

一种改进的广义标签多伯努利机动扩展目标跟踪算法

冯新喜, 迟珞珈[†], 王 泉, 蒲 磊

(空军工程大学 信息与导航学院, 西安 710077)

摘 要: 针对广义标签多伯努利滤波器 (GLMB) 预测步和更新步分别需要进行剪枝而导致计算量大、运行效率低且只考虑到单个运动模型的问题, 提出一种多模型一步更新广义标签多伯努利机动扩展目标跟踪算法. 首先通过公式推导将预测步与更新步合并, 给出一种新的一步递归表达式; 然后将多模型思想引入到一步递归表达式中, 得到最终的多模型一步更新方程, 同时基于吉布斯采样提出一种快速剪枝方法对其进行剪枝. 由于改进后的滤波算法只涉及到一次剪枝且剪枝方法高效, 算法的运行时间大大缩短; 同时, 由于采用了多模型思想, 对机动目标的跟踪精度有了一定的提高. 仿真实验表明, 所提出的改进算法可以有效估计机动目标状态, 且相比于多模型标签多伯努利滤波器 (MMGLMB) 计算效率明显提高.

关键词: 随机有限集; 标签多伯努利; 多扩展目标跟踪; 机动目标

中图分类号: TN953

文献标志码: A

An improved generalized labeled multi-Bernoulli filter for maneuvering extended target tracking

FENG Xin-xi, CHI Luo-jia[†], WANG Quan, PU Lei

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

Abstract: In view of the problems of large amount of calculation and low efficiency resulted by pruning of generalized labeled multi-Bernoulli (GLMB) prediction and updating steps, as well as deficiency of only taking single motion model into consideration, a model of multiple model one step updating GLMB maneuvering extended target tracking algorithm is proposed. Firstly, by merging prediction step with updating step through formula deduction, a new step recursion expression is proposed. Then, the multiple model algorithm is introduced to one step recursion expression to obtain the final step of update equation, and a quick pruning method is proposed based on Gibbs for sampling. Since the improved algorithm only involves one pruning and the pruning method is efficient, the operation time of the algorithm is greatly shortened. At the same time, the multiple model is used to improve the tracking accuracy of the maneuvering target. Simulation results show that the proposed algorithm can effectively estimate the state of the maneuvering target, and the computational efficiency is significantly improved compared to the MMGLMB filter.

Keywords: random finite set; labeled multi-Bernoulli; multi-extended target tracking; maneuvering target

0 引 言

多目标跟踪技术^[1]涉及联合估计目标数目以及目标运动轨迹的问题, 常用的多目标跟踪方法包括联合概率数据关联 (JPDA)^[2-3]、多假设跟踪 (MHT)^[4]以及最新提出的随机有限集 (RFS)^[5]. 由于 RFS 方法能够较好地避免数据关联产生的组合爆炸问题, 成为当下的研究热点.

近年来, 基于 RFS 理论提出一些新的滤波器, 如概率假设密度滤波器 (PHD)^[6-7]、势概率假设密度滤波器 (CPHD)^[8-9] 和多伯努利滤波器^[5,10], 但这些滤波器都不能给出多目标的运动轨迹. 为此, Vo 等^[11]将

多假设跟踪思想 (MHT) 与随机有限集 (RFS) 理论相结合, 提出了广义标签多伯努利滤波器 (GLMB), 并通过序贯蒙特卡洛 (SMC) 方法实现了该算法^[12], 随后又出现很多对于 GLMB 滤波器的改进和扩展^[13-17], 但都面临着计算量大的问题. GLMB 滤波器在每次迭代过程中, 预测步和更新步的权值和数量都存在指数增长的趋势, 因此需要进行两次独立的剪枝, 导致算法的计算效率大大降低. 为此, Vo 等^[18]提出了一种基于吉布斯采样的快速 GLMB 算法, 但该算法只考虑了单个运动模型, 对机动目标的跟踪性能较差.

文献 [15, 19-20] 虽然考虑到多模型机动问题, 但

收稿日期: 2018-01-24; 修回日期: 2018-05-15.

基金项目: 国家自然科学基金项目 (61571458).

[†]通讯作者. E-mail: 592255820@qq.com.

是在预测步和更新步需要分别进行两次剪枝,导致算法计算量大,运行效率低;文献[18]虽然提高了算法的运行效率,但是没有考虑到目标的机动问题,对机动目标的跟踪效果不好.本文针对上述存在的问题,综合考虑实际战场环境中存在大量的目标机动问题以及较强的时效性要求,提出一种多模型一步更新GLMB机动扩展目标跟踪算法.首先对GLMB滤波算法中的预测步和更新步进行合并,推导出一种新的一步递归表达式;然后结合多模型^[15,19-20]的思想,给出最终的一步更新方程,同时采用文献[18]提出的基于吉布斯采样的快速剪枝方法对其进行剪枝.仿真结果表明,所提出改进算法在提高算法时效性的同时,对机动目标也有很好的跟踪性能.

1 广义标签多伯努利滤波器

在多目标跟踪问题中,基于传统RFS理论的滤波方法存在无法提供目标航迹的问题,为此,Vo等^[11]将标签思想引入RFS中,并在此基础上,提出了广义标签多伯努利滤波器(GLMB).在贝叶斯递推过程中,GLMB RFS的后验概率密度具有保持相同形式的特点,能够避免传统算法中复杂的积分求解过程.其后验概率密度可表示为

$$\pi(X) = \Delta(X) \sum_{(I,\xi) \in F(L) \times \Theta} \omega(I,\xi) \delta_I[L(X)] [p(\cdot; \xi)]^X. \quad (1)$$

其中: $X = \{(x, l)_i\} (i = 1, 2, \dots, \|X\|)$ 为标签RFS; $\Delta(X)$ 为标签指示函数; L 为离散的标签空间; $F(L)$ 为航迹集合; Θ 为离散的关联空间; 每对 (I, ξ) 表示一种关联假设, $\omega(I, \xi)$ 为对应的权值; $p(x, l; \xi)$ 为单目标概率分布; $[p(\cdot; \xi)]^X = \prod_{(x,l) \in X} p(x, l; \xi)$.

现假设 $k-1$ 时刻多目标后验概率密度具有式(1)的形式,则GLMB的预测步和更新步可表示如下:

预测步为

$$\bar{\pi}_+(X) = \Delta(X) \sum_{\xi, J, L_+} \bar{\omega}_+(\xi, J, L_+) \delta_{J \cup L_+}[L(X)] [\bar{p}_+(\cdot; \xi)]^X. \quad (2)$$

其中

$$\begin{aligned} \bar{\omega}_+(\xi, J, L_+) = & 1_{F(B_+)}(L_+) r_{B_+}^{L_+} [1 - r_{B_+}]^{B_+ - L_+} \times \\ & \sum_{I \in F(L)} 1_{F(I)}(J) [\bar{P}_S(\cdot; \xi)]^J [1 - \bar{P}_S(\cdot; \xi)]^{I-J} \omega(I, \xi); \quad (3) \end{aligned}$$

$$\bar{P}_S(\cdot, l; \xi) = \langle p(\cdot, l; \xi), P_S(\cdot, l) \rangle; \quad (4)$$

$$\bar{p}_+(\cdot; \xi) = 1_{L_+}(l_+) \frac{\langle P_S(\cdot, l_+) f_+(x_+ | \cdot, l_+), p(\cdot, l_+; \xi) \rangle}{\bar{P}_S(\cdot, l_+; \xi)} +$$

$$1_{B_+}(l_+) p_{B_+}(x_+, l_+); \quad (5)$$

$\xi \in \Theta, J \in F(L), L_+ \in F(B_+); B_+$ 为新生目标标签空间且 $L \cap B_+ = \emptyset; r_{B_+}$ 和 $p_{B_+}(x_+, l_+)$ 分别为新生目标出生概率和概率分布; $f_+(x_+ | \cdot, l_+)$ 为马尔科夫状态转移函数,且预测步中存活目标的标签保持不变; $P_S(\cdot, l_+)$ 为目标存活概率.

更新步为

$$\begin{aligned} \pi_{Z_+}(X) \propto \Delta(X) \sum_{\xi, J, L_+, \theta_+} \omega_{Z_+}(\xi, J, L_+, \theta_+) \times \\ \delta_{J \cup L_+}[L(X)] [p_{Z_+}(\cdot; \xi, \theta_+)]^X. \quad (6) \end{aligned}$$

其中

$$\begin{aligned} \omega_{Z_+}(\xi, J, L_+, \theta_+) = & 1_{\Theta_+(J \cup L_+)}(\theta_+) [\bar{\psi}_{Z_+}(\cdot; \xi, \theta_+)]^{J \cup L_+} \bar{\omega}_+(\xi, J, L_+); \quad (7) \end{aligned}$$

$$\bar{\psi}_{Z_+}(\cdot, l_+; \xi, \theta_+) = \langle \bar{p}_+(\cdot, l_+; \xi), \psi_{Z_+}(\cdot, l_+; \theta_+(l_+)) \rangle; \quad (8)$$

$$p_{Z_+}(\cdot; \xi, \theta_+) = \frac{\bar{p}_+(\cdot; \xi) \psi_{Z_+}(\cdot; \theta_+(l_+))}{\bar{\psi}_{Z_+}(\cdot, l_+; \xi, \theta_+)}; \quad (9)$$

$$\psi_{Z_+}(\cdot; \theta_+(l_+)) = \begin{cases} \frac{P_D(x_+, l_+) g(z_{\theta_+(l_+)} | x_+, l_+)}{\kappa(z_{\theta_+(l_+)})}, \\ \theta_+(l_+) > 0; \\ 1 - P_D(x_+, l_+), \theta_+(l_+) = 0; \end{cases} \quad (10)$$

$\theta_+ \in \Theta_+$ 为目标到量测的关联映射; $g(z_{\theta_+(l_+)} | x_+, l_+)$ 为量测似然函数; $P_D(x_+, l_+)$ 为目标检测概率.

2 改进的广义标签多伯努利滤波器

2.1 一步联合预测和更新表达式推导

GLMB滤波器在每次迭代过程中,预测步和更新步的权值和数量都存在指数增长的趋势,因此需要分别采用 K 最短路径算法和最优分配算法进行两次独立的剪枝,这样做会导致算法的计算效率大大降低.为此,本节将GLMB的预测步与更新步合并,给出其具体推导过程,得到新的一步递归表达式.该算法的优点是只需进行一次剪枝.

现假设 $k-1$ 时刻多目标后验概率密度具有式(1)的形式, k 时刻GLMB的一步联合预测和更新表达式可表示为

$$\begin{aligned} \pi_{Z_+}(X) \propto \Delta(X) \sum_{I, \xi, I_+, \theta_+} \omega(I, \xi) \omega_{Z_+}(I, \xi, I_+, \theta_+) \times \\ \delta_{I_+}[L(X)] [p_{Z_+}(\cdot; \xi, \theta_+)]^X. \quad (11) \end{aligned}$$

其中

$$I \in F(L), \xi \in \Xi, I_+ \in F(L_+), \theta_+ \in \Theta_+,$$

$$\begin{aligned} \omega_{Z_+}(I, \xi, I_+, \theta_+) = & \\ 1_{\Theta_+(I_+)}(\theta_+) [1 - \bar{P}_S(\xi)]^{I-I_+} [\bar{P}_S(\xi)]^{I \cap I_+} \times & \\ [1 - r_{B,+}]^{B_+ - I_+} r_{B,+}^{B_+ \cap I_+} [\bar{\psi}_{Z_+}(\cdot; \xi, \theta_+)]^{I_+}, & \quad (12) \end{aligned}$$

$$\bar{P}_S(\cdot, l; \xi) = \langle p(\cdot, l; \xi), P_S(\cdot, l) \rangle, \quad (13)$$

$$\bar{\psi}_{Z_+}(\cdot, l_+; \xi, \theta_+) = \langle \bar{p}_+(\cdot, l_+; \xi), \psi_{Z_+}(\cdot, l_+; \theta_+(l_+)) \rangle, \quad (14)$$

$$\begin{aligned} \bar{p}_+(x_+, l_+; \xi) = & \\ 1_L(l_+) \frac{\langle P_S(\cdot, l_+) f_+(x_+ | \cdot, l_+), p(\cdot, l_+; \xi) \rangle}{\bar{P}_S(\cdot, l_+; \xi)} + & \\ 1_{B_+}(l_+) p_{B,+}(x_+, l_+), & \quad (15) \end{aligned}$$

$$p_{Z_+}(\cdot; \xi, \theta_+) = \frac{\bar{p}_+(\cdot; \xi) \psi_{Z_+}(\cdot; \theta_+(l_+))}{\bar{\psi}_{Z_+}(\cdot, l_+; \xi, \theta_+)}. \quad (16)$$

在推导一步联合预测和更新表达式时,通过变形公式 $I_+ = J \cup L_+$, 可以得到 $J = L \cap I_+$, $L_+ = B_+ \cap I_+$. 现将其代入式(7), 可以变形为

$$\begin{aligned} \omega_{Z_+}(J, L_+, \xi, \theta_+) = & \\ \omega_{Z_+}(L \cap I_+, B_+ \cap I_+, \xi, \theta_+) = & \\ 1_{\Theta_+(I_+)}(\theta_+) [\bar{\psi}_{Z_+}(\xi, \theta_+)]^{I_+} \bar{\omega}_+(L \cap I_+, B_+ \cap I_+, \xi) = & \\ 1_{\Theta_+(I_+)}(\theta_+) [\bar{\psi}_{Z_+}(\xi, \theta_+)]^{I_+} \times & \\ 1_{F(B_+)}(B_+ \cap I_+) r_{B,+}^{B_+ \cap I_+} \times [1 - r_{B,+}]^{B_+ - (B_+ \cap I_+)} \times & \\ \sum_{I \in F(L)} 1_{F(I)}(L \cap I_+) [\bar{P}_S(\xi)]^{L \cap I_+} \times & \\ [1 - \bar{P}_S(\xi)]^{I - (L \cap I_+)} \omega(I, \xi) = & \\ 1_{\Theta_+(I_+)}(\theta_+) [\bar{\psi}_{Z_+}(\xi, \theta_+)]^{I_+} r_{B,+}^{B_+ \cap I_+} \times & \\ [1 - r_{B,+}]^{B_+ - I_+} \times & \\ \sum_I [1 - \bar{P}_S(\xi)]^{I - I_+} [\bar{P}_S(\xi)]^{I \cap I_+} \omega(I, \xi). & \quad (17) \end{aligned}$$

其中

$$\begin{aligned} 1_{F(B_+)}(B_+ \cap I_+) = 1, \quad B_+ - (B_+ \cap I_+) = B_+ - I_+, \\ L \cap I_+ = I \cap I_+, \quad I - (L \cap I_+) = I - I_+, \end{aligned}$$

使得对于任意一个 I_+ 都有 $1_{F(I)}(L \cap I_+) = 1$. 将式(17)代入(6)中, 通过交换求和顺序得到新的一步递归表达式(11).

2.2 多模型一步更新广义标签多伯努利滤波器

2.2.1 多模型一步更新GLMB方程推导

当目标发生机动时, 单个模型往往不足以描述目标的运动状态, 多模型算法是一种更为合理和强大的描述方法, 是解决机动目标跟踪的有效方式. 多模型算法的基本思想是用多个不同的运动模型匹配机动目标的不同运动模式, 该算法假设任一时刻目标运动模型与有限已知模型中的一个匹配, 不同模型间的转

换概率为一个马尔科夫矩阵. 若目标的运动模式已知且可以用有限个模型描述, 则相比于输入估计法和变维滤波而言, 多模型算法具有更好的跟踪性能.

为了使改进后的滤波器能够有效跟踪机动目标, 适应复杂多变的实际战场环境, 本文引入多模型思想, 提出了一种多模型一步更新GLMB滤波器. 首先对目标状态进行扩展, $X = \{(x, l, r)_i, i = 1, 2, \dots, \|X\|\}$, 其中 r 表示目标的运动模型. 然后将多模型思想引入到2.1节中的一步联合预测和更新表达式中, 推导得到最终的一步更新方程, 其表达式为

$$\begin{aligned} \pi_{Z_+}(X) \propto \Delta(X) \sum_{I, \xi, I_+, \theta_+} \omega(I, \xi) \omega_{Z_+}(I, \xi, I_+, \theta_+) \times \\ \delta_{I_+}[L(X)] [p_{Z_+}(x_+, l_+, r_+; \xi, \theta_+)]^X. \quad (18) \end{aligned}$$

其中

$$\begin{aligned} I \in F(L), \quad \xi \in \Xi, \quad I_+ \in F(L_+), \quad \theta_+ \in \Theta_+, \\ \omega_{Z_+}(I, \xi, I_+, \theta_+) = \\ 1_{\Theta_+(I_+)}(\theta_+) [1 - \bar{P}_S(\xi)]^{I - I_+} [\bar{P}_S(\xi)]^{I \cap I_+} \times \\ [1 - r_{B,+}]^{B_+ - I_+} r_{B,+}^{B_+ \cap I_+} [\bar{\psi}_{Z_+}(\cdot; \xi, \theta_+)]^{I_+}. \quad (19) \end{aligned}$$

需要注意的是, 多模型系统中扩展目标状态的內积函数为多维积分, 则式(13)、(14)在多模型系统中变形为如下形式:

$$\bar{P}_S(\cdot, l; \xi) = \sum_{r \in R} \langle p(\cdot, l, r; \xi), P_S(\cdot, l, r) \rangle; \quad (20)$$

$$\begin{aligned} \bar{\psi}_{Z_+}(\cdot, l_+; \xi, \theta_+) = \\ \sum_{r \in R} \langle \bar{p}_+(\cdot, l_+, r_+; \xi), \psi_{Z_+}(\cdot, l_+, r_+; \theta_+(l_+)) \rangle; \quad (21) \end{aligned}$$

$$\begin{aligned} \psi_{Z_+}(x_+, l_+, r_+; \theta_+(l_+)) = \\ \begin{cases} \frac{P_D(x_+, l_+, r_+) g(z_{\theta_+(l_+)} | x_+, l_+, r_+)}{\kappa(z_{\theta_+(l_+)})}, & \theta_+(l_+) > 0; \\ 1 - P_D(x_+, l_+, r_+), & \theta_+(l_+) = 0; \end{cases} \quad (22) \end{aligned}$$

$$\begin{aligned} \bar{p}_+(x_+, l_+, r_+; \xi) = \\ 1_L(l_+) \frac{\sum_{r' \in R} \langle P_S(\cdot, l_+) f_+(x_+, r_+ | \cdot, l_+, r'), p(\cdot, l_+; \xi) \rangle}{\bar{P}_S(\cdot, l_+; \xi)} + \\ 1_{B_+}(l_+) p_{B,+}(x_+, l_+, r_+); \quad (23) \end{aligned}$$

$$\begin{aligned} p_{Z_+}(x_+, l_+, r_+; \xi, \theta_+) = \\ \frac{\bar{p}_+(x_+, l_+, r_+; \xi) \psi_{Z_+}(x_+, l_+, r_+; \theta_+(l_+))}{\bar{\psi}_{Z_+}(\cdot, l_+; \xi, \theta_+)}. \quad (24) \end{aligned}$$

由式(20)和(21)可以看出, 随着运动模型 r 的增大, 算法的计算量由于求和运算的增多而增大, 但GLMB滤波器的计算量主要取决于剪枝过程, 因此运动模型 r 的增加会在一定程度上增加计算量, 但是影

响不大.

2.2.2 基于吉布斯采样的快速剪枝算法

已知 $k-1$ 时刻GLMB密度参数 (ξ, I) 和 k 时刻的量测集 Z_+ ,目标是找到一组具有有效权值 $\omega_{Z_+}(I, \xi, I_+, \theta_+)$ 的 $(I_+, \theta_+) \in F(L_+) \times \Theta_+(I_+)$. 假设 $Z_+ = \{z_{1:M}\}, I = \{l_{1:R}\}, B_+ = \{l_{R+1:P}\}$,对于每对 $(I_+, \theta_+) \in F(L_+) \times \Theta_+(I_+)$,定义一个数组 $\gamma = (\gamma_{1:P}) \in \{-1 : M\}^P$,其表达式为

$$\gamma_i = \begin{cases} \theta_+(l_i), & l_i \in I_+; \\ -1, & l_i \notin I_+. \end{cases} \quad (25)$$

由于一对一的对应关系,可以通过 $\gamma \in \Gamma$ 获得 I_+ 和 θ_+ ,即

$$I_+ = \{l_i \in I \cup B_+ : \gamma_i \geq 0\}, \theta_+(l_i) = \gamma_i. \quad (26)$$

假设对于所有的 $i \in \{1 : P\}, \bar{P}_S(l_i; \xi) \in (0, 1)$,且 $\bar{P}_D(l_i; \xi) \triangleq \langle \bar{p}_+(\cdot, l_i; \xi), P_D(l_i; \xi) \rangle \in (0, 1)$,定义

$$\eta_i(j) = \begin{cases} 1 - \bar{P}_S(l_i; \xi), & 1 \leq i \leq R, j < 0; \\ \bar{P}_S(l_i; \xi) \bar{\psi}_{Z_+}(l_i; \xi, j), & 1 \leq i \leq R, j \geq 0; \\ 1 - r_{B_+,+}(l_i), & R+1 \leq i \leq P, j < 0; \\ r_{B_+,+}(l_i) \bar{\psi}_{Z_+}(l_i; \xi, j), & R+1 \leq i \leq P, j \geq 0. \end{cases} \quad (27)$$

其中: $j \in \{-1 : M\}$ 为标签 l_i 的量测指标, $j = 0$ 表示 l_i 为误检, $j = -1$ 表示 l_i 消失.可以看出, $\eta_i(j)$ 由 (ξ, I) 和 Z_+ 决定.将式(27)代入(19),可得

$$\omega_{Z_+}(I, \xi, I_+, \theta_+) = 1_{\Gamma}(\gamma) \prod_{i=1}^P \eta_i(\gamma_i). \quad (28)$$

这样,目标由找到一组具有有效权值 $\omega_{Z_+}(I, \xi, I_+, \theta_+)$ 的 $(I_+, \theta_+) \in F(L_+) \times \Theta_+(I_+)$ 转化为找到一组具有有效 $\prod_{i=1}^P \eta_i(\gamma_i)$ 的 γ .但是,直接从权重分布函数式(28)中采样十分困难,因此本文选择使用一种高效快速的吉布斯采样对改进后的GLMB进行剪枝,其具体推导过程见文献[18],吉布斯采样的算法伪代码如下所示.

输入: $\gamma^{(1)}K, \eta = [\eta_i(j)]$;

输出: $\gamma^{(1)}, \dots, \gamma^{(T)}$.

$P := \text{size}(\eta, 1); M := \text{size}(\eta, 2)$;

$c := \text{size}(-1, M); \tilde{\eta} := \eta$;

for $k = 2 : K$

$\gamma^{(k)} := []$;

for $n = 1 : P$

for $j = 1 : M$

$\tilde{\eta}_n(j) := \eta_n(j)(1 - 1_{\{\gamma_{1:n-1}^{(k-1)}, \gamma_{n+1:P}^{(k-1)}\}}(j))$;

end

$\gamma_n^{(k)} \sim \text{Categorical}(c, \tilde{\eta}_n); \gamma^{(k)} := [\gamma^{(k)}, \gamma_n^{(k)}]$;

end

2.2.3 多模型一步更新广义标签多伯努利滤波器的实现

GLMB滤波器可以完全由参数 $(\omega(I, \xi), p(\xi)), (I, \xi) \in F(L) \times \Xi$ 表示.为了简便,将其表示为 $(I^{(h)}, \omega^{(h)}, p^{(h)})_{h=1}^H$.由式(18)~(24), (26)和(28)可以得到

$$I_+^{(h,t)} = \{l_i \in I^{(h)} \cup B_+ : \gamma_i^{(h,t)} \geq 0\}, \quad (29)$$

$$\theta_+(l_i) = \gamma_i^{(h,t)},$$

$$\omega_+^{(h,t)} = \omega^{(h)} \prod_{i=1}^{\|I^{(h)} \cup B_+\|} \eta_i^{(h)}(\gamma_i^{(h,t)}), \quad (30)$$

$$p_+^{(h,t)}(\cdot, l_i, r_+) = \frac{\bar{p}_+^{(h)}(\cdot, l_i, r_+) \psi_{Z_+}^{(\gamma_i^{(h,t)})}(\cdot, l_i, r_+)}{\bar{\psi}_{Z_+}^{(h, \gamma_i^{(h,t)})}(l_i)}. \quad (31)$$

下面给出改进后的多模型一步更新GLMB滤波器具体参数计算流程.

输入: $\{I^{(h)}, \omega^{(h)}, p^{(h)}\}_{h=1}^H, Z_+, H_+^{\max}\{r_{B_+,+}(l), p_{B_+,+}(l)\}_{l \in B_+}, P_S(\cdot, l, r), f_+(x_+, r_+ | \cdot, l_+, r'), \kappa_+, P_D(x_+, l_+, r_+), g(z_{\theta_+(l_+)}) \| x_+, l_+, r_+$;

输出: $\{I_+^{(h+)}, \omega_+^{(h+)}, p_+^{(h+)}\}_{h_+=1}^{H_+}$.

for $h = 1 : H$

初始化 $\gamma^{(h,1)}$

由式(27)计算 $\eta^{(h)} = [\eta_i^{(h)}(j)]_{(i,j)=(1,-1)}^{(\|I^{(h)} \cup B_+\|, \|Z_+\|)}$

利用2.2.2节的算法进行吉布斯采样

$$\{\gamma^{(h,k)}\}_{k=1}^{K_+^{(h)}} :=$$

$$\text{Unique}(\text{Gibbs}(\gamma^{(h,1)}, K_+^{(h)}, \eta^{(h)}))$$

for $k = 1 : K_+^{(h)}$

使用式(29)通过 $I^{(h)}$ 和 $\gamma^{(h,k)}$ 计算 $I_+^{(h,k)}$

使用式(30)通过 $\omega^{(h)}$ 和 $\gamma^{(h,k)}$ 计算 $\omega_+^{(h,k)}$

使用式(31)通过 $p^{(h)}$ 和 $\gamma^{(h,k)}$ 计算 $p_+^{(h,k)}$

end

end

$(\{I_+^{(h+)}, p_+^{(h+)}\}_{h_+=1}^{H_+}, \sim, [U_{h,k}]) :=$

$\text{Unique}(\{(I_+^{(h,k)}, p_+^{(h,k)})\}_{(h,k)=(1,1)}^{(H, K_+^{(h)})})$

for $h_+ = 1 : H_+$

$$\omega_+^{h_+} := \sum_{h,k: U_{h,k}=h_+} \omega_+^{(h,k)}$$

end

权值归一化 $\{\omega_+^{h_+}\}_{h_+=1}^{H_+}$.

3 仿真实验与分析

本文将所提出算法与文献[18]的快速标签多伯努利滤波算法(fast GLMB)和文献[2]的多模型标签

多伯努利滤波算法(MMGLMB)进行比较分析,对所提出算法跟踪扩展目标如下两方面的性能进行验证:

- 1) 时效性:算法的运行效率是否提高;
- 2) 跟踪性能:目标发生机动的情况下,是否具有很好的跟踪精度及稳定性.

3.1 实验参数设置

假设仿真环境中最多有5个机动目标在监测区域 $[-300\text{ m}, 600\text{ m}] \times [-600\text{ m}, 400\text{ m}]$ 内运动,目标运动模型 r 包括匀速(CV)和转弯(CT)两种,其对应的运动方程如下.

CV模型:

$$x_k = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} x_{k-1} + \nu_k. \quad (32)$$

CT模型:

$$x_k = \begin{bmatrix} 1 & \frac{\sin \omega T}{\omega} & 0 & -\frac{1 - \cos \omega T}{\omega} \\ 0 & \cos \omega T & 0 & -\sin \omega T \\ 0 & \frac{1 - \cos \omega T}{\omega} & 1 & \frac{\sin \omega T}{\omega} \\ 0 & \sin \omega T & 0 & \cos \omega T \end{bmatrix} x_{k-1} + \nu_k. \quad (33)$$

其中:传感器采样间隔 $T = 1\text{ s}$,转弯速率 ω 包括 $\omega_1 = 5\pi/180\text{ rad/s}$, $\omega_2 = -5\pi/180\text{ rad/s}$ 两种.过程噪声标准差 $\sigma_v = 0.5\text{ m/s}^2$,模型转换概率矩阵 $f(r||r')$ 和协方差矩阵 Q_v 分别为

$$f(r||r') = \begin{bmatrix} 0.6 & 0.2 & 0.2 \\ 0.4 & 0.6 & 0 \\ 0.4 & 0 & 0.6 \end{bmatrix}, \quad (34)$$

$$Q_v = \begin{bmatrix} T^4/4 & T^3/2 & 0 & 0 \\ T^3/2 & T^2 & 0 & 0 \\ 0 & 0 & T^4/4 & T^3/2 \\ 0 & 0 & T^3/2 & T^2 \end{bmatrix} \sigma_v^2. \quad (35)$$

系统的量测方程为

$$z_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} x_k + \omega_k. \quad (36)$$

其中:量测噪声 $w_k \sim N(0, Q_w)$,量测噪声标准差 $\theta_w = 5\text{ m/s}$,其协方差矩阵 $Q_w = \text{diag}([1, 1])\theta_w^2$.

新生目标随机集可以用标签伯努利参数集 $\{r_{B,k}(l_i), p_{B,k}(l_i)\}_{i=1}^4$ 表示,其中新生目标的概率为 $r_{B,k}(l_i) = 0.04$,概率密度服从高斯分布 $p_B(l_i) = N(x; m_B^{(i)}, P_B)$.4个新生目标的初始状态分别为

$$m_B^{(1)} = [180, 0, 300, -12]^T,$$

$$m_B^{(2)} = [-100, 9, 200, -6]^T,$$

$$m_B^{(3)} = [300, 10, -400, -3]^T,$$

$$m_B^{(4)} = [50, 3, -400, 12]^T,$$

$$P_B = \text{diag}([10, 5, 10, 5]^T)^2.$$

目标的存活概率 $P_s = 0.98$,检测概率 $P_D = 0.8$.背景杂波数服从均值为10的泊松分布,且在监测区域内均匀分布.仿真参数设置最大高斯分量数目 $H_{\max} = 1000$ ^[14],整个跟踪过程持续100s.为了验证算法的有效性和稳定性,在不改变实验参数和运动轨迹的情况下,共进行100次蒙特卡洛实验.仿真场景中包含目标的新生和消亡,目标的初始状态如表1所示.

表1 目标初始状态

目标	初始状态	出现时间/s	消失时间/s
目标1	[0 10 -300 0]	1	70
目标2	[180 0 300 -12]	21	90
目标3	[-100 9 200 -6]	21	100
目标4	[300 10 -400 -3]	11	80
目标5	[50 3 -400 0]	41	100

3.2 仿真结果分析

本文选用目标估计数、OSPA距离^[21]和平均计算时间3个指标对算法的性能进行评价.OSPA距离能够反映目标状态的估计性能,其计算公式为

$$\bar{d}_p^{(c)}(p, c, X, Y) = \left(\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m d^{(c)}(x_i, y_{\pi(i)})^p + c^p \|n - m\| \right) \right)^{1/p}. \quad (37)$$

其中: $X = \{x_1, \dots, x_m\}$ 和 $Y = \{y_1, \dots, y_n\}$ 分别为真实目标状态和估计目标状态的有限集, m 和 n 分别为真实目标数和估计目标数, c 为水平参数, p 为阶数.实验设置 $c = 60, p = 2$.由式(17)可见,OSPA距离既包含目标位置估计误差,也包含目标个数估计误差.

多机动目标的真实运动轨迹及量测如图1所示.图2给出了本文所提出算法与文献[18]的fast GLMB算法、文献[20]的MM-GLMB算法的滤波结果对比.由图1和图2可见,本文所提出算法与MM-GLMB算法均可以较好地跟踪机动扩展目标,而fast GLMB由于只考虑到单个运动模型,会出现“跟不上”的情况.







图1 目标真实运动轨迹和量测



(a) 本文所提算法滤波结果




(b) MM-GLMB 算法滤波结果




(c) fast GLMB 算法滤波结果

图2 滤波结果对比图

本文所提出算法在 x 轴和 y 轴方向上对机动目标的跟踪效果如图3所示,由图3可见各目标出现和消失的时间及运动状态.



(a) 本文所提算法在 x 轴方向滤波结果



(b) 本文所提算法在 y 轴方向滤波结果

图3 本文所提出算法对目标状态估计图

图4给出了本文所提出算法与文献[18]的 fast GLMB 算法、文献[20]的 MM-GLMB 算法对目标数目的估计.可以看出,在低检测概率 ($P_D = 0.8$) 下,不同算法对目标数量的估计均出现一定程度的偏差.

其中本文所提出算法和 MM-GLMB 算法对目标的数目估计相当,虽然对目标的出现消失反应速度有所延迟,但均能较为准确地估计出机动目标的数目,具有较好的稳定性和抗干扰性;而 fast GLMB 算法在目标发生机动时,则出现了明显的航迹丢失,稳定性较差,对目标的数目估计出现明显的偏差.




图4 目标数目估计图

图5给出本文算法与文献[18] fast GLMB 算法、文献[20] MM-GLMB 算法的 OSPA 距离对比,OSPA 距离越小,代表跟踪效果越好. OSPA 距离既包含目标位置估计误差,也包含目标个数估计误差,因此当目标数目估计错误时,OSPA 会出现峰值.可以更为直观地看出,当目标发生机动时, fast GLMB 算法的滤波效果最差,而本文所提出算法和 MM-GLMB 算法的滤波效果相当,都能较好地对机动目标进行跟踪.




图5 OSPA 距离图

由图1~图5可见,本文算法与 MM-GLMB 算法对机动扩展目标的跟踪效果相当,为了比较两种算法的运行效率,表2给出了所提出算法与 MM-GLMB 算法所需的最大高斯分量数及运行时间.令假设标签数 $P = \max_h \|I^{(h)} \cup B\|$, 目标量测数 $M\Delta\| = \|Z_+\|$. MM-GLMB 采用标准的最优分配算法进行剪枝,其计算复杂度^[18]为 $O((2P + M)^3)$,在假设标签数及目标量测数上都达到立方的计算,因此计算量较大;而本文所提出算法采用吉布斯采样进行剪枝,其计算复杂度^[18]为 $O(P^2M)$,是假设标签数的二次方和目标量测数上的线性计算,因此计算量较小.由表2可以更明显地看出,所提出算法在有效估计机动目标状态的同时,相比于 MM-GLMB 滤波器,所需的最大高斯分量数明显下降,并且由于本文所提出算法只涉及到一次剪枝且剪枝方法高效,计算效率有明显提高,运行时间大大缩短.综合跟踪效果和时效性两方面进

行考虑,本文所提出算法优于fast GLMB算法和MM-GLMB算法。

表2 平均运行时间

算法名称	最大高斯分量数目 H_{\max}	运行时间/s
NM-GLMB	10^4	589.15
本文所提算法	10^3	69.29

4 结论

本文将多模型思想与快速GLMB思想相结合,提出了一种多模型一步更新GLMB机动扩展目标跟踪算法。实验结果表明,当目标发生机动时,所提出的改进算法能够进行有效跟踪,具有较好的稳定性,相比于MM-GLMB算法,运行时间大大降低,提高了运算效率,具有很好的实时性。

参考文献(References)

- [1] 刘妹琴, 兰剑. 目标跟踪前沿理论与应用[M]. 北京: 科学出版社, 2015: 1-65.
(Liu M Q, Lan J. Target tracking theory and application of the frontier[M]. Beijing: Science Press, 2015: 1-65.)
- [2] Fortmann T E, Bar-shalom Y, Scheffe M. Sonar tracking of multiple targets using joint probabilistic data association[J]. IEEE J of Oceanic Engineering, 1983, 8(3): 173-184.
- [3] Bar-shalom Y, Li X R, Kirubarajan T. Estimation with applications to tracking and navigation[M]. New York: Wiley, 2001: 421-488.
- [4] Blackman S S. Multiple hypotheses tracking for multiple target tracking[J]. IEEE Trans on Aerospace and Electronic System, 2004, 19(1): 5-18.
- [5] Mahler R. Statistical multisource-multitarget information fusion[M]. Norwood: Artech House, 2007: 565-682.
- [6] Mahler R. Multitarget Bayes filtering via first-order multitarget moments[J]. IEEE Trans on Aerospace and Electronic System, 2003, 39 (4): 1152-1178.
- [7] Vo B N, Ma W. The Gaussian mixture probability hypothesis density filter[J]. IEEE Trans on Signal Processing, 2006, 54(11): 4091-4104.
- [8] Mahler R. PHD filters of higher order in target number[J]. IEEE Trans on Aerospace and Electronic System, 2007, 43(4): 1523-1543.
- [9] Vo B T, Vo B N, Cantonl A. Analytic implementations of the cardinalized probability hypothesis density filter[J]. IEEE Trans on Signal Processing, 2007, 55(7): 3553-3567.
- [10] Vo B T, Vo B N, Cantonl A. The cardinality balanced multi-target multi-bernoulli filter and its implementation[J]. IEEE Trans on Signal Processing, 2009, 57(2): 409-423.
- [11] Vo B T, Vo B N. Labeled random finite sets and multi-object conjugate priors[J]. IEEE Trans on Signal Processing, 2013, 61(13): 3460-3475.
- [12] Vo B N, Vo B T, Phung D. Labeled random finite sets and the Bayes multi-target tracking filter[J]. IEEE Trans on Signal Processing, 2014, 62(24): 6554-6567.
- [13] Reuter S, Vo B T, Vo B N, et al. The labeled multi-bernoulli filter[J]. IEEE Trans on Signal Processing, 2014, 62(12): 3246-3260.
- [14] Beard M, Vo B T, Vo B N. Bayesian multi-target tracking with merged measurements using labeled random finite sets[J]. IEEE Trans on Signal Processing, 2015, 63(6): 1433-1447.
- [15] 邱昊, 黄高明, 左炜, 等. 多模型标签多伯努利机动目标跟踪算法[J]. 系统工程与电子技术, 2015, 37(12): 2683-2688.
(Qiu H, Huang G M, Zuo W, et al. Multiple model labeled multi-bernoulli filter for maneuvering target tracking[J]. Systems Engineering and Electronics, 2015, 37(12): 2683-2688.)
- [16] 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]. J of Xi'an Jiaotong University, 2017, 51(10): 107-112.)
- [17] 袁常顺, 王俊, 向洪, 等. 基于VB近似的自适应GLMB滤波算法[J]. 系统工程与电子技术, 2017, 39(2): 237-243.
(Yuan C S, Wang J, Xiang H, et al. Adaptive GLMB filtering algorithm based on VB approximation[J]. Systems Engineering and Electronics, 2017, 39(2): 237-243.)
- [18] Vo B N, Vo B T, Hoang H G. An efficient implementation of the generalized labeled multi-bernoulli filter[J]. IEEE Trans on Signal Processing, 2017, 65(8): 1975-1987.
- [19] Reuter S, Alexander S, Klaus D. The multiple model labeled multi-bernoulli filter[C]. The 18th Int Conf on Information Fusion. Washington, DC: IEEE Xplore, 2015: 1574-1580.
- [20] Punchihewa Y, Vo B N, Vo B T. A generalized labeled multi-bernoulli filter for maneuvering targets[C]. The 19th Int Conf on Information Fusion. Heidelberg: IEEE Xplore, 2016: 1-7.
- [21] Schuhmacher D, Vo B N. A consistent metric for performance evaluation of multi-object filters[J]. IEEE Trans 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、目标跟踪等研究, E-mail: fengxinxi2005@aliyun.com;

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

王泉(1990—), 男, 博士生, 从事多传感器数据融合、目标跟踪的研究, E-mail: wangquan628@126.com;

蒲磊(1991—)男, 博士生, 从事多传感器数据融合、目标跟踪的研究, E-mail: 304019416@qq.com.