

基于标签随机有限集的多量测多目标跟踪算法

邱昊, 黄高明, 左炜, 高俊

(海军工程大学 电子工程学院, 武汉 430033)

摘要: 针对一个扫描周期内单个目标可能产生多个量测的问题, 提出一种基于标签随机有限集的扩展算法. 结合脉冲扩展标签多伯努利(δ -GLMB)滤波器和多量测模型, 推导出新的更新方程; 采用假设分解策略对关联过程进行降维, 避免了量测分组过程. 实验分析表明: 所提出算法能对目标数进行无偏估计, 在低探测概率条件下跟踪性能明显优于多量测概率假设密度(MD-PHD)算法; 计算开销在量测较少时高于MD-PHD, 量测个数增加时增幅低于MD-PHD.

关键词: 多目标跟踪; 标签随机有限集; 多伯努利; 多量测

中图分类号: TP391

文献标志码: A

Multi-detection multi-target tracking with labeled random finite sets

QIU Hao, HUANG Gao-ming, ZUO Wei, GAO Jun

(College of Electronic Engineering, Naval University of Engineering, Wuhan 430033, China. Correspondent: QIU Hao, E-mail: qhcs01@163.com)

Abstract: For the case that one target may generate multiple detections per scan, an extended method within the labeled random finite sets framework is proposed. A new update equation is derived based on the δ -generalized labeled multi-Bernoulli(δ -GLMB) filter and multi-detection model. The hypotheses decomposition strategy is employed to reduce the dimensions of association process, so that partitioning of the detections set is avoided. Experiments indicate that the proposed method can estimate the target number without bias, and significantly outperforms the multi-detection probability hypothesis density(MD-PHD) filter in low probability of detection situation. The computational cost of the proposed method is higher than MD-PHD with a few detections, and grows slowly than MD-PHD when the amount of detections increases.

Keywords: multi-target tracking; labeled random finite sets; multi-Bernoulli; multi-detection

0 引言

基于随机有限集(RFS)理论的多目标跟踪(MTT)算法能避免复杂的数据关联过程而受到人们广泛关注. 由于无法有效区分集合中的目标, 传统的RFS滤波器并非严格意义上的MTT算法^[1]. 文献[2]结合多假设跟踪(MHT)思想和标签RFS理论, 提出了一种脉冲扩展标签多伯努利(δ -GLMB)算法. 该算法能够通过标签信息快速形成航迹, 同时继承了MHT在低信噪比环境下的优异性能, 但也存在假设的“组合爆炸”问题. 文献[3]通过后验概率一阶矩近似和航迹分组方法有效改善了原算法的滤波效率.

标准MTT算法通常假设一个监测周期内单个目标至多产生一个量测. 实际应用中, 单目标可能对应多个量测. 例如, 天波超视距雷达(OTHR)的多径现象

和无源相干定位中多个外辐射信号均可能导致多量测问题^[4]; 另外, 受传感器分辨率或探测距离等因素影响, 目标可能呈现扩展或不可分辨特性^[5-6]. 本文主要对第1种情形进行讨论. 文献[7]将联合概率数据关联(JPDA)算法应用于多量测MTT问题, 但该方法假定目标数恒定且已知. 文献[4]研究了基于MHT滤波器的改进算法, 当目标较少且杂波密度较低时, 算法表现出良好的性能, 但MHT固有的局限性限制了其应用. 文献[8]结合多传感器PHD算法^[9-10]和多量测模型, 提出了一种多量测PHD(MD-PHD)算法, 但该算法仅适用于少量多量测目标场景, 同时, 由于假设目标数服从泊松分布, 低信噪比探测环境下MD-PHD性能严重下降.

针对上述问题, 本文提出一种基于 δ -GLMB滤波

收稿日期: 2015-07-19; 修回日期: 2015-11-25.

基金项目: 国家863计划项目(2014AA7014061); 国家自然科学基金项目(61501484).

作者简介: 邱昊(1988-), 男, 博士生, 从事多目标跟踪技术的研究; 黄高明(1972-), 男, 教授, 博士生导师, 从事信息对抗技术等研究.

的多量测 MTT 算法. 结合多目标多量测模型, 推导了新的更新方程, 通过假设分解等技术有效限制了假设数目增长, 提高了滤波效率. 实验结果表明, 所提出算法能对多个多量测目标进行有效跟踪, 目标数和目标状态估计结果均优于 MD-PHD, 量测增多时, 计算开销增速慢于 MD-PHD.

1 背景知识

1.1 标准 δ -GLMB 滤波器

传统的 RFS 理论假设集合中各元素处于无序状态. 针对该问题, Vo 等^[2]将标签引入 RFS 用以表征集合中元素的唯一性. 标签 RFS 可描述为

$$X = \{(\mathbf{x}, l)_i\}, i = 1, 2, \dots, |X|. \quad (1)$$

其中: \mathbf{x} 为单目标状态向量, $l \in \mathbf{L}$ 为目标标签, \mathbf{L} 为离散的标签空间, $|X|$ 为集合元素个数. 记 $\mathcal{L}(X)$ 为 X 的标签集合, 标签指示函数 $\Delta(X) = \delta_{|X|}(|\mathcal{L}(X)|)$ 表示 X 中各元素互异, 其中 $\delta(\cdot)$ 为 Kronecker 函数.

在多目标跟踪环境中, 标签思想简化了目标状态提取和航迹管理等过程. 在标签 RFS 基础上, 文献[6]进一步定义了 δ -GLMB RFS, 其概率密度为

$$\pi(X) = \Delta(X) \sum_{(I, \varepsilon) \in \mathcal{F}(\mathbf{L}) \times \Theta} \omega(I; \varepsilon) \delta_I(\mathcal{L}(X)) [p(\cdot; \varepsilon)]^X. \quad (2)$$

其中: 每对 $(I; \varepsilon)$ 表示一种关联假设, $\omega(I; \varepsilon)$ 为相应权重; $\mathcal{F}(\cdot)$ 为空间划分函数; Θ 为关联空间; $p(\mathbf{x}, l; \varepsilon)$ 为单目标概率分布; $h^X = \prod_{\mathbf{x} \in X} h(\mathbf{x})$.

下面简要介绍 δ -GLMB 滤波器预测和更新步骤, 具体推导过程见文献[2]. 令上一时刻多目标后验概率满足式(2), 新生目标概率密度为

$$\pi_B(X) = \Delta(X) \sum_{L \in \mathcal{F}(\mathbf{B})} \omega_B(L) \delta_L(\mathcal{L}(X)) [p_B]^X. \quad (3)$$

其中: $\omega_B(L) = \prod_{i \in \mathbf{B}} (1 - r_B^i) \prod_{l \in L} \frac{1_{\mathbf{B}}(l) r_B^l}{1 - r_B^l}$; \mathbf{B} 为新生目标标签空间, 且 $L \cap \mathbf{B} = \emptyset$; r_B^l 和 $p_B(\mathbf{x}, l)$ 分别为新目标出生概率和概率分布; $1_{\mathbf{B}}(\cdot)$ 为指示函数. 记 $\pi_+(X)$ 为多目标预测分布, 则 δ -GLMB 预测方程为

$$\begin{aligned} \pi_+(X) = & \Delta(X) \sum_{(I_+, \varepsilon) \in \mathcal{F}(\mathbf{L}_+) \times \Theta} \omega_+(I_+; \varepsilon) \delta_{I_+}(\mathcal{L}(X)) [p_+(\cdot; \varepsilon)]^X. \end{aligned} \quad (4)$$

其中

$$\begin{aligned} \omega_+(I_+; \varepsilon) &= \omega_{P, \varepsilon}(I_+ \cap \mathbf{L}) \omega_B(I_+ \cap \mathbf{B}); \\ \omega_{P, \varepsilon}(L) &= [\eta_\varepsilon]^L \sum_{I \subseteq L} 1_I(L) [\rho_\varepsilon]^{I-L} \omega(I; \varepsilon); \\ \rho_\varepsilon(l) &= \langle 1 - p_S(\cdot, l), p(\cdot, l; \varepsilon) \rangle; \end{aligned}$$

$$p_+(\mathbf{x}, l; \varepsilon) = 1_{\mathbf{B}}(l) p_B(\mathbf{x}, l) + 1_{\mathbf{L}}(l) \frac{\langle p_S(\cdot, l) f(\mathbf{x}|\cdot, l), p(\cdot, l; \varepsilon) \rangle}{\eta_\varepsilon(l)};$$

$$\eta_\varepsilon(l) = \int \langle p_S(\cdot, l) f(\mathbf{x}|\cdot, l), p(\cdot, l; \varepsilon) \rangle d\mathbf{x};$$

$f(\mathbf{x}|\mathbf{x}', l)$ 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; $p_S(\mathbf{x}, l)$ 为目标存活概率; $\mathbf{L}_+ = \mathbf{L} \cup \mathbf{B}$; $\langle \cdot \rangle$ 为内积函数.

记量测集合为 $Z = \{z_1, z_1, \dots, z_{|Z|}\}$, 预测分布满足式(4), 则 δ -GLMB 更新方程为

$$\begin{aligned} \pi(X|Z) = & \Delta(X) \sum_{(I_+, \varepsilon) \in \mathcal{F}(\mathbf{L}_+) \times \Theta} \sum_{\zeta} \omega_Z(I_+; \varepsilon, \zeta) \times \\ & \delta_{I_+}(\mathcal{L}(X)) [p(\cdot; \varepsilon, \zeta|Z)]^X. \end{aligned} \quad (5)$$

其中

$$\omega_Z(I_+; \varepsilon, \zeta) \propto \omega_+(I_+; \varepsilon) [\theta_Z(\cdot; \varepsilon, \zeta)]^{I_+};$$

$$p(\mathbf{x}, l; \varepsilon, \zeta|Z) = \frac{p_+(\mathbf{x}, l; \varepsilon) \phi_Z(\mathbf{x}, l; \zeta)}{\theta_Z(l; \varepsilon, \zeta)};$$

$$\theta_Z(l; \varepsilon, \zeta) = \langle p_+(\cdot, l; \varepsilon), \phi_Z(\cdot, l; \zeta) \rangle;$$

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

$g(\mathbf{z}|\mathbf{x}, l)$ 为似然函数; $p_D(\mathbf{x}, l)$ 为目标探测概率; ζ 为目标到量测的关联映射 $\{l_1, l_2, \dots, l_{|I|}\} \rightarrow \{0, 1, \dots, |Z|\}$, 且当 $\zeta(l) > 0$ 时关联具有唯一性.

1.2 多量测问题

在一个监测周期内, 传统 MTT 问题假设单个目标至多产生一个量测, 而在实际应用中单目标可能对应多个量测. 为简化问题, 假设多量测模型为多伯努利过程: 系统包含 M 个测量模型, 一个监测周期内每个模型至多产生一个量测, 对应的观测方程为

$$\mathbf{z} = h_i(\mathbf{x}) + \mathbf{w}_i, i = 1, 2, \dots, M. \quad (6)$$

其中: $h_i(\mathbf{x})$ 为测量函数; \mathbf{w}_i 为测量噪声. 记 $W = \{z_1, z_2, \dots, z_{|W|}\}$, $0 < |W| \leq M$ 为单目标量测集合, 根据文献[8]结论, 多量测似然函数为

$$L(W|\mathbf{x}, l) = L(\emptyset|\mathbf{x}, l) \sum_{\theta} \left(\prod_{\theta(j) > 0} \frac{p_{D,j}(\mathbf{x}, l) g_j(\mathbf{z}_{\theta(j)}|\mathbf{x}, l)}{1 - p_{D,j}(\mathbf{x}, l)} \right). \quad (7)$$

其中: $L(\emptyset|\mathbf{x}, l) = \prod_{i=1}^M (1 - p_{D,i}(\mathbf{x}, l))$; θ 为测量值到观测模型的关联映射 $\{1, 2, \dots, |W|\} \rightarrow \{0, 1, \dots, M\}$; $g_j(\mathbf{z}|\mathbf{x}, l)$, $p_{D,j}(\mathbf{x}, l)$ 分别为与测量模型相关的似然函数和探测概率.

2 多量测标签多伯努利滤波算法

由于预测步骤不涉及观测模型, 多量测条件下多

目标预测方程与原算法一致, 此处不再赘述. 本节主要讨论 MD- δ -GLMB 更新方程及其实现.

2.1 MD- δ -GLMB 更新方程

假设多目标预测分布满足式(4), 杂波个数满足泊松分布, 多量测模型满足式(7). 在上述条件下, 多量测标签多伯努利更新方程为

$$\begin{aligned} \pi(X|Z) = & \Delta(X) \sum_{\mathcal{P} \subset Z} \sum_{\zeta} \sum_{(I_+, \varepsilon) \in \mathcal{F}(L_+) \times \Theta} \tilde{\omega}_Z(I_+; \varepsilon, \zeta) \times \\ & \delta_{I_+}(\mathcal{L}(X)) [\tilde{p}(\cdot; \varepsilon, \zeta | Z)]^X. \end{aligned} \quad (8)$$

其中

$$\begin{aligned} \tilde{\omega}_Z(I_+; \varepsilon, \zeta) & \propto \omega_+(I_+; \varepsilon) [\tilde{\theta}_Z(\cdot; \varepsilon, \zeta)]^{I_+}; \\ \tilde{p}(\mathbf{x}, l; \varepsilon, \zeta | Z) & = \frac{p_+(\mathbf{x}, l; \varepsilon) \psi_Z(\mathbf{x}, l; \zeta)}{\tilde{\theta}_Z(l; \varepsilon, \zeta)}; \\ \tilde{\theta}_Z(l; \varepsilon, \zeta) & = \langle p_+(\cdot, l; \varepsilon), \psi_Z(\cdot, l; \zeta) \rangle; \\ \psi_Z(\mathbf{x}, l; \zeta) & = \frac{L(W_{\zeta(l)} | \mathbf{x}, l)}{\kappa^{W_{\zeta(l)}}}; \end{aligned}$$

$\mathcal{P} \subset Z$: $\{W_0, W_1, \dots, W_{|I|}\}$ 为量测的一种分组, 与文献[8-9]的分组方式不同, $\mathcal{P} \subset Z$ 中量测子集可以为空集; ζ 为目标与测量子集的关联映射 $\{l_1, l_2, \dots, l_{|I|}\} \rightarrow \{0, 1, \dots, |I|\}$, 且映射关系具有唯一性: 若 $\zeta(i) = \zeta(j)$, 则 $i = j$; $\kappa(\mathbf{z})$ 为泊松杂波密度. 多量测更新方程的推导过程与原算法类似, 此处不再详述.

2.2 实现优化

MD- δ -GLMB 的更新过程主要包含 3 步: 对量测进行分组; 将量测子集与预测航迹进行关联得到新的假设; 最后计算新假设对应的权值和概率分布. 量测分组过程极大地增加了算法计算开销, 常用的优化策略有聚类方法^[11]、距离分区^[12]和航迹分组^[3]等. 若式(6)中多个测量函数不同(如多径目标), 则基于马氏距离的分组优化方法不再适用, 因为同一目标不同测量方程对应的量测值可能相差较大. 针对该问题, 本文采用假设分解^[4]方法对关联过程进行降维, 图 1 描述了具体过程.

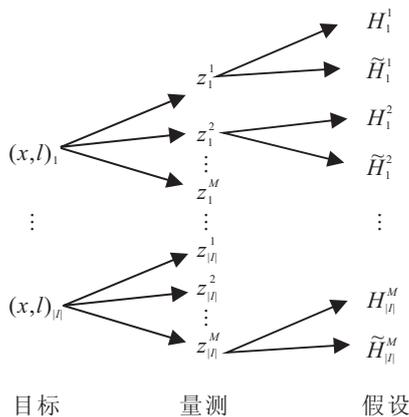


图 1 假设分解

图 1 中: $(\mathbf{x}, l)_i$ ($i = 1, 2, \dots, |I|$) 为预测航迹; z_i^j ($j = 1, 2, \dots, M$) 为可能存在的量测; H_i^j, \tilde{H}_i^j 分别为 z_i^j 被检测或漏检. 假设分解方法通过枚举所有可能存在的量测而避免了量测分组, 并且更新步仍存在闭集解, 但需假设多量测的个数有限.

针对单个预测假设 (I, ε) , 式(8)需要考虑的分组数目为 $\sum_{k=1}^{|I|+1} s(|Z|, k)$, 其中 $s(\cdot, \cdot)$ 为第 2 类 Stirling 数. 在此基础上, 将每个分组的子集与预测航迹进行关联排序, 当量测较多时这种方法显然难以实现. 使用假设分组方法, 单个预测假设仅需进行一次关联. 若考虑所有可能假设, 则更新过程仍为 NP-Hard 问题, 因此需要对假设进行截断. 构造代价函数

$$\begin{aligned} C(i, j; \varepsilon, \tilde{\theta}) = & \langle p(\cdot, l_i; \varepsilon), P_{D,j}(\cdot, l_i) g_j(z_{\tilde{\theta}(j)} | \cdot, l_i) \rangle \\ & - \log \frac{\langle p(\cdot, l_i; \varepsilon), 1 - P_{D,j}(\cdot, l_i) \rangle \kappa(z_{\tilde{\theta}(j)})}{\langle p(\cdot, l_i; \varepsilon), 1 - P_{D,j}(\cdot, l_i) \rangle \kappa(z_{\tilde{\theta}(j)})}, \end{aligned} \quad (9)$$

其中 $\tilde{\theta}$ 为量测假设到量测集合的关联映射 $\{1, 2, \dots, M \times |I|\} \rightarrow \{0, 1, \dots, |Z|\}$. 通过 Murty 算法^[13]能有效解决 2-D 排序问题, 其计算复杂度为 $\mathcal{O}(M|Z|^3)$, 文献[14]对误差进行了分析. 另外, 门限裁剪、 k 最短路径和 PHD/CPHD 预处理等近似方法也能在一定程度上提高滤波效率^[14].

3 仿真分析

3.1 实验设置

由文献[12]设置一种 2D 运动场景. 观测区间为 $[200, 1000] \times [200, 1000]$ (km), 目标状态 $\mathbf{x}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$, (x_k, y_k) 为位置信息, (\dot{x}_k, \dot{y}_k) 为速度信息. 目标进行近匀速运动, 状态转移矩阵为

$$\mathbf{I}_2 \otimes \begin{bmatrix} 1 & \tau \\ 0 & 1 \end{bmatrix}.$$

其中: \mathbf{I}_2 为 2 阶单位矩阵, 探测间隔 $\tau = 20$ s, \otimes 为 Kronecker 积. 过程噪声分布为

$$\mathbf{v}_k \sim N\left(\mathbf{0}, \mathbf{I}_2 \otimes \begin{bmatrix} q \frac{\tau^3}{3} & q \frac{\tau^2}{2} \\ q \frac{\tau^2}{2} & q\tau \end{bmatrix}\right),$$

其中噪声密度 $q = 10^{-8}$ km²/s³.

OTHR 信号传播模型如图 2 所示. 观测向量 $\mathbf{z}_k = [z_{r,k}, z_{\dot{r},k}, z_{\alpha,k}]^T$ 包含了径向距离、多普勒和方位角信息. 多径观测模型为 $\mathbf{z}_k = h_l(\mathbf{x}_k) + \mathbf{w}_{l,k}$. 其中: l 包括 EE、EF、FE、FF 四种模式, 对应的观测方程为

$$h_l(\mathbf{x}_k) = \begin{bmatrix} r_{l,k} + r'_{l,k} \\ \frac{\dot{\rho}_k}{4} \left(\frac{\rho_k}{r_{l,k}} + \frac{\rho_k - d \sin b_k}{r'_{l,k}} \right) \\ \sin^{-1} \left(\frac{\rho_k \sin b_k}{2r_{l,k}} \right) \end{bmatrix},$$

这里

$$r_{l,k} = \sqrt{\left(\frac{\rho_k}{2}\right)^2 + h_{r,l}^2},$$

$$r'_{l,k} = \sqrt{\left(\frac{\rho_k}{2}\right)^2 - d\left(\frac{\rho_k}{2}\right) \sin b_k + \frac{d^2}{4} + h_{t,l}^2},$$

$$\rho_k = \sqrt{x_k^2 + y_k^2}, \dot{\rho}_k = \frac{x_k \dot{x}_k + y_k \dot{y}_k}{\rho_k};$$

接收站与发射站距离 $d = 1 \text{ km}$, $h_{r,l}$ 和 $h_{t,l}$ 分别为传播接收和发射信号的电离层高度, 并假设 E、F 层高度为常数 $h_E = 180 \text{ km}$, $h_F = 220 \text{ km}$; $w_{l,k}$ 为零均值高斯观测噪声, 假设所有模型噪声标准差相同, $\sigma_r = 1 \text{ km}$, $\sigma_{\dot{r}} = 0.005 \text{ km/s}$, $\sigma_\alpha = 0.004 \text{ rad}$, 探测概率为 $p_{D,j} = 0.6$. 杂波在观测区间均匀分布, 杂波个数服从 $\lambda_C = 5$ 的泊松分布.

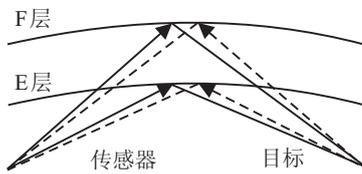


图2 信号传播模型

新生目标满足多伯努利分布

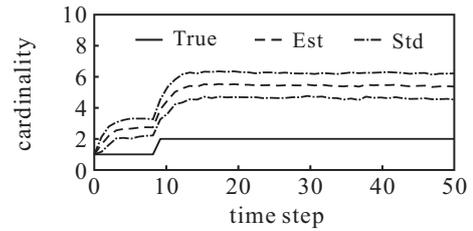
$$\pi_B(X) = \{(r_B^i, p_B^i(\mathbf{x}))\}, i = 1, 2.$$

其中: $p_B^i(\mathbf{x}) \sim N(\mathbf{x}_{B,i}, \Gamma_{B,i}^T \Gamma_{B,i})$; $r_B^i = 0.05$, $\Gamma_{B,i} = \text{diag}([5, 0.02, 5, 0.02])$, $i = 1, 2$; $\mathbf{x}_{B,1} = [290, 0.25, 450, 0.3]^T$, $\mathbf{x}_{B,2} = [600, -0.15, 520, 0.2]^T$. 实验共设置两个多量测目标: 目标分别从新生区域 1 和 2 出生, 新生时间步分别为 1 和 10, 消亡时间步均为 50.

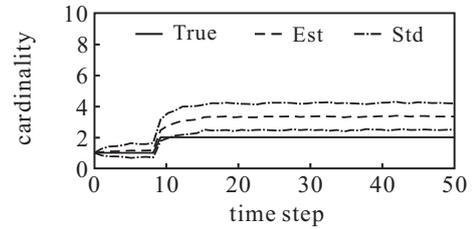
实验对比了 δ -GLMB、MD-PHD 和 MD- δ -GLMB 算法 200 次 Monte Carlo 实验的平均结果. 4 种算法均通过粒子滤波框架实现, 单目标粒子规模最大值为 1000, 最小值为 300. δ -GLMB 使用 EE 和 EF 两种探测模型. δ -GLMB 和 MD- δ -GLMB 假设数量上限为 10^4 , 裁剪门限为 10^{-3} .

3.2 结果分析

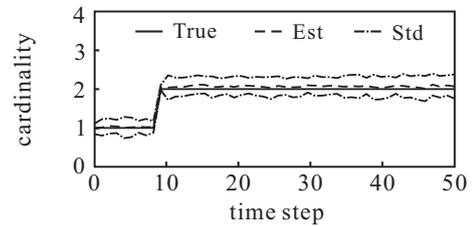
上述条件下, 4 种算法的平均目标数估计结果如图 3 所示. 可以看出, MD-PHD 和 MD- δ -GLMB 均能对目标数进行无偏估计, 但后者估计结果的标准差明显小于前者. 与 PHD 类似, MD-PHD 仅对概率密度一阶矩进行递推, 目标数估计结果实质为均值的近似. 所提出算法完整递推了多目标多伯努利分布, 算法实现时采用的假设裁剪等近似过程是信息损失的主要来源. 同时, 所提出算法避免了量测分组误差, 因此目标数估计稳定性优于 MD-PHD. 另一方面, 多量测环境中两种标准算法均出现了明显的目标数过估现象. 在 OTHR 模型中, EF 模式与 FE 模式量测值非常接近, 因此使用单模型跟踪多径目标时, EF 模式过估比 EE 模式更严重.



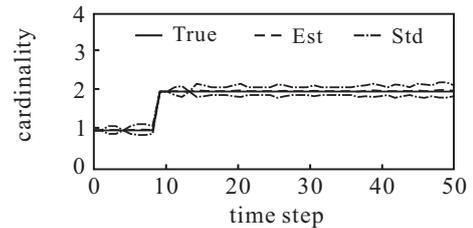
(a) δ -GLMB(EF mode)



(b) δ -GLMB(EE mode)



(c) MD-PHD



(d) MD- δ -GLMB

图3 不同算法的势估计结果

不同算法的平均 OSPA 距离如图 4 所示, 其中 OSPA 距离参数设置为 $p = 1$, $c = 300 \text{ km}$. 可以看出, MD- δ -GLMB 的 OSPA 距离小于 MD-PHD, 表现出良好的多量测目标跟踪性能. 除上文分析原因外, 通过粒子滤波实现算法时, 由于避免了聚类过程, MD- δ -GLMB 的目标状态提取过程比 MD-PHD 更稳定可靠. 由于目标数严重过估, 原算法的平均 OSPA 距离远大于改进算法.

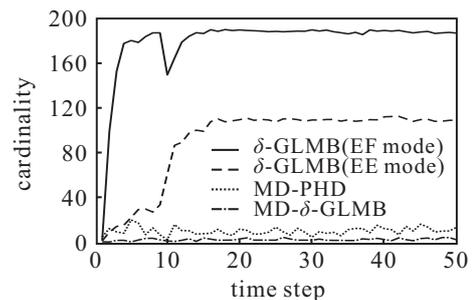


图4 不同算法的 OSPA 距离

MD-PHD 和 MD- δ -GLMB 在不同探测概率条件下的时间平均 OSPA 距离与单步迭代运行时间如

表 1 所示,为简化问题,此处未考虑标准算法.计算平台为一台普通个人计算机,低探测概率时,所提出算法跟踪精度明显更优.这主要是因为 MD-PHD 假设目标数服从泊松分布,对漏警敏感,探测概率较低时性能严重下降. MD- δ -GLMB 利用多帧量测信息对多假设进行回溯处理,抗干扰性能更好.由文献 [8] 可知, MD-PHD 分组个数与 Bell 数的数量级相同,这极大地限制了该算法的应用范围.随着探测概率的升高,传感器接收到的量测数目增加, MD-PHD 的计算开销增幅明显高于所提出算法.

表 1 不同探测概率条件下平均 OSPA 距离和运算时间

	探测概率	0.7	0.6	0.5	0.4	0.3
OSPA 距离/km	MD-PHD	8.6	15.8	36.2	72.6	92.8
	MD- δ -GLMB	5.1	4.4	4.9	5.5	7.9
运算时间/(步/s)	MD-PHD	3.59	1.52	0.80	0.41	0.31
	MD- δ -GLMB	0.85	0.77	0.66	0.58	0.51

4 结 论

本文提出了一种基于 δ -GLMB 滤波框架的多量测多目标跟踪算法.基于贝叶斯估计理论,推导了新的更新方程,采用假设分解等方法改善了滤波效率.实验分析表明,所提出算法能对多量测目标进行有效跟踪,低信噪比环境下跟踪精度明显优于 MD-PHD 算法,且计算效率较高,具有良好的应用前景.此外,所提出算法对扩展目标、群目标和多传感器多目标跟踪有一定的参考意义.

参考文献(References)

- [1] Vo B N, Vo B T, Reuter S, et al. Towards large scale multi-target tracking[C]. Proc of Sensors and Systems for Space Applications. Bellingham: SPIE, 2014: 1-6.
- [2] 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.
- [3] 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.
- [4] Sathyan T, Chin T J, Arulampalam S, et al. A multiple hypothesis tracker for multitarget tracking with multiple simultaneous measurements[J]. IEEE J of Selected Topics in Signal Processing, 2013, 7(3): 448-460.

- [5] 刘伟峰,柴中,文成林.基于随机采样的多量测目标跟踪算法[J].自动化学报,2013,39(2):168-178.
(Liu W F, Chai Z, Wen C L. Multi-measurement target tracking by using random sampling approach[J]. Acta Automatic Sinica, 2013, 39(2): 168-178.)
- [6] 连峰,马东东,元向辉,等.扩展目标 CBMeMber 滤波器及其高斯混合实现[J].控制与决策,2015,30(4):611-616.
(Lian F, Ma D D, Yuan X H, et al. CBMeMber filter for extended targets and its Gaussian mixture implementations[J]. Control and Decision, 2015, 30(4): 611-616.)
- [7] Habtemariam B, Tharmarasa R, Thayaparan T, et al. A multiple-detection joint probabilistic data association filter[J]. IEEE J of Selected Topics in Signal Processing, 2013, 7(3): 461-471.
- [8] Tang X, Chen X, McDonald M, et al. A multiple-detection probability hypothesis density filter[J]. IEEE Trans on Signal Processing, 2015, 63(8): 2007-2019.
- [9] Mahler R. The multisensor PHD filter, I: General solution via multitarget calculus[C]. Proc of Signal Processing, Sensor Fusion, and Target Recognition. Orlando: SPIE, 2009: 1-6.
- [10] Clark D, Mahler R. Generalized PHD filters via a general chain rule[C]. Proc of Int Conference on Information Fusion. Singapore: IEEE, 2012: 157-164.
- [11] Li Y, Xiao H, Song Z, et al. A new multiple extended target tracking algorithm using PHD filter[J]. Signal Processing, 2013, 93(12): 3578-3588.
- [12] Granstrom K, Lundquist C, Orguner U. Extended target tracking using a Gaussian-mixture PHD filter[J]. IEEE Trans on Aerospace and Electronic Systems, 2012, 48(4): 3268-3286.
- [13] Miller M, Stone H, Cox I. Optimizing Murty's ranked assignment method[J]. IEEE Trans on Aerospace and Electronic Systems, 1997, 33(3): 851-862.
- [14] 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.

(责任编辑:郑晓蕾)