E-mail: csa@iscas.ac.cn http://www.c-s-a.org.cn Tel: +86-10-62661041

基于 GGIW-PMB 的衍生扩展目标跟踪^①

吕晓燕¹, 吴孙勇^{1,2}, 蔡如华¹, 郑翔飞¹, 谢 芸¹

¹(桂林电子科技大学 数学与计算科学学院, 桂林 541004) ²(桂林电子科技大学 广西精密导航技术与应用重点实验室, 桂林 541004) 通信作者: 吴孙勇, E-mail: wusunyong121991@163.com

摘要: 针对标准的扩展目标泊松多伯努利 (Poisson multi-Bernoulli, PMB) 滤波器难以有效跟踪衍生目标的问题, 提出一种改进的 PMB 跟踪算法. 算法采用随机矩阵法对扩展目标外形和尺寸建模, 在滤波预测阶段利用多假设模 型对衍生事件进行预测, 得到多个伽玛高斯逆威沙特 (gamma Gaussian inverse Wishart, *GGIW*) 预测假设分量, 最后 在滤波更新阶段对预测分量更新得到扩展目标的运动状态和扩展形状估计. 仿真结果表明, 与标准的 PMB 滤波算 法相比, 所提算法有效改善衍生扩展目标的跟踪性能.

关键词:扩展目标; 泊松多伯努利 (PMB); 衍生目标; 伽玛高斯逆威沙特 (GGIW); 多假设模型; 多目标跟踪

引用格式: 吕晓燕,吴孙勇,蔡如华,郑翔飞,谢芸.基于 GGIW-PMB 的衍生扩展目标跟踪.计算机系统应用,2023,32(5):220-226. http://www.c-s-a.org.cn/1003-3254/9104.html

Spawning Extended Target Tracking Based on GGIW-PMB

LYU Xiao-Yan¹, WU Sun-Yong^{1,2}, CAI Ru-Hua¹, ZHENG Xiang-Fei¹, XIE Yun¹

¹(School of Mathematics & Computing Science, Guilin University of Electronic Technology, Guilin 541004, China) ²(Guangxi Key Laboratory of Precision Navigation Technology and Application, Guilin University of Electronic Technology, Guilin 541004, China)

Abstract: The standard Poisson multi-Bernoulli (PMB) filter for extended targets can hardly track spawning targets effectively. To resolve this problem, this study proposes an improved PMB tracking algorithm. The algorithm uses a random matrix method to model shapes and dimensions of extended targets and adopts a multi-hypothesis model to predict spawning targets in the filtering prediction stage and obtain multiple hypothetical components of gamma Gaussian inverse Wishart (*GGIW*). Finally, it updates the predicted components in the filtering update stage to estimate the motion state and expansion shapes of extended targets. Simulations show that the proposed algorithm has better tracking performance for spawning extended targets in comparison with the standard PMB filtering algorithm.

Key words: extended target; Poisson multi-Bernoulli (PMB); spawning target; gamma Gaussian inverse Wishart (*GGIW*); multi-hypothesis model; multi-target tracking

早期目标跟踪通常假设每个目标在给定的时间步 长最多可以产生一个量测值^[1].利用现代更精确的传感 器,目标可能占据传感器的多个分辨单元,从而在给定 时间步长产生多个量测,这些目标被称为扩展目标^[2]. 扩展目标跟踪的应用包括使用汽车雷达的车辆跟踪、 使用地面或者海上雷达站跟踪足够近的飞机或者船 舶等.

Mahler 首先将随机有限集 (random finite set, RFS) 引入到扩展目标跟踪^[3],将扩展目标状态集和量测数据 集均建模为随机有限集,避免了数据关联问题. Koch



① 基金项目:国家自然科学基金(62263007);桂林电子科技大学数学与计算科学学院研究生创新项目(2022YJSCX02) 收稿时间:2022-11-06;修改时间:2022-12-23;采用时间:2022-12-29; csa 在线出版时间:2023-03-30
 CNKI 网络首发时间:2023-03-30

²²⁰ 软件技术•算法 Software Technique•Algorithm

提出利用对称正定的随机矩阵 (random matrix, RM) 方 法将目标外形建模成椭圆[4],并首次将贝叶斯方法应用 于椭圆外形的扩展目标跟踪,在忽略传感器误差的假 设条件下给出贝叶斯估计的封闭形式解. 文献 [5] 首先 将该方法用于概率假设密度 (probability hypothesis density, PHD) 滤波器, 提出了基于随机矩阵的扩展目 标高斯逆威沙特概率假设密度 (Gaussian inverse Wishartprobability hypothesis density, GIW-PHD) 滤波器, 实现 对扩展目标的运动学特征和外形状态估计. 文献 [6] 将 扩展目标量测比建模为伽玛分布,提出能够实时估计 目标量测比率与扩展目标状态的伽玛高斯逆威沙特 (gamma Gaussian inverse Wishart, GGIW) 模型, 文献 [7] 将 GGIW 模型应用于扩展目标多伯努利 (multi-Bernoulli, MB) 滤波器. 针对上述滤波器未能直接形成目标轨迹 的问题, 文献 [8] 将广义标签多伯努利算法应用于扩展 目标跟踪,并将目标状态建模为 GGIW 分布, 通过标签 追溯目标的运动轨迹. Granström 等人提出了泊松多伯 努利混合 (Poisson multi-Bernoulli mixture, PMBM) 算 法,并在扩展目标跟踪中取得比δ-GLMB 算法更好的 滤波性能^[9,10], 文献 [11] 对 PMBM算法做出改进, 提出 一种泊松多伯努利 (Poisson multi-Bernoulli, PMB) 算 法,该算法假设目标状态服从 GGIW 分布,将描述后验 分布的多个伯努利混合近似为单个伯努利以减少计算 量,维持稳定的滤波性能.

衍生是扩展目标的重要运动方式,在军事的体现 有战斗机发射导弹、飞机在航母上起飞等. 文献 [12] 首先提出了扩展目标衍生的研究工作,基于随机矩阵 提出了一种衍生目标状态期望值与原始目标状态期望 值相同的衍生模型,衍生目标的扩展也保持了原始目 标扩展的预期值. 当原始目标的外形尺寸与衍生出的 目标尺寸不一致时,这样的简单衍生模型并不适用. 针 对该问题,文献 [13] 提出多假设模型,考虑了衍生目标 的合理备选方案,并验证所提的模型提高了 GGIW-PHD 滤波器对衍生扩展目标的跟踪性能. 之后将学者 们多假设模型结合 CPHD、δ-GLMB 和 PMBM 等滤 波器开展了一系列的研究工作^[14-16],提高了滤波器对 衍生目标的跟踪性能.

本文在文献 [11] 的基础上, 提出一种改进的 GGIW-PMB 滤波算法. 在滤波算法的预测阶段利用多假设模 型^[12] 对衍生事件建模, 根据给定的假设值, 产生多个衍 生假设分量,将衍生分量建模为 GGIW 形式,最后在 PMB 滤波框架下利用量测数据对每个假设分量更新, 实现原始目标和衍生目标的有效跟踪,增强算法的适 用性.

1 扩展目标模型

假设在k时刻扩展目标状态为:

$$X_{k} = \left\{ \xi_{k}^{i} = \left(\gamma_{k}^{i}, x_{k}^{i}, X_{k}^{i} \right) \right\}_{i=1}^{N_{x,k}}$$
(1)

其中, $N_{x,k}$ 表示k时刻目标的数量, γ'_k 表示第i个目标k时 刻的泊松均值, x'_k 表示第i个目标的运动学状态, 例如目 标的位置、速度等其他参数, X^i_k 表示第i个目标的外形 及尺寸.

目标运动模型为:

$$x_{k+1}^{i} = (F_{k+1|k} \otimes I_d) x_k^{i} + \varpi_{k+1}^{i}$$
(2)

其中, $F_{k+1|k}$ 为状态转移矩阵, ϖ_{k+1}^i 为协方差为 $Q_{k+1|k} \otimes X_{k+1}^i$ 的零均值高斯白噪声.

假设 $z_x = \{z_k^j\}_{j=1}^{N_{z,k}} 为 k$ 时刻扩展目标的量测集,则量 测模型可表示为:

$$z_k^j = (H_k \otimes I_d) x_k^i + e_k^j \tag{3}$$

其中, e_k^j 是协方差为 X_k^j 的高斯白噪声, H_k 为量测矩阵. k时刻的量测集合包括目标产生的量测和杂波产生的量测, 且表示为两者的并集:

$$Z_k = z_x(z) \cup z_c(z) \tag{4}$$

其中, zc(z)表示杂波量测.

假设k时刻, $\gamma_k \sim GAM(\gamma_k, \alpha_k, \beta_k)$ 表示泊松分布的 均值; $x_k \sim N(x_k; m_k, P_k \otimes X_k)$ 表示目标质心的运动状态; $X_k \sim IW(X_k; v_k, V_k)$ 表示目标的扩展状态. 令 $Z^k = \{Z_1, \dots, Z_k\}$ 代表直到k时刻所有量测的集合, 假设扩展目标状态 估计服从 GGIW 分布:

$$p(\xi_k) = GAM(\gamma_k; \alpha_k, \beta_k) N(x_k; m_k, P_k \otimes X_k) \cdot IW(X_k; v_k, V_k)$$
$$= GGIW(\xi_k, \zeta_k)$$
(5)

其中, $\xi_k \triangleq (\gamma_k, x, X_k)$ 为k时刻扩展目标的待估计状态; $\zeta_k = (\alpha_k, \beta_k, m_k, P_k, v_k, V_k)$ 为 *GGIW*分量的参数.

2 PMB 滤波器

PMB 分为泊松点过程 (Poisson point process, PPP) 部分和多伯努利 (MB) 部分, 其中 PPP 部分表示目标 存在但未被传感器检测到的目标, 由符号X"表示; MB

```
Software Technique•Algorithm 软件技术•算法 221
```

部分表示多目标演化过程中存在并被传感器检测到的 目标的分布情况,由符号 X^d , 且 $X = X^u \cup X^d$, $X^u \cap X^d = \phi$.

. . .

假设k-1时刻的后验 PMB 密度参数为:

$$D^{u}, \left(r^{i}, f^{i}(\cdot)\right)_{i \in \mathbb{I}} \tag{6}$$

则k时刻的预测 PMB 密度参数为:

$$D_{k|k-1}^{u}, \left(r_{k|k-1}^{i}, f_{k|k-1}^{i}(\cdot)\right)_{i \in \mathbb{I}}$$
(7)

其中,

$$D_{k|k-1}^{u}(X) = D^{b}(X) + \langle D^{u}, p_{s}f_{k|k-1} \rangle$$
(8)

$$r_{k|k-1}^{i} = \left\langle f^{i}, p_{s} \right\rangle r^{i} \tag{9}$$

$$f_{k|k-1}^{i} = \frac{\left\langle f^{i}, p_{s} f_{k|k-1} \right\rangle}{\left\langle f^{i}, p_{s} \right\rangle} \tag{10}$$

其中, r为伯努利分量的权重, fⁱ(·)表示第i个伯努利的 密度函数, f(·)为状态转移模型, D^b代表泊松点过程新 生强度.

假设给出预测步的 PMB 密度参数如式 (7) 和量测 集合Z^k,将预测步得到的 PMB 密度进行更新,得到的 后验为 PMBM 形式,其参数为:

$$\hat{D}^{u}_{k|k}, \left\{ \left(W^{j}_{k|k}, \left\{ \left(\hat{r}^{j,i}_{k|k}, \hat{f}^{j,i}_{k|k} \right) \right\}_{i \in \mathbb{I}} \right) \right\}_{j \in \mathbb{J}}$$
(11)

其中, PPP 部分的更新为:

$$D^{u}(X) = (1 - p_D) D^{u}_{k|k-1}(X)$$
(12)

pD表示独立于目标状态的检测概率.

对于之前存在的目标,每个单目标假设可能包含 误检的目标,或者使用量测更新的目标.对于误检的目标,伯努利密度参数为:

$$r^{i,j} = \frac{r^{i}_{k|k-1} \left\langle f^{i}_{k|k-1}, (1-p_D) \right\rangle}{1 - r^{i}_{k|k-1} + r^{i}_{k|k-1} \left\langle f^{i}_{k|k-1}, p_D \right\rangle}$$
(13)

$$f^{j,i}(X) = \frac{(1-p_D)(X)f^i_{k|k-1}(X)}{\left\langle f^i_{k|k-1}, (1-p_D) \right\rangle}$$
(14)

其中,单目标假设的更新轨迹对应的伯努利参数为:

$$r^{j,i} = 1 \tag{15}$$

$$f^{j,i}(X) = \frac{l(X)f^{i}_{k|k-1}(X)}{\left\langle f^{i}_{k|k-1}, l(X) \right\rangle}$$
(16)

其中, *l*(*X*)为单个伯努利分量的似然函数, *r*^{*j*,*i*}(·)表示第 *j*个多伯努利中第*i*个伯努利的存在概率, *f*^{*j*,*i*}(·)表示第

222 软件技术•算法 Software Technique•Algorithm

j个多伯努利中第i个伯努利的密度函数.

为了减少多伯努利的数量, 需要从 PMBM 滤波器 中获得保留尽可能多信息的 PMB 滤波器, 实现该滤波 器需要最小化 PMBM 与 PMB 之间的 KL 散度^[11], 将 多伯努利混合部分近似为单个伯努利分量来处理, 即:

$$\arg\min_{e} D_{KL}\left(f_{k|k}\left(X_{k}\right) \parallel \hat{f}_{k|k}\left(X_{k}\right)\right) \tag{17}$$

其中, $\hat{f}_{k|k}(X_k)$ 被限制为 PMB, 则更新后的 PMB 密度参数为:

$$D^{u}_{k|k}, \left(\hat{r}^{i}_{k|k}, \hat{f}^{i}_{k|k}\right)_{i \in \mathbb{I}}$$
(18)

其中, $D_{k|k}^{u}$ 表示 PPP 部分的强度, $\hat{r}_{k|k}^{i}$ 表示第i个伯努利存在概率, $\hat{f}_{k|k}^{i}$ 表示第i个伯努利密度.

3 改进的 GGIW-PMB 滤波算法

假设在k-1时刻, 后验密度函数是 GGIW 混合的形式:

$$D_{k-1}^{u}(X) = \sum_{n=1}^{N^{u}} \omega_{k-1}^{u,n} GGIW(X; \zeta_{k-1}^{u,n})$$
(19)

其中, $\zeta_{k-1}^{u,n} = \{\alpha_{k-1}, \beta_{k-1}, m_{k-1}, P_{k-1}, v_{k-1}\}, \omega_{k-1}^{u,n}$ 表示 GGIW 分量的权重, 第*i*个伯努利分量也是 GGIW 的 形式:

$$f_{k-1}^{i} = GGIW\left(X; \zeta_{k-1}^{i}\right) \tag{20}$$

 预测.若有衍生事件发生,则需要考虑原目标和 衍生目标的预测,所以预测阶段包括未发生衍生事件 分量的预测和衍生分量的预测两部分.k时刻未发生衍 生事件的 GGIW 分量的预测过程为:

$$D_{k|k-1}^{u}(X) = \sum_{n=1}^{N^{b}} \omega_{k}^{b,n} GGIW(X; \zeta_{k}^{b,n}) + \sum_{n=1}^{N^{u}} \omega_{k|k-1}^{u,n} GGIW(X; \zeta_{k|k-1}^{u,n})$$
(21)

$$\omega_{k|k-1}^{u,n} = \omega_{k-1}^{u,n} p_S \tag{22}$$

$$r_{NT,k|k-1}^{i} = p_{S} r_{k-1}^{i}$$
(23)

$$f_{NT,k|k-1}^{i}(X) = GGIW\left(X; \zeta_{k|k-1}^{i}\right)$$
(24)

其中, $\omega_k^{b,n}$ 为新生目标的权重, $\zeta_k^{b,n}$ 新生目标的 *GGIW* 分量, p_S 表示目标的存活概率, 其中 *GGIW* 分量参数的计算如下:

$$\begin{cases} \alpha_{k|k-1} = \frac{\alpha_{k-1}}{\eta} \\ \beta_{k|k-1} = \frac{\beta_{k-1}}{\eta} \\ m_{k|k-1} = Fm_{k-1} \\ P_{k|k-1} = FP_{k-1}F^{T} + Q \\ v_{k|k-1} = 2d + 2 + e^{-T_{s}/\tau} (v - 2d - 2) \\ V_{k|k-1} = e^{-T_{s}/\tau}MV_{k-1}M^{T} \end{cases}$$
(25)

其中, M为转化矩阵, T_s 采样时间, τ 为运动相关常数, η 为量测率参数.

假设衍生事件发生在量测产生之间,即在扩展目标跟踪滤波的预测步骤中,且每个目标在每个时刻只产生一个衍生目标.由于衍生目标相对于原目标的运动状态发生了变化,若直接忽略对衍生目标的预测,将会导致在衍生时刻无法检测跟踪到衍生目标,对于该问题本文利用多假设模型对衍生目标建模,在预测阶段根据给定的衍生假设值,产生多个假设的衍生先验信息,其中每个假设代表一个可能的衍生事件,即假设衍生事件发生在k时刻,未发生衍生事件的GGIW分量参数如式(25),则衍生目标状态为:

 $\xi_{t,k|k-1}^{(l,\kappa)} = \{\gamma_{k|k-1}^{(t)}, x_{k|k-1}^{(t)}, X_{k|k-1}^{(t)}\}_{t=1}^{2}, l = 1, 2, \cdots, d$ (26) 其中, κ 为衍生假设值, d为扩展目标的外形维度. 然后 将衍生目标状态建模成 GGIW形式, 假设 $\zeta_{1,k|k-1}^{(l,\kappa)}$ 和 $\zeta_{2,k|k-1}^{(l,\kappa)}$ 分别为给定每一个衍生假设值 κ 和每个扩展状态 维度l对应的衍生估计对的 GGIW分量, 参数计算如下:

$$\zeta_{k|k-1}^{(1,l,\kappa)} = \left(\alpha_{k|k-1}, \frac{\beta_{k|k-1}}{\kappa}, m_{k|k-1}^{(1,l,\kappa)}, P_{k|k-1}^{(1,l,\kappa)}, v_{k|k-1}^{(l,\kappa)}, \kappa V_{k|k-1}^{(l,\kappa)}\right) (27)$$

$$\zeta_{k|k-1}^{(2,l,\kappa)} = \left(\alpha_{k|k-1}, \frac{\beta_{k|k-1}}{\kappa}, m_{k|k-1}^{(2,l,\kappa)}, P_{k|k-1}^{(2,l,\kappa)}, v_{k|k-1}^{(l,\kappa)}, (1-\kappa)V_{k|k-1}^{(l,\kappa)}\right) (28)$$

其中,

$$m_{k|k-1}^{(1,l,k)} = m_{k|k-1} + (1-\kappa) \sqrt{e_l} H^{\mathrm{T}} v_l$$
(29)

$$m_{k|k-1}^{(2,l,\kappa)} = m_{k|k-1} - \kappa \sqrt{e_l} H^{\mathrm{T}} v_l$$
(30)

$$P_{k|k-1}^{(i,l,\kappa)} = P_{k|k-1}, i = 1, 2$$
(31)

假设有*K*个不同的衍生假设值κ,则在预测阶段将 产生2*dK*个不同的 *GGIW* 假设分量.由同一目标衍生 出的两个目标是相关的,而由不同目标衍生出的两个 目标是相互独立的.基于 KL-DIV 准则对衍生分量的 联合密度分布作近似[15]:

$$r_{T,k|k-1}^{i} = p_{S} \omega_{sp} r_{k-1}^{i}$$
(32)

$$\bar{f}_T^i(X_{1:2,k,k-1}) \triangleq \bar{f}_T^i(X_{1,k|k-1}, X_{2,k|k-1})$$
(33)

$$\bar{f}_{T}^{i}(X_{1:2,k|k-1}) \approx \sum_{l=1}^{d} \delta(l) GGIW\left(X_{1,k|k-1}^{(l,\kappa)};\zeta_{1,k|k-1}^{(l,\kappa)}\right) \\
\times GGIW\left(X_{2,k|k-1}^{(l,\kappa)};\zeta_{2,k|k-1}^{(l,\kappa)}\right) \\
= \sum_{l=1}^{d} \delta(l) \prod_{t=1}^{2} f_{T}^{i}\left(X_{t,k|k-1}^{(i,\kappa)}\right)$$
(34)

其中, $f_T^i(X_{1:2,k|k-1})$ 是联合概率密度, ω_{sp} 为衍生权重, 结 合未发生衍生事件分量的 PMB 密度 f_{NT}^i , 因此可得到 近似的预测 PMB 密度形式:

$$D_{k|k-1}^{u}, \left(\hat{r}_{k|k-1}^{i}, \hat{f}_{k|k-1}^{i}\right)_{i \in \mathbb{I}}$$
(35)

$$\left(\hat{r}_{k|k-1}^{i}, \hat{f}_{k|k-1}^{i}\right) = \left\{\left(r_{NT,k|k-1}^{i}, f_{NT,k|k-1}^{i}\right), \left(r_{T,k|k-1}^{i}, f_{T,k|k-1}^{i}\right)\right\}$$
(36)

• 更新. 假设给出如式 (5) 的预测 PMB 密度分布, 更新阶段的概率密度由以下 4 个部分组成.

(1) PPP 漏检

$$D^{u}(X) = \sum_{n=1}^{N^{u}} \left(\omega_{1}^{u,n} GGIW(X;\zeta_{1}^{u,n}) + \omega_{2}^{u,n} GGIW(X;\zeta_{2}^{u,n}) \right) \quad (37)$$

其中,

$$\omega_1^{u,n} = (1 - p_D) \omega_{k|k-1}^{u,n}$$
(38)

$$\omega_2^{u,n} = p_D \left(\frac{\beta_{k|k-1}^{u,n}}{\beta_{k|k-1}^{u,n} + 1} \right)^{\alpha_{k|k-1}^{u,n}} \omega_{k|k-1}^{u,n}$$
(39)

$$\zeta_{1}^{u,n} = \zeta_{k|k-1}^{u,n} \tag{40}$$

$$\zeta_{2}^{u,n} = \left\{ \alpha_{k|k-1}^{u,n}, \beta_{k|k-1}^{u,n} + 1, m_{k|k-1}^{u,n}, P_{k|k-1}^{u,n}, v_{k|k-1}^{u,n}, V_{k|k-1}^{u,n} \right\}$$
(41)
(2) PPP 更新

根据文献 [17] 的距离划分方法对量测集Z^k划分, 得到划分后的量测单元*C*, PPP 部分的更新如下:

$$r_{C}^{\mu} = \begin{cases} 1, & \text{if } |C| > 1 \\ \frac{L_{C}}{\kappa^{C} + L_{C}}, & \text{if } |C| = 1 \end{cases}$$
(42)

$$f_{C}^{u}(X) = \frac{\sum_{n=1}^{N^{u}} \omega_{k|k-1}^{u,n} p_{D} L_{C}^{u,n} GGIW(X;\zeta_{C}^{u,n})}{\sum_{n=1}^{N^{u}} \omega_{k|k-1}^{u,n} p_{D} L_{C}^{u,n}}$$
(43)

Software Technique•Algorithm 软件技术•算法 223

$$L_{C}^{u} = \sum_{n=1}^{N^{u}} \omega_{k|k-1}^{u,n} p_{D} l_{C}^{u,n}$$
(44)

其中, $\kappa^{C} = \lambda c(z)$ 表示杂波强度, 其中 λ 为杂波率, c(z)为杂波空间分布; $\zeta_{C}^{u,n} \pi l_{C}^{u,n}$ 的具体计算见文献 [9].

(3) MBM 漏检

$$r_{\phi}^{j,i} = \frac{r_{k|k-1}^{i}q_{D}^{i}}{1 - r_{k|k-1}^{i} + r_{k|k-1}^{i}q_{D}^{i}}$$
(45)

$$f_{\phi}^{j,i}(X) = \omega_1^i GGIW\left(X;\zeta_1^i\right) + \omega_2^i GGIW\left(X;\zeta_2^i\right)$$
(46)

$$L_{\phi}^{j,i} = 1 - r_{k|k-1}^{i} + r_{k|k-1}^{i} q_{D}^{i}$$
(47)

其中,

$$q_D^i = 1 - p_D^i + p_D^i \left(\frac{\beta_{k|k-1}^i}{\beta_{k|k-1}^i + 1} \right)^{\alpha_{k|k-1}^i}$$
(48)

$$\omega_1^i = \left(q_D^i\right)^{-1} (1 - p_D) \tag{49}$$

$$\omega_{2}^{i} = \left(q_{D}^{i}\right)^{-1} p_{D}^{i} \left(\frac{\beta_{k|k-1}^{i}}{\beta_{k|k-1}^{i}+1}\right)^{\alpha_{k|k-1}^{i}}$$
(50)

$$\zeta_1^i = \zeta_{k|k-1}^i \tag{51}$$

$$\zeta_{2}^{i} = \left\{ \alpha_{k|k-1}^{i}, \beta_{k|k-1}^{i} + 1, m_{k|k-1}^{i}, P_{k|k-1}^{i}, v_{k|k-1}^{i}, V_{k|k-1}^{i} \right\}$$
(52)
(4) MBM 更新

 $r_C^{j,i} = 1 \tag{53}$

$$f_C^{j,i}(X) = GGIW(X;\zeta_C^{j,i})$$
(54)

$$L_C^{j,i} = r_{k|k-1}^i p_D l_C^{j,i}$$
(55)

PMB 滤波器的更新步骤与 PMBM 滤波器类似, 详细的 GGIW 更新过程的参数计算参考文献 [9].

4 实验仿真

在区域[-200 m, 200 m]×[-200 m, 200 m]内, 对 4 个 目标进行跟踪, 时间采样间隔设置为T = 1 s, 时间步长 为 100 s. 杂波数目服从杂波率 λ 为 60 的泊松分布且杂 波在监测范围内服从均匀分布. 扩展目标的外形状态 为 $X_k = R_k \operatorname{diag}([A^2, a^2]), 其中<math>R_k$ 表示转移矩阵, $A \pi a \beta$ 别表示椭圆外形的长轴和短轴.

初始的两个目标及其各自的衍生目标参数设置 如下:

224 软件技术•算法 Software Technique•Algorithm

$$\begin{cases}
A_1 = 0.8, a_1 = 1, \gamma_1 = 10, t_{b,1} = 1, t_{d,1} = 100 \\
A_2 = 0.8, a_2 = 0.5, \gamma_2 = 5, t_{b,2} = 51, t_{d,2} = 90 \\
A_3 = 0.8, a_3 = 1, \gamma_3 = 10, t_{b,3} = 4, t_{d,3} = 100 \\
A_4 = 0.8, a_4 = 0.5, \gamma_4 = 5, t_{b,4} = 51, t_{d,4} = 80
\end{cases}$$

每个扩展目标每个时刻产生的量测数量服从泊松 分布, γ_i , $t_{b,i}$ 和 $t_{d,i}$ (*i* = 1,2,3,4) 分别表示对应泊松分布 的均值和每个扩展目标的新生时间和消失时间. 其他 的参数设置为: *P* = diag{1,1}, *v* = 2, *V* = diag{12,12}, *a* = 32, β = 4, 运动相关 τ = 10, 量测率参数 η = 2, 外形维度 d = 2, 转化矩阵 $M = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$, $H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$, 传 感器的检测概率设为 p_D = 0.95, 目标存活概率为 p_S = 0.99. 衍生权重为 ω_{sp} = 0.05, 衍生假设为 κ = {0.25,0.5, 0.75}. 新生目标的权重 ω_k^k = 0.01.

假设场景中目标均做匀速直线运动,目标的状态 转移矩阵和噪声协方差分别为:

$$F = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, Q = \begin{bmatrix} \frac{T^4}{4} & \frac{T^3}{2} \\ \frac{T^3}{2} & T^2 \end{bmatrix} \cdot 0.1^2 \otimes \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

为验证所提算法的有效性,我们进行了 50 次蒙特 卡洛实验,同时选取广义最优子模式分配 (GOSPA) 距 离^[18] 评估算法的性能,其定义为:

$$d_{p}^{(c,2)}(X,\hat{X}) = \left[\min_{\theta \in \Theta^{(|X|,|\hat{X}|)}} \sum_{(i,j) \in \theta} d_{GW}^{(c)}(x^{i},\hat{x}^{j})^{p} + \frac{c^{p}}{2} \left(|X| - |\theta| + |\hat{X}| - |\theta|\right)\right]_{(56)}^{\frac{1}{p}}$$

其中,

$$d_{GW}^{(c)}(x,\hat{x}) = \min\left(c; d_{GW}\left(x^{i}, \hat{x}^{j}\right)\right)$$
(57)

其中, $d_{GW}(x, \hat{x})$ 为高斯 Wassterstein 距离 (Gaussian Wassterstein distance, GWD)^[19], c是基线距离的截止值, p是 异常值的惩罚程度, 在本文仿真实验中取c = 10, p = 1.

图 1(a) 和图 1(b) 分别为标准的 PMB 算法和改进 的 PMB 算法的跟踪轨迹. 通过对比图 1 两张图的跟 踪轨迹可知, 衍生事件发生后, 改进的 PMB 算法利用 多假设模型对衍生事件预测, 相比于标准的 PMB 算 法能更有效地跟踪目标轨迹, 同时根据图 2 可知, 改进 的 PMB 算法对目标数目的估计也更接近真实的目标 数目.



GOSPA 误差评估算法的整体性能,图 3 显示了标准 PMB 算法和改进的 PMB 算法的 GOSPA 误差.在扩展目标*k* = 51时刻之前,两种算法的 GOSPA 误差相近,说明在未发生衍生事件之前两种算法都能有效地跟踪目标.在*k* = 51时刻,衍生事件发生后,由于衍生目标与原目标的轨迹相近导致两种算法均出现较大的误差,之后改进的 PMB 算法的 GOSPA 误差有下降的趋势且小于标准的 PMB 算法的 GOSPA 误差,说明改进的 PMB 算法能够有效地检测到衍生目标并进行跟踪.

为了验证改进的 PMB 算法在不同条件下的估计 性能,在其他仿真环境相同的条件下,分别设置跟踪区 域内的杂波率为λ = 40, λ = 50, λ = 60,以此来观察分析 实验结果.由图 4 可以看出,在给定的 3 种不同的杂波 率下,所提算法都能有效地准确估计目标的数目.根据 图 5 显示的 GOSPA 距离误差可知, 3 种不同的杂波率 下算法对运动状态和外形的估计效果相差较小,由此 说明不同的杂波率对所提算法影响不大,符合标准的 PMB 滤波算法适用于高杂波的性质.



图 4 不同杂波率下改进的 PMB 算法估计得到的目标数



图 5 不同杂波率下改进的 PMB 算法估计的 GOSPA 距离误差

Software Technique•Algorithm 软件技术•算法 225

5 结论

针对标准 PMB 滤波器未对衍生扩展目标建模的 问题,本文利用多假设模型在 PMB 滤波的预测阶段对 衍生事件进行预测,利用随机矩阵法建模不同尺寸的 椭圆外形,使之更符合扩展目标衍生的假设.仿真结果 表明,改进的算法能更有效地检测到衍生目标并进行 跟踪,但该算法对衍生的估计精度依赖于衍生假设值 的选取,因此如何合理地选取假设值提高衍生目标的 估计精度还需要进一步研究.

参考文献

- Bar-Shalom Y, Fortmann TE, Cable PG. Tracking and data association. The Journal of the Acoustical Society of America, 1990, 87(2): 918–919. [doi: 10.1121/1.398863]
- 2 Granström K, Baum M, Reuter S. Extended object tracking: Introduction, overview and applications. arXiv:1604.00970, 2016.
- 3 Mahler R. PHD filters for nonstandard targets, I: Extended targets. Proceedings of the 12th International Conference on Information Fusion. Seattle: IEEE, 2009. 915–921.
- 4 Koch JW. Bayesian approach to extended object and cluster tracking using random matrices. IEEE Transactions on Aerospace and Electronic Systems, 2008, 44(3): 1024–1059.
- 5 Granström K, Orguner U. A PHD filter for tracking multiple extended targets using random matrices. IEEE Transactions on Signal Processing, 2012, 60(11): 5657–5671. [doi: 10.1109/ TSP.2012.2212888]
- 6 Lundquist C, Granström K, Orguner U. An extended target CPHD filter and a gamma Gaussian inverse Wishart implementation. IEEE Journal of Selected Topics in Signal Processing, 2013, 7(3): 472–483. [doi: 10.1109/JSTSP.2013. 2245632]
- 7 裴佳. 基于随机超曲面的多扩展目标跟踪算法研究 [硕士 学位论文]. 西安: 西安电子科技大学, 2017.
- 8 Chen YM, Liu WF, Wang XD. Multiple extended target tracking based on GLMB filter and Gibbs sampler. Proceedings of the 2017 International Conference on Control, Automation and Information Sciences (ICCAIS). Chiang Mai: IEEE, 2017. 26–31.
- 9 Granström K, Fatemi M, Svensson L. Poisson multi-

Bernoulli mixture conjugate prior for multiple extended target filtering. IEEE Transactions on Aerospace and Electronic Systems, 2020, 56(1): 208–225. [doi: 10.1109/TAES.2019.2920220]

- 10 Granström K, Fatemi M, Svensson L. Gamma Gaussian inverse-Wishart Poisson multi-Bernoulli filter for extended target tracking. Proceedings of the 19th International Conference on Information Fusion (FUSION). Heidelberg: IEEE, 2016. 893–900.
- 11 Xia YX, Granström K, Svensson L, et al. Extended target Poisson multi-Bernoulli filter. arXiv:1801.01353, 2018.
- 12 Lian F, Han CZ, Liu WF, et al. Sequential Monte Carlo implementation and state extraction of the group probability hypothesis density filter for partly unresolvable group targets-tracking problem. IET Radar, Sonar & Navigation, 2010, 4(5): 685–702.
- 13 Granström K, Orguner U. On spawning and combination of extended/group targets modeled with random matrices. IEEE Transactions on Signal Processing, 2013, 61(3): 678–692. [doi: 10.1109/TSP.2012.2230171]
- 14 苗露, 冯新喜, 迟珞珈. 基于 GGIW-CPHD 的衍生扩展目标跟踪算法. 计算机工程与应用, 2019, 55(9): 118-123. [doi: 10.3778/j.issn.1002-8331.1801-0400]
- 15 马艳琴, 甘林海, 王刚. 基于 δ-广义标签多贝努利的群分裂 算法. 现代雷达, 2018, 40(12): 46-51.
- 16 Cai RH, Xie Y, Wu SY, et al. Tracking the spawning of group with Poisson multi-Bernoulli mixture filter. Proceedings of the 2021 International Conference on Control, Automation and Information Sciences (ICCAIS). Xi'an: IEEE, 2021. 296–300.
- 17 Granström K, Lundquist C, Orguner O. Extended target tracking using a Gaussian-mixture PHD filter. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(4): 3268–3286. [doi: 10.1109/TAES.2012.6324703]
- 18 Rahmathullah AS, García-Fernández ÁF, Svensson L. Generalized optimal sub-pattern assignment metric. Proceedings of the 20th International Conference on Information Fusion (Fusion). Xi'an: IEEE, 2017. 1–8.
- 19 Givens CR, Shortt RM. A class of Wasserstein metrics for probability distributions. Michigan Mathematical Journal, 1984, 31(2): 231–240.

(校对责编:牛欣悦)