

基于箱粒子的多扩展目标 PHD 滤波

宋骊平, 严超, 姬红兵, 梁萌

(西安电子科技大学 电子工程学院, 西安 710071)

摘要: 在高斯混合多扩展目标 PHD 滤波的基础上, 结合最新兴起的箱粒子滤波, 提出一种基于区间分析的多扩展目标 PHD 滤波算法. 采用大小可控的非零矩形区域来代替传统的多个点量测, 这样可降低权值计算中对量测分布的要求. 仿真对比实验表明, 采用区间分析方法在保证近似于传统滤波精度的同时可降低计算复杂度, 在目标数目估计及抗杂波干扰方面也具有较为突出的优势, 并且可解决在目标靠近时由于不能正确给出子划分而造成的漏检问题.

关键词: 箱粒子; 区间分析; 概率假设密度; 多目标跟踪; 扩展目标

中图分类号: TP273

文献标志码: A

PHD filter for tracking multiple extended targets using box particle

SONG Li-ping, YAN Chao, JI Hong-bing, LIANG Meng

(School of Electronic Engineering, Xidian University, Xi'an 710071, China. Correspondent: SONG Li-ping, E-mail: lpsong@xidian.edu.cn)

Abstract: A novel probability hypothesis density(PHD) filter for tracking multiple extended targets is proposed by using interval analysis resulting from the Gaussian mixture PHD(GM-PHD) and the recently emerged box particle filtering. The key idea is replacing traditional multiple measurements with a rectangular region of the non-zero volume in the state space, which can reduce the requirement of the measurements' distribution. Simulation results show that, using interval analysis can reach the same tracking level of GM-PHD with a low computational complexity and a good performance on estimating the number of the targets and anti-clutter. This approach can also solve the problem of leak detection with the wrong sub-partition.

Keywords: box particle; interval analysis; probability hypothesis density (PHD); multiple targets tracking; extended targets

0 引言

自二十世纪八十年代起, 随着雷达距离分辨率的提高, 目标在雷达距离显示器上将占据多个距离分辨单元, 产生了所谓的扩展目标, 使得扩展目标跟踪问题变得越来越重要. 文献[1]提出了在假设各时刻目标产生的量测数目服从泊松分布的条件下对扩展目标进行跟踪; 文献[2]中采用的观测模型同样假设每一时刻目标会在其周围产生服从一定分布的多个量测, 且量测数目服从泊松分布; 在此基础上, Granstrom等^[3]结合 Mahler^[4]提出的概率假设密度(PHD)滤波方法, 提出了一种针对多扩展目标的高斯混合 PHD(GM-PHD)滤波, 文中假设目标的动态模型和观测模型是线性高斯的, 并且每一时刻, 每个目标所产生的量测数目服从泊松分布. 区别于传统的非

扩展目标跟踪, 扩展目标跟踪根据同一目标产生的量测具有较近的空间距离原理, 采用距离划分将量测数据划分成不同的划分单元, 再将每一个划分单元里的量测作为一个整体, 采用集中式融合的方法对预测结果进行量测更新. 该算法要求目标的量测模型服从某一分布, 并且在量测划分过程中, 当两个目标距离较近时, 其所产生的量测往往会被划分到一个划分单元中. 为了将其划分开就必须采用子划分, 然而子划分并不能将两个目标的量测准确地划分出来, 这就导致在计算权值及目标数目估算时出现错误而产生漏检. 其次, 在目标扩展范围内一旦存在杂波量测, 则在量测划分时该杂波量测是无法从划分单元中剔除的, 权值计算也会受到杂波量测空间位置的影响.

为了解决上述问题, 本文在传统的高斯混合多扩

收稿日期: 2014-07-09; 修回日期: 2015-04-21.

基金项目: 国家自然科学基金项目(61372003); 中央高校基本科研业务费项目(JB140221).

作者简介: 宋骊平(1975—), 男, 副教授, 博士, 从事信号与信息处理、目标定位与跟踪等研究; 姬红兵(1963—), 男, 教授, 博士生导师, 从事微弱信号检测与参数估计、目标定位与跟踪等研究.

展目标 PHD 滤波的基础上, 结合最新兴起的箱粒子滤波提出一种基于箱粒子的多扩展目标 PHD 滤波算法. 根据箱粒子滤波, 已知最大误差的数据可通过区间分析方法采用一个矩形区域来表示并进行计算. 而对于扩展目标, 所面临的问题恰恰正是: 扩展目标不是一个点目标, 而是具有一定的扩展范围且目标量测是一个区域内的多个点量测, 而多个量测之间的数据融合又会导致较高的计算复杂度. 因此本文运用区间分析方法, 采用矩形箱表示扩展目标, 将箱粒子所处理的最大误差问题应用在扩展目标的扩展范围上. 仿真实验表明, 采用区间分析来处理扩展目标, 可降低滤波算法的计算复杂度, 且对于目标的量测分布也无限制要求, 并且由于其采用的区间量测不需要区分划分区域内的真实量测与杂波量测, 可很好地解决传统扩展目标量测划分中由于无法剔除目标区域内的杂波量测而对滤波结果产生的影响; 再结合权值计算中似然函数的特殊性可极大地提高在密集杂波条件下的滤波性能, 理论上对于不同大小的扩展目标也可直接跟踪.

1 多扩展目标的 GM-PHD 滤波

近几年, 基于有限集 (RFS) 统计理论的概率假设密度 (PHD) 滤波算法, 采用多目标随机集概率分布的一阶矩 (即 PHD) 进行迭代运算, 通过对集合特征的处理, 将复杂的多目标状态空间的运算转换为单目标状态空间内的运算, 避免了复杂的数据关联. 2009 年, Mahler^[5]提出了将 PHD 滤波算法应用到扩展目标中; 随后 Karl 等^[6]又提出了在高斯混合条件下, 通过一系列高斯分量加权来近似目标强度函数的方法来处理扩展目标. 下面介绍扩展目标 GM-PHD 滤波算法的主要步骤.

1.1 量测划分

扩展目标的 PHD 滤波和传统的单量测目标的最大区别是对量测的划分处理^[3]. 一个 p 划分定义为: 将量测 Z 划分为若干个子集 W . 在跟踪扩展目标中划分是极其关键的一步, 因为同一个目标可产生不止一个量测. 假设一个量测集合有 3 个独立的量测 $Z_k = \{z_k^1, z_k^2, z_k^3\}$, 则此量测可有以下 5 种划分^[4]:

$$\begin{aligned} p_1 : W_1^1 &= \{z_k^1, z_k^2, z_k^3\}; \\ p_2 : W_1^2 &= \{z_k^1, z_k^2\}, W_2^2 = \{z_k^3\}; \\ p_3 : W_1^3 &= \{z_k^1, z_k^3\}, W_2^3 = \{z_k^2\}; \\ p_4 : W_1^4 &= \{z_k^2, z_k^3\}, W_2^4 = \{z_k^1\}; \\ p_5 : W_1^5 &= \{z_k^1\}, W_2^5 = \{z_k^2\}, W_3^5 = \{z_k^3\}. \end{aligned} \quad (1)$$

其中: p_i 表示第 i 种划分, W_j^i 为第 i 种划分的第 j 个划分单元. 不难想象, 当量测集合包含的量测数目

增多时, 可能的划分数目将变得十分巨大, 因此为了保证可行的计算方案, 只有少数的划分可以被考虑. 文献 [3] 采用的是一种较为简单的基于量测间距离的划分方法. 已知量测 Z 和距离门限 $\{d_i\}_{i=1}^{N_d}$, 其中 $d_i < d_{i+1}$, 由此可计算出 N_d 种划分, 并且由于 d_i 是递增的, 划分所包含的划分单元将逐步减少, 其划分单元的数目也将逐渐增加. 这种按距离划分的理论依据为同一目标产生的量测更有可能相距较近, 而不同目标产生的量测则通常相距较远. 对于两个量测 z_k^1 和 z_k^2 , 其协方差都为 $R_k = \sigma_e^2 I_2$, 其中 I_2 为一个 2×2 的单位矩阵, 那么两个量测间的马氏距离可表示为

$$(z_k^1 - z_k^2)^T R_k^{-1} (z_k^1 - z_k^2), \quad (2)$$

根据式 (2) 可计算出两个量测间的距离. 由

$$(z_k^1 - z_k^2)^T R_k^{-1} (z_k^1 - z_k^2) < \delta_{PG}, \quad (3)$$

可将相互距离小于门限 δ_{PG} 的量测放入同一划分单元中.

由于 $R_k^{-1} = \sigma_e^{-2} I_2$, 式 (3) 可简化为

$$\|z_k^1 - z_k^2\|_2 < \sigma_e \sqrt{\delta_{PG}}. \quad (4)$$

但是这种划分也存在一定的缺陷, 即当多个目标相距较近时, 由于各个目标产生的量测较为接近, 往往会被划分到同一划分单元中, 在这种情况下需采取子划分将此划分单元划分为多个子集. 本文采用 K -means 划分, 当然其他划分方法也可以采用.

1.2 预测

对于扩展目标的预测与传统的单量测目标的处理方法完全相同, 即

$$\begin{aligned} D_{k|k-1}(x) &= \gamma_k(x) + D_{S,k|k-1}(x) = \\ &= \sum_{l=1}^{J_{\gamma,k}} \omega_{\gamma,k}^{(l)} N(\mathbf{m}_{\gamma,k}^{(l)}, \mathbf{P}_{\gamma,k}^{(l)}) + \\ &= P_S \sum_{l=1}^{J_{k-1}} \omega_{k-1}^{(l)} N(\mathbf{m}_{S,k|k-1}^{(l)}, \mathbf{P}_{S,k|k-1}^{(l)}). \end{aligned} \quad (5)$$

其中: $\{\omega_{\gamma,k}^{(l)}, \mathbf{m}_{\gamma,k}^{(l)}, \mathbf{P}_{\gamma,k}^{(l)}\}_{l=1}^{J_{\gamma,k}}$ 表示新生目标集合, P_S 为存活概率, $\{\omega_{k-1}^{(l)}, \mathbf{m}_{S,k|k-1}^{(l)}, \mathbf{P}_{S,k|k-1}^{(l)}\}_{l=1}^{J_{k-1}}$ 表示存活目标集合, 每个高斯分量的预测均值 $\mathbf{m}_{k|k-1}^{(l)}$ 和协方差 $\mathbf{P}_{k|k-1}^{(l)}$ 可通过以下卡尔曼滤波进行计算:

$$\mathbf{m}_{S,k|k-1}^{(l)} = \mathbf{F} \mathbf{m}_{S,k-1}^{(l)}, \quad (6)$$

$$\mathbf{P}_{S,k|k-1}^{(l)} = \mathbf{Q} + \mathbf{F} \mathbf{P}_{S,k-1}^{(l)} \mathbf{F}^T. \quad (7)$$

其中: \mathbf{F} 为目标状态转移矩阵, \mathbf{Q} 为过程噪声的协方差矩阵.

1.3 更新

在单量测目标的量测更新中每一个量测都被用来更新每一个高斯分量, 但在扩展目标中, 是用划分

单元作为一个整体对高斯分量进行更新, 更新公式如下:

$$D_{k|k-1}(x) = \sum_{l=1}^{J_{k|k-1}} \omega_k^{(l)} N(\mathbf{m}_k^{(l)}, \mathbf{P}_k^{(l)}). \quad (8)$$

k 时刻的后验概率密度也是服从高斯分布的, 即

$$D_{k|k}(x) = D_{k|k}^N(x) + \sum_{z \in Z} \sum_{W \in p} D_{k|k}(x, W). \quad (9)$$

其中: 对于未检测到的高斯分量更新如下:

$$v_{k|k}^N(x) = \sum_{j=1}^{J_{k|k-1}} w_{k|k-1}^{(j)} N(x|m_{k|k}^{(j)}, P_{k|k}^{(j)}), \quad (10)$$

$$w_{k|k}^{(j)} = (1 - (1 - e^{-\gamma(j)})p_D)w_{k|k-1}^{(j)}, \quad (11)$$

$$m_{k|k}^{(j)} = m_{k|k-1}^{(j)}, \quad (12)$$

$$P_{k|k}^{(j)} = P_{k|k-1}^{(j)}; \quad (13)$$

而对于检测到的高斯分量更新如下:

$$v_{k|k}^D(x, W) = \sum_{j=1}^{J_{k|k-1}} w_{k|k}^{(j)} N(x|m_{k|k}^{(j)}, P_{k|k}^{(j)}), \quad (14)$$

$$w_{k|k}^{(j)} = w_p \frac{\Gamma^{(j)} p_D}{d_W} \varphi_W^{(j)} w_{k|k-1}^{(j)}, \quad (15)$$

$$\Gamma^{(j)} = e^{-\gamma^{(j)}} (\gamma^{(j)})^{|W|}, \quad (16)$$

$$\Phi_W^{(j)} = \varphi_W^{(j)} \prod_{Z \in W} \frac{\varphi_Z(m_{k|k-1}^{(j)})}{\lambda_k c_k(Z)}. \quad (17)$$

其中: 量测存在于划分单元 W 中的概率为

$$\varphi_Z(m_{k|k-1}^{(j)}) = N(Z|H_k m_{k|k-1}^{(j)}, R_k + H_k P_{k|k-1}^{(j)} H_k^T); \quad (18)$$

划分的权重

$$w_p = \frac{\prod_{W \in p} d_W}{\sum_p \sum_Z \prod_{W \in p} d_W}, \quad (19)$$

$$d_W = \delta_{|W|,1} + \sum_{l=1}^{J_{k|k-1}} \Gamma^{(l)} p_D \varphi_W^{(l)} w_{k|k-1}^{(l)}. \quad (20)$$

2 区间分析与箱粒子滤波

2.1 区间分析

一维闭区间 $[x] = [\underline{x}, \bar{x}]$ 定义了实数集 \mathbf{R} 中一个连续的闭合子集, 其下限 \underline{x} 为区域内的最小值, 上限 \bar{x} 为区域内的最大值, 在 n_x 为实数域时, $[x]$ 定义了 n_x 个一维闭区间的笛卡尔积 $[x] = [x_1] \times [x_2] \times \cdots \times [x_{n_x}]$, 文中用 $|\cdot|$ 表示 $[x]$ 的体积, 即 $|[x]|$. 不难发现, 区间分析是一门用区间变量代替点变量进行运算的数学分支. 因此, 例如 \pm, \times, \div 或者用于集合的 $\cup, \cap, \supset, \subset$ 这些基本运算都可以自然地扩展到区间运算中^[7]. 在很多区间分析的研究中应用到了“包含函数”的概念^[8], 由于区间 $[x]$ 经过非线性转移函数 f 传播后得到的并不一定为矩形形状, 为了保证非线

性转移后得到箱体形状而引入包含函数. 函数 f 的包含函数 $[f]$ 定义为: 包含 $[x]$ 经 $[f]$ 映射后得到体积 $[f]([x])$ 的最小矩形区域, 并满足 $[f]([x]) \supseteq f([x])$. 使用包含函数可以最大程度地减少计算量, 加快收敛速度. 收缩算法是区间分析中的另一重要概念, 实现箱粒子收缩需要解决的问题就是“约束满足问题 (CSP)”. CSP 定义为: 在 n 维实数域上, 满足约束函数

$$f(x) = f(x_1, x_2, \cdots, x_n) = 0 \quad (21)$$

的约束集为

$$H : (f(x) = 0, x \in [x]), \quad (22)$$

CSP 的解集为

$$S = \{x \in [x] | f(x) = 0\}, \quad (23)$$

其中: H 表示找到一个包含 $[x]$ 中所有 x 且满足 f 的最小体积的 $[x]'$, 用 $[x]'$ 代替 $[x]$, 如 $S \subseteq [x]' \subseteq [x]$. 收缩算法定义为可以收缩 H 的任何算法, 关于多种收缩算法在文献 [8] 中第 4 章有详细陈述. 每一种收缩算法都对特定的一些 CSP 有较好的收缩效果, 本文采用一种被广泛应用的约束传播 (CP) 方法, CP 方法的主要优势在于实现简单, 在高冗余的数据和方程的收缩上拥有更高的效率并且不受非线性的约束.

2.2 箱粒子滤波

箱粒子滤波 (BPF) 是由 Fahed Abdallah 等^[9]首次提出的, 是粒子滤波与区间分析^[7]相结合的一种滤波方法. 量测过程的 3 种不确定因素^[10]如下. 1) 随机不确定性: 这是由随机量测噪声引起的. 2) 集合论不确定性: 对于具有未知分布和偏差的量测, 为了描述其有界误差, 需将其建模为多维区间. 3) 数据关联不确定性: 这是由传感器的漏检和虚警引起的, 或者在复杂的分布式观测系统中由于经常存在的未知的同步偏差或系统时延等, 这些都会导致得到的量测数据是以区间的形式出现. 因此, 在二维空间中可将最大误差已知的一个非零且大小可控的矩形区域定义为箱粒子, 用箱粒子代替传统的点粒子来拟合后验概率密度从而进行滤波, 称为箱粒子滤波^[11]. 箱粒子滤波既与传统的粒子滤波有相同之处, 又有诸多的不同. 由于不精确量测, 在所得到的信息中存在很大的噪声和偏差时, 传统的粒子滤波需要大量粒子来拟合后验概率密度以得到良好的跟踪效果, 但却大大增加了运算复杂度, 导致运算时间大幅度增加, 并不适合目标的实时跟踪, 而箱粒子滤波可很好地处理这一问题.

箱粒子滤波的核心思想为: 用最大误差已知的箱粒子 $[x_k^i]$ 来取代传统的点粒子 x_k^i . 在保证与传统粒子滤波算法相近的效果的前提下, 所需的箱粒子数目仅为几十个, 相比于粒子滤波的上千个可以大大降低滤波算法的计算复杂度, 节省运算时间, 这也是箱粒子

滤波最为显著的优点. 箱粒子滤波^[9]的算法流程如下.

Step 1: 输入 $\{[x_{k-1}^i, w_{k-1}^i = 1/N]\}_{i=1}^N$.

Step 2: 预测

$$[\bar{x}_k^i] = [f]([x_{k-1}^i]) + [w_k], i = 1, 2, \dots, N.$$

Step 3: 更新.

Step 3.1: 预测量测

$$[\bar{z}_k^i] = [h]([\bar{x}_k^i]) + [\varepsilon], i = 1, 2, \dots, N;$$

Step 3.2: 新息 $[r_k^i] = [\bar{z}_k^i] \cap [z_k]$, $[z_k]$ 为 k 时刻实际量测;

Step 3.3: 似然函数

$$A^i = \prod_1^d A^i(j),$$

其中 $A^i(j) = |[r_k^i(j)]| / |[z_k^i(j)]| \leftarrow d$ 表示状态维数;

Step 3.4: 利用收缩算法, 如果 $[r_k^i] \neq \emptyset$, 则采用 $[r_{k+1}^i]$ 和 CP 方法收缩 $[\bar{x}_k^i]$, 得到 $[x_k^i]^{\text{new}}$, 否则 $[x_k^i]^{\text{new}} = [\bar{x}_k^i]$;

Step 3.5: 计算归一化权值

$$\bar{w}_k^i = A^i \cdot w_{k-1}^i / \sum_{i=1}^N A^i \cdot w_{k-1}^i.$$

Step 4: 状态估计

$$\hat{x}_k = \sum_{i=1}^N \bar{w}_k^i \cdot \text{mid}([\bar{x}_k^i]^{\text{new}}),$$

其中 $\text{mid}(\cdot)$ 表示取中点, 由此可得

$$\hat{P}_k = \sum_{i=1}^N w_{k+1}^i ((\hat{x}_k - \text{mid}([\bar{x}_k^i]^{\text{new}})) \dots (\hat{x}_k - \text{mid}([\bar{x}_k^i]^{\text{new}}))^T).$$

Step 5: 重采 $\{[x_k^i], w_k^i = 1/N\}_{i=1}^N$.

算法流程中的似然函数为

$$A^i(j) = |[r_k^i(j)]| / |[z_k^i(j)]|. \quad (24)$$

其中: $[r_k^i(j)]$ 表示预测箱粒子与区间量测的交集, $A^i(j)$ 表示其在区间量测中所占的比例. 交集越大, 似然越大, 计算所得的权值越大.

3 基于箱粒子的多扩展目标 PHD 滤波

由箱粒子滤波可知, 已知最大误差的数据可以通过区间分析方法采用一个区域来表示并进行计算. 而对于扩展目标, 所面临的问题恰恰正是: 扩展目标不再是一个点目标, 而是具有一定的扩展范围, 且目标量测是一个区域内的多个点量测, 但多个量测之间的数据融合又会导致较高的计算复杂度. 因此, 本文考虑将箱粒子所处理的最大误差问题应用于扩展目标的扩展范围方面, 基于区间分析原理, 用一个矩形区域来表示扩展目标. 在其量测更新时, 可将已划分的划分单元通过包含函数的方法转化成一个包含划分单元内所有量测值的最小矩形区域, 从而对扩展目标

进行跟踪. 基于区间分析的扩展目标的量测表示如图 1 所示.

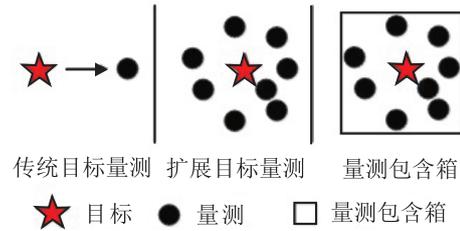


图 1 扩展目标量测示意图

基于箱粒子的方法降低了计算难度, 并通过箱粒子滤波的似然函数, 保证了该算法在强杂波环境下的滤波性能, 具体的算法步骤如下.

3.1 初始化

区别于箱粒子和传统扩展目标的初始化, 为了减小由于目标扩展范围不同对初始化的影响, 在此引入箱粒子新生粒子方法, 根据上一时刻量测划分结果生成 N_k^j 个服从 $N([z_p]_j^{k-1}, \Sigma)$ 分布的矩形区域, 再经过状态转移函数完成本时刻的初始化. 其中: $N_k^j = N/m_{k-1}$, $j = 1, 2, \dots, m_{k-1}$, N 为箱粒子总数, m_{k-1} 为上一时刻量测数目.

3.2 量测划分

本划分仍根据式 (4), 并采用较为直接的距离划分. 为了区别于传统划分, 本划分选取最大距离划分结果, 根据包含函数 $[f]$ 将其包含成具有一定大小的矩形箱, 矩形箱的大小为划分单元中量测的分布范围, 即

$$[z_p]_i = \{[f]W_\lambda\}, \lambda = 1, 2, \dots, m, \quad (25)$$

其中 m 为划分单元个数. 在目标距离较近, 其划分单元内量测数目大于门限 χ 时采取子划分. 本文采用先计算出聚类中心, 再根据量测分布范围扩展为箱的方法进行子划分, 箱的大小保持之前的划分大小.

3.3 新生粒子产生

在多目标的跟踪中存在着目标的新生和消失行为, 理论上新生的目标可能从状态空间的任意位置出现, 在先验知识不足的情况下需要对观测区域进行全局搜索, 然而将粒子覆盖到整个观测区域的做法不仅计算复杂而且效率低下. 箱粒子滤波认为量测出现的位置更有可能是新生目标产生的区域, 因而采用上一时刻量测进行新生箱粒子的补入, 在检测新生目标的同时也可防止箱粒子的退化, 具体计算如下:

$$\beta(x|[z_p]) = \frac{1}{N_b} \sum_{i=1}^{N_b} U_{[x_{b,i}^i]}(x). \quad (26)$$

其中: $[x_{b,i}^i]$ 表示目标状态向量, $U_{[x_{b,i}^i]}(x)$ 表示 $[x_{b,i}^i]$ 上的均匀分布. 式 (26) 表示新生概率密度可以用 N_b 个权值均为 $1/N_b$ 的箱粒子代替. 假设 $[x_{b,i}^i]$ 由量测分

量 $[q]$ 和非量测量 $[u]$ 两部分构成, 即 $[x_{b,k}^i] = [[q]^T, [u]^T]$. 对于量测量, 可通过量测函数的反函数获得, 即 $[q] = [h_k^{-1}](z)$; 对于非量测量, 用一个包含其先验值的均匀分布表示, 即 $[u] = [\text{support}(p_0(u))]$. 产生的每个箱粒子的权值均为 $w_{b,k}^i = 1/N_b, i = 1, 2, \dots, N_b$. 其中每一个量测产生的箱粒子数目为 $N_b^j = N_b/m_{k-1}, j = 1, 2, \dots, m_{k-1}, N$ 为箱粒子的总数, m_{k-1} 为上一时刻的量测数目.

3.4 预测

预测部分与传统的 PHD 预测方法相同, 只是在此预测的不再是高斯分量, 而是一个矩形区域, 预测方程如下:

$$[\tilde{x}_k^i] = [f](x_{k-1}^i) + [w_k], i = 1, 2, \dots, N. \quad (27)$$

3.5 更新

在量测更新部分, 由于得到的预测数据与量测值都是一个箱体, 不能采用传统似然计算方法, 而应采用箱粒子滤波的方法, 采用重叠面积比来更新权值, 即

$$\tilde{w}_i = [(1 - p_k^d([\tilde{x}_i])) + \sum_{i=1}^{N_k + N_{k,\text{new}}} \frac{p_k([z_{p_j}] | [\tilde{x}_i]) p_k^d([\tilde{x}_i])}{\lambda_{k|k-1}([z_{p_j}])}] \cdot w_i, \quad (28)$$

$$\lambda_{k|k-1}([z_{p_j}]) = \lambda_c([z_j]) + \sum_{i=1}^{N_k + N_{k,\text{new}}} p_k([z_{p_j}] | [\tilde{x}_i]) p_k^d([\tilde{x}_i]) w_i. \quad (29)$$

其中: 似然函数为

$$p_k([z_{p_j}] | [\tilde{x}_i]) = \frac{[h_{\text{cp}}]([\tilde{x}_i], [z])}{|[x]|}, \quad (30)$$

h_{cp} 为约束传播算法. 实验表明, 在量测更新部分对于箱粒子的收缩是必须的^[13], 在扩展目标中箱粒子的收缩则表现为对之前得到的预测扩展范围中冗余信息的剔除, 在此根据相应的量测来收缩预测得到箱. 首先选择出对预测权值贡献最大的相应的箱量测, 即

$$[z] = \arg \max_{w_{j,i}} \{[z_{p_j}], w_{j,i} > 0\},$$

$$w_{j,i} = \frac{p_k([z_{p_j}] | [\tilde{x}_i]) p_k^d([\tilde{x}_i])}{\lambda_{k|k-1}([z_{p_j}])}. \quad (31)$$

如果搜索不到则此箱不用收缩, 如果找到最大量测, 则根据此量测对其相应预测进行收缩, 即

$$[\tilde{x}_i] = [h_{\text{cp}}]([\tilde{x}_i], [z]). \quad (32)$$

本文采用面积重叠的方法, 选取预测值与真实量测重叠的部分作为收缩结果, 即

$$[h_{\text{cp}}]([\tilde{x}_i], [z]) = [\tilde{x}_i] \cap [z]. \quad (33)$$

3.6 目标状态提取

为了避免聚类过程中杂波对目标状态的影响, 本文采用文献[14]中的方法, 首先计算出所有预测分量

对各个量测的权值更新, 即

$$w_{j,i} = \frac{p_k([z_{p_j}] | [\tilde{x}_i]) p_k^d([\tilde{x}_i])}{\lambda_{k|k-1}([z_{p_j}])} \cdot w_i, \quad (34)$$

计算每个量测的权值和

$$W_j = \sum_{i=1}^{N_k} w_{j,i},$$

并将计算出的权值和作为第 j 个量测为真实目标量测的概率. 设定一个门限, 当 W_j 大于这一门限时则认为其为真实量测, 即

$$J = \{j | W_j > \tau, j = 1, 2, \dots, m_k\}; \quad (35)$$

然后进行目标状态提取, 即

$$\hat{y} = \frac{1}{W_j} \sum_{i=1}^{N_k} \text{mid}([\tilde{x}_i]) \cdot w_{j,i}. \quad (36)$$

3.7 重采样

由于本文采用区间形式来进行目标跟踪, 这里的重采样部分区别于传统重采样, 首先计算期望目标数 n_k 为真实量测的数目, 设 N_{k+1} 为重采样的粒子数, 采用将箱划分成多个箱的方式来代替传统的多次复制. 现有的重采样方法称为“随机子划分重采样”^[5], 就是在每个时刻将滤波得到的状态箱粒子按照重采样次数随机选取其状态的一维进行均匀子划分, 以使箱粒子始终保持一个合适的大小, 既可满足下一时刻滤波的需要, 又可去除箱粒子多余的部分. 值得注意的是: 这种重采样策略必须在每个采样时刻都要依据前一时刻量测信息产生若干新生箱粒子的条件下进行, 否则算法将会迅速发散. 最后对其权值进行归一化处理, 即

$$\{[x_i], n_k/N_{k+1}\}_{i=1}^{N_{k+1}}. \quad (37)$$

本文由于针对的是扩展目标跟踪, 为了降低预测误差对目标扩展范围的影响, 在初始速度维加入一个增量 σ , 即速度区间可表示为 $[v - \sigma/2, v + \sigma/2]$. 这样可使下一步预测的扩展范围产生一个扩张, 再通过当前的量测信息对预测扩展范围进行收缩. 在重采样时不同于箱粒子滤波的重采样, 因为扩展目标中箱的大小代表目标的扩展范围, 所以不能对目标的位置维进行划分, 而是对目标的速度维进行划分, 以达到更加精准的预测.

4 仿真分析与比较

为了验证本文算法的性能, 设计了两组实验. 实验 1 验证了在高斯条件下, 基于箱粒子的 PHD 滤波算法在扩展目标跟踪中的可行性, 并与传统的 GM-PHD 滤波进行了比较. 在高杂波情况下的仿真结果也验证了本文算法良好的抗杂波性能. 实验 2 表明了本文算法对扩展目标的量测分布无特殊要求, 在均匀分

布情况下依然具有良好的滤波性能。

4.1 实验 1

实验环境构建在一个二维平面的监控区域 $[-200, 600] \times [-1000, 1000]$ 内, 在监控区域有两个目标作匀速直线运动, 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}) 表示目标的速度. 两个目标分别在 $0 \sim 40$ s 作匀速直线运动. 目标的初始状态为: $m_1 = [-190, 19, 220, -22]^T$, $m_2 = [-160, 16, -210, 21]^T$, 在 11 s 时目标交叉. 目标的状态方程和量测方程分别为

$$\begin{aligned} [x_k] &= F[x_{k-1}] + Gw, \\ z_k &= Hx_k + e_{kk}, \\ [x_k] &= [[x_k], [y_k], [v_k^x], [v_k^y]]^T, \\ z_k &= [x_k, y_k], \\ [zP_k] &= [[xP_k], [yP_k]]^t. \end{aligned} \quad (38)$$

其中: w, e_{kk} 分别为过程噪声和量测噪声. 量测以目标真实位置为中心, 服从高斯分布, 而量测个数则是以 10 为基的泊松分布, 杂波数为 5, $[zP_k]$ 为划分结果经包含函数形成的箱, 参与量测更新中似然函数的计算. 匀速运动模型的状态转移矩阵和观测矩阵分别为

$$\begin{aligned} F &= \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad G = \begin{bmatrix} \frac{T^2}{2} & T_s & 0 & 0 \\ 0 & 0 & \frac{T_s^2}{2} & T_s \end{bmatrix}^T, \\ H &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}. \end{aligned} \quad (39)$$

状态噪声方差

$$Q_k = \text{diag}[\sigma_x^2, \sigma_y^2] = \text{diag}[10\text{m}^2, 10\text{m}^2].$$

量测噪声方差

$$Q_k = \text{diag}[2.5^2\text{m}, 2.5^2\text{m}].$$

OSPA 参数设置为: $p = 2, c = 100$ m. BP-PHD 的箱粒子数为 20, GM-PHD 的高斯混合分量最大数目为 $J_{\text{max}} = 100$.

50 次仿真结果如图 2 和图 3 所示. 由图 2 可以看出, 在杂波率较低的情况下, 传统的扩展目标跟踪方法与本文方法都能较好地实现扩展目标的跟踪. 然而, 当目标靠近时, 传统子划分无法精确区分出各个目标的量测, 往往采用强制划分, 结果导致划分结果在计算时得到的权值较小, 造成漏检现象. 本文提出的聚类扩展成箱的方法能很好地解决当扩展目标在靠近时产生的目标漏检问题. 由于传统的量测划分中存在不可剔除的杂波量测, 在目标位置加权计算中, 杂波的参与直接导致了目标位置的不准确. 由图 3 可见, 高斯混合 PHD 算法的 OSPA 距离高于本文算法.

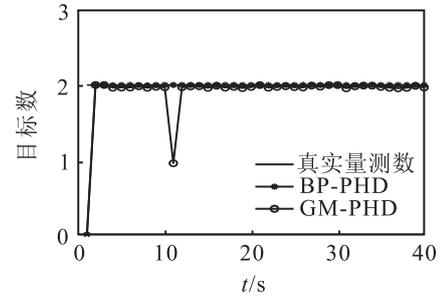


图 2 杂波数为 5 时的目标数估计

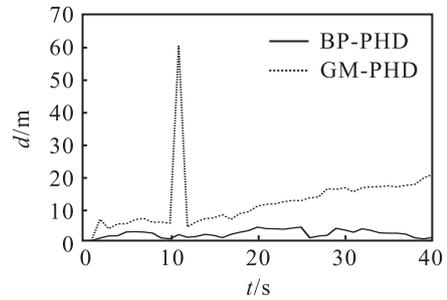


图 3 杂波数为 5 时的 OSPA 距离

表 1 两种算法的运行时间对比 s

参数	GM-PHD	BP-PHD
t	10.599 516	7.709 151

为了进一步验证本文算法在强杂波情况下的抗干扰性能, 将实验中的杂波数由 5 提高到 50. 50 次仿真结果如图 4 和图 5 所示.

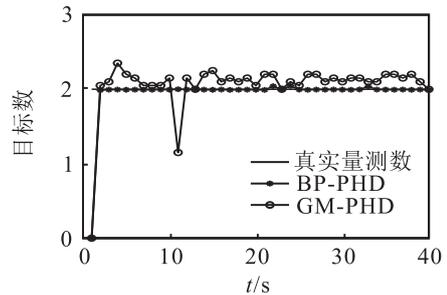


图 4 杂波数为 50 时的目标数估计

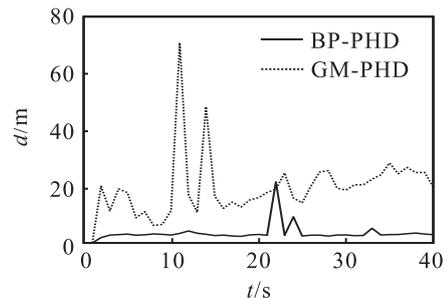


图 5 杂波数为 50 时的 OSPA 距离

由图 4 和图 5 可见, 当杂波率明显上升时, 传统的扩展目标处理方法由于不能剔除落入目标扩展范围内的杂波量测, 在更新过程中, 杂波量测也参与了权值计算和目标位置的加权, 直接导致了目标数目和位置估算的不准确, 当杂波量测越靠近预测中心时,

其产生的影响就越大. 而本文算法, 在似然计算过程中, 不需要严格区分目标真实量测与杂波量测, 只要区域划分准确, 其中混入的杂波将不对滤波结果产生任何影响, 因此对杂波具有较强的抗干扰性, 即使在高杂波环境下, 扩展目标的预测区域也会与多个杂波量测接近或重叠. 但是, 由于杂波量测矩形区域的面积仅为预测状态箱的几十或百分之一, 对最终的预测结果难以造成大的影响. 因此在强杂波条件下, 本文算法明显优于传统的高斯混合 PHD 的处理方法.

4.2 实验 2

本文算法在似然计算中采用的是箱粒子的区域重叠方法, 因此权值的计算只与量测划分结果的区域有关, 而与量测的具体分布无关, 不需要目标量测服从特定的分布. 本实验仍采用实验 1 的运动模型, 但观测模型由之前的目标量测服从高斯分布变为服从均匀分布, 这也更符合某些扩展目标和群目标形成的机理. 当杂波数为 5 时, 两种算法对目标数的估计如图 6 所示.

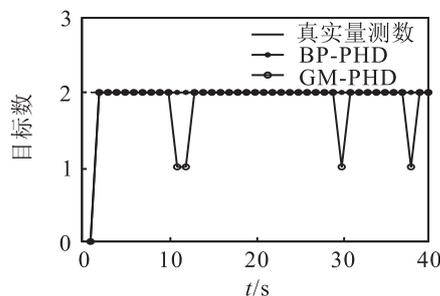


图 6 目标量测服从均匀分布时的目标数估计

由图 6 可见, 当目标量测服从均匀分布时, 传统的算法出现了多次漏检, 而本文提出的算法由于对目标量测分布无硬性要求, 依然有良好的跟踪效果. 这种优越性表现在本文算法可以更好地处理更实际更多样的扩展目标. 例如在种群迁移、部队行军等这种群目标的扩展目标跟踪中, 由于群中各元素并不服从特定的分布, 在此情况下更适于采用本文提出的算法.

5 结 论

本文提出了一种基于箱粒子的多扩展目标 PHD 跟踪算法. 该算法能以较小的代价和较低的计算复杂度实现较为理想的跟踪效果, 在目标数目估计上更加优于传统算法. 本文算法并不要求精确区分真实量测和混入目标扩展范围的杂波量测, 而是通过确定出目标的扩展范围来进行计算, 因此具有很好的抗杂波干扰能力. 本文算法对扩展目标的量测分布没有特定要求, 更符合真实扩展目标的跟踪环境. 仿真实验结果表明, 在扩展目标跟踪中采用箱粒子滤波能够更有效、更合理地实现扩展目标的跟踪.

参考文献(References)

- [1] Gilholm K, Salmund D. Spatial distribution model for tracking extended objects[C]. IEE Proc on Radar, Sonar and Navigation. Stevenage, 2005: 364-371.
- [2] Gilholm K, Godsill S, Maskell S, et al. Poisson models for extended target and group tracking[C]. Int Society for Optics and Photonics. San Diego, 2005: 1-12.
- [3] Granstrom K, Lundquist C, Orguner U. A Gaussian mixture PHD filter for extended target tracking[C]. The 13th Conf on Information Fusion. Edinburgh: IEEE, 2010.
- [4] Mahler R P S. Multitarget Bayes filtering via first-order multitarget moments[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.
- [5] Mahler R. PHD filters for nonstandard targets, I: Extended targets[C]. The 12th Int Conf on Information Fusion. Seattle: IEEE, 2009: 915-921.
- [6] Juang R, Burlina P. Comparative performance evaluation of GM-PHD filter in clutter[C]. The 12th Int Conf on Information Fusion. Seattle: IEEE, 2009: 1195-1202.
- [7] Moore R E, Cloud M J, Kearfott R B. Introduction to interval analysis[M]. Cambridge: Cambridge University Press, 2009: 7-19.
- [8] Jaulin L, Kieffer M, Didrit O, et al. Applied interval analysis: with examples in parameter and state estimation, robust control and robotics[M]. Berlin: Springer, 2001: 27-42.
- [9] Abdallah F, Gning A, Bonnifait P. Box particle filtering for nonlinear state estimation using interval analysis[J]. Automatica, 2008, 44(3): 807-815.
- [10] Gning A, Ristic B, Mihaylova L. Bernoulli particle/box-particle filters for detection and tracking in the presence of triple measurement uncertainty[J]. IEEE Trans on Signal Processing, 2012, 60(5): 2138-2151.
- [11] Gning A, Ristic B, Mihaylova L, et al. Introduction to box particle filtering[J]. IEEE Signal Processing Magazine, 2012, 30(4): 1-10.
- [12] Schikora M, Gning A, Mihaylova L, et al. Box-particle PHD filter for multi-target tracking[C]. The 15th Int Conf on Information Fusion. Singapore: IEEE, 2012: 106-113.
- [13] Gning A, Mihaylova L, Abdallah F. Mixture of uniform probability density functions for nonlinear state estimation using interval analysis[C]. The 13th Conf on Information Fusion. Edinburgh: IEEE, 2010.
- [14] Ristic B, Clark D, Vo B N. Improved SMC implementation of the PHD filter[C]. The 13th Conf on Information Fusion. Edinburgh: IEEE, 2010.

(责任编辑: 滕 蓉)