mathbf{x}_{k+1|k}^{(i)}]; \theta(l))}. \quad (14)$$

$$\psi'([\mathbf{x}_{k+1|k}^{(i)}]; \theta(l)) = \begin{cases} \frac{p_D^{(l)}(\mathbf{x}) g'([\mathbf{z}_{\theta(l)}] | [\mathbf{x}_{k+1|k}^{(i)}])}{\kappa[\mathbf{z}_{\theta(l)}]}, & \theta(l) > 0; \\ 1 - p_D^{(l)}(\mathbf{x}), & \theta(l) = 0. \end{cases} \quad (15)$$

$$g'([\mathbf{z}_{\theta(l)}] | [\mathbf{x}_{k+1|k}^{(i)}]) = \prod_{j=1}^n \frac{|[\mathbf{x}_{k+1}^{(i)}(j)]|}{|[\mathbf{x}_{k+1|k}^{(i)}(j)]|}. \quad (16)$$

当采用 LMB 对 Box-HLMB 进行更新时, 由于 LMB 不具有共轭先验, 无法直接完成多目标贝叶斯滤波器的量测更新, 首先需要将预测的 LMB 转化为相应的 GLMB 形式, 之后采用 GLMB 进行更新, 最后为了得到 LMB 的递归形式, 更新后使用 LMB 分布 $\tilde{\pi}(\mathbf{X})$ 近似 GLMB $\pi(\mathbf{X})$, 即 $\pi(\mathbf{X}) \approx \tilde{\pi}(\mathbf{X}) = \{(r_{k+1}^{(l)}, (p_{k+1}^{(l)}))\}_{l \in L_{k+1}}$, 此时需要保留 LMB 近似前的 GLMB 参数 $\pi(\mathbf{X})$, 为后续计算做准备. LMB 的更新

参数通过GLMB更新参数近似表示为

$$r_{k+1}^{(l)} = \sum_{(I_+, \theta) \in (F(L_+) \times \Theta_{I_+})} w^{(I_+, \theta)}(Z) 1_{I_+}(l), \quad (17)$$

$$p_{k+1}^{(l)} = \frac{1}{r_{k+1}^{(l)}} \sum_{(I_+, \theta) \in (F(L_+) \times \Theta_{I_+})} w^{(I_+, \theta)}(Z) 1_{I_+}(l) \times p^{(\theta)}(x, l|Z). \quad (18)$$

更新完成后,根据1.1节的转换准则,通过Kullback Leibler散度表达式(2)检验LMB近似分布 $\hat{\pi}(\mathbf{X})$ 与GLMB分布 $\pi(\mathbf{X})$ 的差异,判断是否存在信息损失,同时使用熵表达式(6)判断是否存在较大的量测与轨迹关联不确定性.当Kullback Leibler散度较大或熵较大时,表示LMB具有较大的近似误差或量测与轨迹关联不确定性较大,此时在更新步中,用GLMB更新代替LMB更新,即不进行LMB的近似,并使用GLMB的更新参数进行下一时刻的循环.如果采用GLMB进行更新,则在下一个时刻,依据相应的转换准则,判断周围环境是否恢复正常.如果是由于信息丢失导致的转换,则选择Kullback Leibler散度进行检查;如果是由于信息关联模糊导致的转换,则选择熵进行检查.只要Kullback Leibler散度或熵降到门限之下,则表示环境恢复正常,将GLMB重新转换为LMB滤波器.虽然在滤波更新的每一时刻都要进行Kullback Leibler散度和熵的计算,但是两个准则使用的计算变量均为原算法中含有的量,且只进行了简单的四则运算,因此不会影响算法的计算复杂度.

2.3 多目标状态提取

目标数目 $|\hat{\mathbf{X}}_{k+1}|$ 及目标状态 $\hat{\mathbf{X}}_{k+1}$ 估计如下:

$$|\hat{\mathbf{X}}_{k+1}| = \sum_{l=1}^{|\mathbf{Z}_{k+1}|} r_{k+1}^{(l)}, \quad (19)$$

$$\hat{\mathbf{X}}_{k+1} = \{(\hat{\mathbf{x}}_{k+1,j}^{(l)})\}_{j=1}^{|\hat{\mathbf{X}}_{k+1}|}. \quad (20)$$

其中: $\hat{\mathbf{x}}_{k+1,j}^{(l)} = \sum_{i=1}^{N(l)} \omega_{k+1}^{(l)(i)} \text{mid}([\mathbf{x}_{k+1}^{(l)(i)}]), j = 1, 2, \dots, |\hat{\mathbf{X}}_{k+1}|$, $\text{mid}(\cdot)$ 取区间中值函数.

3 仿真实验与分析

本文将所提出的Box-HLMB算法与文献[8]中的LMB算法和文献[7]中GLMB算法进行比较分析,对所提出的算法跟踪扩展目标的时效性及跟踪性两方面的性能进行验证.

3.1 实验参数设置

假设仿真环境中最多有5个目标在监测区域 $[-300 \text{ m}, 700 \text{ m}] \times [-600 \text{ m}, 400 \text{ m}]$ 内运动,目标运动

方程和系统量测方程表达式分别为

$$\mathbf{x}_{k+1} = \begin{bmatrix} 1 & \frac{\sin \omega T}{\omega} & 0 & -\frac{1 - \cos \omega T}{\omega} \\ 0 & \cos \omega T & 0 & -\sin \omega T \\ 0 & \frac{1 - \cos \omega T}{\omega} & 1 & \frac{\sin \omega T}{\omega} \\ 0 & \sin \omega T & 0 & \cos \omega T \end{bmatrix} \mathbf{x}_k + \mathbf{v}_k, \quad (21)$$

$$\mathbf{z}_{k+1} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \mathbf{x}_{k+1} + \mathbf{w}_{k+1}. \quad (22)$$

其中: k 时刻目标的运动状态 $\mathbf{x}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]$, $[x_k, y_k]$ 表示目标的位置, $[\dot{x}_k, \dot{y}_k]$ 表示目标的速度;传感器采样间隔 $T = 1 \text{ s}$;转弯速率 $\omega = 3\pi/180 \text{ rad/s}$.过程噪声标准差 $\sigma_v = 2 \text{ m/s}^2$;量测噪声服从正态分布,即 $w_k \sim N(0, Q_w)$,其协方差矩阵 $Q_w = \text{diag}([5^2, 5^2])$;箱粒子区间量测满足 $[\mathbf{z}_{k+1}] = [\mathbf{h}_{k+1}(\mathbf{x}) + \mathbf{v}_{k+1} - 0.5\Delta, \mathbf{h}_{k+1}(\mathbf{x}) + \mathbf{v}_{k+1} + 0.5\Delta]$,区间长度 $\Delta = [15, 25]^T$;在转换准则的参数设置中,参考文献[15],将Kullback Leibler散度和熵的门限值分别设置为 10^{-4} 和0.5;同时在Box-HLMB更新过程中,粒子数随时间不断增多,为了减少计算量,需要将存在概率小于门限值 λ 的假设轨迹删除,本文将轨迹提取的门限设置为 $\lambda = 0.5$.

用标签伯努利参数集 $\{r_B^{(l)(i)}, p_B^{(l)(i)}\}_{i=1}^5$ 表示5个新生目标的随机集,其中新生目标概率 $r_B^{(l)(i)} = 0.05$,概率密度服从高斯分布 $p_B^{(l)(i)} = N(\mathbf{x}; \mathbf{m}_B^{(i)}, \mathbf{P}_B)$.5个新生目标的初始状态分别为 $\mathbf{m}_B^{(1)} = [-200, 10, -100, 0]^T$, $\mathbf{m}_B^{(2)} = [400, 6, -400, 9]^T$, $\mathbf{m}_B^{(3)} = [-100, 9, -200, -6]^T$, $\mathbf{m}_B^{(4)} = [-50, 10, -40, 3]^T$, $\mathbf{m}_B^{(5)} = [-100, 0, 200, -12]^T$, $\mathbf{P}_B = \text{diag}([10, 5, 10, 5]^T)^2$.共进行100次蒙特卡洛实验,目标的存活概率 $P_s = 0.99$,检测概率 $P_D = 0.98$,背景杂波数服从均值为10的泊松分布且均匀分布.监测区域中包含目标的出现和消失,且多目标数目是时变的,其中目标1的运动时间为1~70 s,目标2的运动时间为21~80 s,目标3的运动时间为31~100 s,目标4的运动时间为11~55 s,目标5的运动时间为21~90 s,目标1和目标4在36 s时交叉.本文使用电脑的CPU型号为Inter(R) Core(TM) i53320 M CPU @2.60 GHz,仿真软件版本为Matlab R2013a.

3.2 实验结果与分析

仿真实验结果如图1~图4所示.图1给出了多目标的真实运动轨迹及量测,其中星点表示量测.图2给出了本文Box-HLMB算法与文献[8]中LMB算法

的滤波结果对比.






图1 目标真实运动轨迹和量测



(a) LMB filtering result



(b) HLMB filtering result

图2 滤波结果对比




图3 OSPA 距离对比




图4 运行时间对比

由图1和图2可以看出:当两个目标靠近时,由于量测与轨迹关联模糊,LMB算法错误地转换了两个目标的标签,致使跟踪错误;Box-HLMB在一般环境中使用LMB进行滤波,当转换准则检测到特殊环境时,切换到更为精准的GLMB进行滤波,当转换准则检测到特殊环境消失时,切换回LMB进行滤波,因此可以很好地对两个目标进行跟踪.

图3给出了本文Box-HLMB算法与文献[8]中的LMB算法、文献[7]中的GLMB算法的OSPA距离对比结果.

OSPA^[16]距离既包含目标位置估计误差,也包含目标个数估计误差,其数值越小,代表误差越小,跟踪效果越好.同时,目标的出现和消失都会引起OSPA距离的突增.由图3可以看出,在11s,21s,31s,70s,80s,90s附近出现了OSPA的突增,表明发生了目标的出现和消失.从图3中还可以更加清晰地看出:在一般环境中,由于Box-HLMB采用LMB进行滤波,Box-HLMB与LMB的OSPA值相当,但由于LMB近似,使得OSPA值略大于GLMB;当目标交叉时,Box-HLMB与GLMB的OSPA值远小于LMB,可见Box-HLMB能检测到特殊环境并切换为GLMB进行滤波,而此时LMB由于近似产生大量信息的丢失,同时量测与轨迹关联模糊,导致LMB错误地对目标轨迹进行转换,出现“误跟”的情况;当特殊情况消失时,Box-HLMB切换回更加高效的LMB进行滤波.综上,当目标处于近邻或目标量测与轨迹关联模糊情况时,Box-HLMB与GLMB的滤波效果相当,具有很好的跟踪性能.

图4给出了本文Box-HLMB算法与文献[8]中LMB算法、文献[7]中GLMB算法进行100次蒙特卡洛实验的平均运行时间对比.其中横坐标表示算法更新的时刻,纵坐标表示算法运行的平均时间.

由图4可以看出:LMB由于近似,运行时间相对于GLMB明显缩短;本文Box-HLMB采用箱粒子进行滤波,且以高效LMB为主,仅在特殊环境切换为滤波精度更高的GLMB,因此运行时间最短.综合考虑跟踪效果及时效性两方面性能,Box-HLMB在与GLMB滤波效果相当的情况下,大大缩短了算法的运行时间,具有较好的跟踪精度及时效性.

4 结论

本文结合LMB算法时效性高与GLMB算法跟踪性能好的优点,采用区间分析技术,提出了一种基于箱粒子滤波的混合标签多伯努利跟踪算法.仿

真结果表明,当目标处于近邻或目标量测与轨迹关联模糊时,所提出的改进算法能够根据转换准则在LMB与GLMB间进行切换,具有较好的跟踪性能,且与GLMB算法相比,运行时间更短,提高了运算效率,具有较好的实时性.

参考文献(References)

- [1] Mahler R. Statistical multisource-multitarget information fusion[M]. Norwood: Artech House, 2007: 565-682.
- [2] Vo B N, Ma W. The Gaussian mixture probability hypothesis density filter[J]. IEEE Transactions on Signal Processing, 2006, 54 (11): 4091-4104.
- [3] Mahler R. PHD filters of higher order in target number[J]. IEEE Transactions on Aerospace and Electronic System, 2007, 43(4): 1523-1543.
- [4] Vo B T, Vo B N, Cantonl A. Analytic implementations of the cardinalized probability hypothesis density filter[J]. IEEE Transactions on Signal Processing, 2007, 55(7): 3553-3567.
- [5] Vo B T, Vo B N, Cantonl A. The cardinality balanced multi-target multi-Bernoulli filter and its implementation[J]. IEEE Transactions on Signal Processing, 2009, 57(2): 409-423.
- [6] 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.
- [7] 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.
- [8] Reuter S, Vo B T, Vo B N, et al. The labeled multi-Bernoulli filter[J]. IEEE Transactions on Signal Processing, 2014, 62(12): 3246-3260.
- [9] Reuter S. Multi-object tracking using random finite sets[D]. Ulm: Faculty of Engineering, Computer Science and Psychology, Ulm University, 2014.
- [10] Reuter S, Beardy M, Granstromz K, et al. Tracking extended targets in high clutter using a GGIW-LMB filter[C]. Sensor Data Fusion: Trends, Solutions, Applications. Bonn: IEEE, 2015: 1-6.
- [11] Beard M, Reuter S, Granström K, et al. Multiple extended target tracking with labeled random finite sets[J]. IEEE Transactions on Signal Processing, 2016, 64(7): 1638-1653.
- [12] Andrew M. Applied interval analysis: With examples in parameter and state estimation, robust control and robotics[J]. Kybernetes, 2002, 31(5): 117-123.
- [13] Abdalah F, Gning A, Bonnifait P. Box particle filtering for nonlinear state estimation using interval analysis[J]. Automatic, 2008, 44(3): 807-815.
- [14] 苗雨, 宋骊平, 姬红兵. 箱粒子广义标签多伯努利滤波的目标跟踪算法[J]. 西安交通大学学报, 2017, 51(10): 107-112.
(Miao Y, Song L P, Ji H B. Target tracking method with box-particle generalized labeled multi-bernoulli filtering[J]. Journal of Xi'an Jiaotong University, 2017, 51(10): 107-112.)
- [15] Danzer A, Reuter S, Dietmayer K. The adaptive labeled multi-Bernoulli filter[J]. IEEE Transactions on Signal Processing, 2016, 62(12): 3246-3260.
- [16] Schuhmacher D, Vo B N. A consistent metric for performance evaluation of multi-object filters[J]. IEEE Transactions on Signal Processing, 2008, 56(8): 3447-3457.

作者简介

冯新喜(1962—), 男, 教授, 博士生导师, 从事信息融合与目标跟踪方向等研究, E-mail: fengxinxi2005@aliyun.com;

迟珞珈(1993—), 女, 硕士生, 从事扩展目标跟踪方法的研究, E-mail: 592255820@qq.com;

王泉(1990—), 男, 博士生, 从事目标跟踪方法的研究, E-mail: wangquan628@126.com;

苗露(1994—), 男, 硕士生, 从事扩展目标跟踪方法的研究, E-mail: 1766584727@qq.com.

(责任编辑: 闫妍)