

多传感器箱粒子 PHD 滤波多目标跟踪算法

蔡如华¹, 杨 标¹, 吴孙勇^{1,2}

(1. 桂林电子科技大学 数学与计算科学学院, 广西 桂林 541004; 2. 广西密码学与信息安全重点实验室, 广西 桂林 541004)

摘要: 针对目标检测概率较低导致单个传感器无法对目标进行有效检测并跟踪的问题, 本文提出了多传感器箱粒子概率假设密度 (multi-sensor box particle probability hypothesis density filter, MS-BOX-PHD) 滤波器。MS-BOX-PHD 滤波器首先将多个传感器的量测转换、融合成为一个量测集合, 并利用箱粒子概率假设密度 (box particle probability hypothesis density filter, BOX-PHD) 滤波器对多个目标的状态进行预测和更新。数值实验表明, 相较于单传感器箱粒子概率假设密度 (Single-BOX-PHD) 滤波器, MS-BOX-PHD 滤波器在目标检测概率较低时, 能够有效地对多目标的状态和数目进行估计; 相较于区间量测下多传感器标准 PHD 粒子 (multi-sensor standard probability hypothesis density particle filter with interval measurement, IM-PHD-PF) 滤波器, 在达到相同的跟踪性能时, 计算效率提升了 38.57%。

关键词: 多传感器; 箱粒子滤波; 概率假设密度滤波; 区间量测

中图分类号: TP302.7 文献标识码: A 文章编号: 1001-8891(2020)04-0385-08

Multisensor Box Particle PHD Multitarget Tracking Algorithm

CAI Ruhua¹, YANG Biao¹, WU Sunyong^{1,2}

(1. Mathematics and Computer Science College of Guilin University of Electronic Technology, Guilin 541004, China;

2. Guangxi Key Laboratory of Cryptography and Information Security, Guilin 541004, China)

Abstract: As single sensors cannot detect and track targets with low detection probability, a new multisensor box particle probability hypothesis density filter is proposed in this paper. The MS-BOX-PHD filter converts and fuses multiple sensor measurement sets into a new set, and the multitarget states are predicted and updated using a box particle probability hypothesis density filter. Numerical experiments show that the MS-BOX-PHD filter can estimate the state and number of multitargets when the target detection probability is low, unlike a single sensor box particle probability hypothesis density filter. Compared with the multisensor standard probability hypothesis density filter with interval measurement, the computational efficiency increased by 38.57% for the same tracking performance

Key words: multi-sensor, box particle filter, probability hypothesis density filter, interval measurement

0 引言

多目标跟踪 (multi-target tracking, MTT) 算法的有效性和实时性一直以来是国内外学者关注的热点。针对多目标跟踪问题, Mahler 提出了随机有限集^[1] (random finite set, RFS) 理论, 将多目标状态集和多目标观测集建模为随机有限集的形式, 有效地解决了基于多假设跟踪^[2]和联合概率数据关联^[3]在多目标跟踪过程中产生的组合爆炸问题, 并提出了基于随机有

限集的概率假设密度^[4] (probability hypothesis density filter, PHD) 滤波器, PHD 滤波器能够对目标状态和数目进行有效的估计。

传统的粒子滤波器是以点粒子的形式来模拟目标状态。在进行蒙特卡洛实验时, 需要大量的点粒子来对目标进行捕获和持续跟踪, 所以会产生较大的计算量, 为减轻计算量, 文献[5]提出了基于区间分析^[6-7]的箱粒子滤波算法, 之后在文献[8]中结合 PHD 滤波器实现了箱粒子 PHD 滤波器, 从而减轻了计算量。

收稿日期: 2018-08-01; 修订日期: 2020-03-20.

作者简介: 蔡如华 (1971-), 男, 副教授, 研究方向: 多目标跟踪。E-mail: ruhuac@guet.edu.cn.

通信作者: 吴孙勇 (1981-), 男, 教授, 研究方向: 多目标跟踪。E-mail: wusunyong121991@163.com.

基金项目: 国家自然科学基金 (61561016, 61362005); 广西密码学与信息安全重点实验室研究课题项目 (GCIS201611)。

2015年国内学者宋骊平^[9]将箱粒子 PHD 滤波用于扩展目标跟踪,之后在文献[10]中使用箱粒子 PHD 滤波对群目标进行了有效的跟踪。文献[11]提出了未知杂波状态下基于箱粒子滤波的 PHD 算法。

但对于低可观测目标的跟踪,单传感器 PHD 滤波器已不能满足需求,而多传感器技术的应用则能够很好地解决这一问题。早在 2009 年, Mahler^[12-13]便给出了多传感器的实现。文献[14-15]分别给出了多传感器 PHD 滤波的序列蒙特卡洛实现和高斯实现,文献[16]利用先验信息对下一时刻可能存在目标的区域进行压缩,并利用多个被动式传感器同时对可能存在目标的区域进行观测,以多个被动式传感器的观测角度相交区域以及传感器位置计算得到目标位置区间,作为目标区间量测,根据区间量测值产生箱粒子,再利用箱粒子 PHD 滤波对目标进行跟踪,旨在去除虚假量测降低运算量,提升计算效率。

本文则是针对低可观测目标难以跟踪以及点粒子滤波产生较大计算量的问题,利用多传感器技术在低可观测目标检测上的优势以及箱粒子滤波能够提升计算效率的优势,提出 MS-BOX-PHD 算法。并通过仿真实验验证了 MS-BOX-PHD 算法对多目标状态以及数目估计的稳定有效性,以及 MS-BOX-PHD 算法相对于区间量测下多传感器标准 PHD 粒子滤波(multi-sensor standard probability hypothesis density particle filter with interval measurement, IM-PHD-PF)算法在计算效率上的优势。

1 系统模型

在多目标跟踪系统中,会有多个目标随机的出现和消失在观测区域中。全文单目标状态用小写字母 x 表示, $x=[x;\bar{x};y;\bar{y}]$ 。其中 (x,y) 包含目标位置信息, (\bar{x},\bar{y}) 包含目标速度信息;多目标状态用大写字母 X 表示;单目标量测用小写字母 z , $z=[\theta;r]$, 其中 θ 表示角度, r 表示距离;多目标量测集用大写字母 Z 表示。

1.1 多目标状态转移模型

考虑系统:

$$x_k = f(x_k) + w_k \quad (1)$$

式中: k 为时间指标; f 为非线性的状态转移函数; w_k 表示 k 时刻的过程噪声。对于 k 时刻多目标状态可以描述为随机有限集:

$$X_k = \{x_{k,1}, x_{k,2}, \dots, x_{k,N}\}$$

式中: N 表示 k 时刻的目标个数。 $x_{k,i}$ 表示 k 时刻的第 i 个目标,可能为新生目标,也可能为 $k-1$ 时刻存活并转移后的目标。

1.2 多目标多传感器量测模型

对于 k 时刻的目标 $x_{k,i}$, 其可能被传感器检测到并产生量测值 $z_{k,i}$, 也可能未被传感器检测到,没有产生量测值,同样在 k 时刻传感器也可能产生虚假量测。

由第 $s \in \{1, 2, \dots, S\}$ 个传感器产生的量测集合 Z_k^s 可表示为:

$$Z_k^s = K_k \cup [\bigcup_{x_{k,i} \in X_k} \Theta_k(x_{k,i})] \quad (2)$$

式中: $[\bigcup_{x_{k,i} \in X_k} \Theta_k(x_{k,i})]$ 表示 k 时刻由目标产生的量测集; K_k 表示 k 时刻由传感器产生的虚假量测集。 k 时刻由第 s 个传感器产生的量测集可记为随机有限集:

$$Z_k^s = \{z_{k,1}^s, z_{k,2}^s, \dots, z_{k,M_s}^s\}$$

式中: M_s 表示第 s 个传感器产生的量测总个数为 M_s 个。

本文采用非线性量测模型,假设第 s 个传感器位置为 (d_x^s, d_y^s) , 则量测方程为:

$$z_k = \left[\begin{array}{c} \arctan \frac{y_k - d_y^s}{x_k - d_x^s} \\ \sqrt{(x_k - d_x^s)^2 + (y_k - d_y^s)^2} \end{array} \right] + v_k \quad (3)$$

2 收缩算法

收缩算法以区间分析^[6-7]为基础,通过区间收缩,保证更新之后的箱粒子拥有一个合适的区间大小,并利用收缩前后的箱粒子区间大小来求解似然函数,从而对箱粒子的权重进行更新。

假设原箱粒子为 $[x]$, 区间量测值记为 $[z]$, h 为量测方程,若 $h([x]) \cap [z] = \emptyset$, 则 $[x'] = [x]$, 但是似然度 $g([z] | [x']) = 0$; 否则收缩后的箱粒子满足:

$$\{x \in [x'] | h([x']) = h([x]) \cap [z] \neq \emptyset\} \quad (4)$$

收缩之后得到的箱粒子 $[x']$ 的似然度 $g([z] | [x'])$ 可以表示为:

$$g([z] | [x']) = \prod_{i=1}^n \frac{|[x'](i)|}{|[x](i)|} \quad (5)$$

式中: $|[x](i)|$ 表示箱粒子 $[x]$ 的第 i 维的长度。

3 MS-BOX-PHD 滤波

假设在 $k-1$ 时刻的后验 PHD $D_{k-1|k-1}$ 由一组服从均匀分布的箱粒子集 $\{[x_{k-1,i}], w_{k-1,i}\}_{i=1}^{L_{k-1}}$ 描述为:

$$D_{k-1|k-1}(x_{k-1}) = \sum_{i=1}^{L_{k-1}} w_{k-1,i} U_{[x_{k-1,i}]}(x_{k-1}) \quad (6)$$

式中: $[x_{k-1,i}]$ 为箱粒子支撑集; L_{k-1} 为 $k-1$ 时刻箱粒子的个数。

3.1 MS-BOX-PHD 滤波预测

若 $\gamma_k(x)$ 表示新生目标贡献强度, $\beta_{\text{Sur},k}(x_k)$ 表示 $k-1$ 时刻到 k 时刻存活下来的目标贡献强度, $p_{k-1|k-1}(x_{k-1})$ 表示 $k-1$ 时刻目标 x 空间分布概率密度, $f(x_k|x_{k-1})$ 表示目标 x 由 $k-1$ 时刻到 k 时刻的转移密度, 则 k 时刻预测 PHD 可以由 k 时刻的预测箱粒子参数集 $\{[x_{k|k-1,i}], w_{k|k-1,i}\}_{i=1}^{L_{k|k-1}}$ 表示为:

$$\begin{aligned} D_{k|k-1}(x_{k|k-1}) &= \sum_{i=1}^{L_{k|k-1}} w_{k|k-1,i} U_{[x_{k|k-1,i}]}(x_{k|k-1}) \\ &= \gamma_k(x_k) + \beta_{\text{Sur},k}(x_k) = \gamma_k(x) + \\ &\int p_{k-1|k-1}(x_{k-1}) f(x_k|x_{k-1}) D_{k-1|k-1}(x_{k-1}) \end{aligned} \quad (7)$$

式中: $L_{k|k-1} = N_\Gamma + N_{\text{Sur}}$ 表示预测得到的箱粒子个数;

N_Γ 为新生箱粒子个数; N_{Sur} 为 $k-1$ 时刻到 k 时刻存活下来并进行转移的箱粒子个数。且有:

$$\begin{aligned} \{[x_{k|k-1,i}], w_{k|k-1,i}\}_{i=1}^{L_{k|k-1}} &= \\ \{[x_{\text{Sur},k|k-1,i}], w_{\text{Sur},k|k-1,i}\}_{i=1}^{N_{\text{Sur}}} \cup \{[x_{\Gamma,i}], w_{\Gamma,i}\}_{i=1}^{N_\Gamma} \end{aligned} \quad (8)$$

新生箱粒子根据 $k-1$ 时刻量测产生^[5], 在量测上服从均匀分布, $\{[x_{\Gamma,i}], w_{\Gamma,i}\}_{i=1}^{N_\Gamma}$ 为新生箱粒子集合, 新生目标贡献强度 $\gamma_k(x)$ 可由其表示为:

$$\gamma_k(x) = \sum_{i=1}^{N_\Gamma} w_{\Gamma,i} U_{[x_{\Gamma,i}]}(x_\Gamma) \quad (9)$$

$\{[x_{\text{Sur},k|k-1,i}], w_{\text{Sur},k|k-1,i}\}_{i=1}^{N_{\text{Sur}}}$ 为 $k-1$ 时刻存活下来的箱粒子集合, $\beta_{\text{Sur},k}(x_{k-1})$ 可由其表示为:

$$\beta_{\text{Sur},k}(x_k) = \sum_{i=1}^{N_{\text{Sur}}} w_{\text{Sur},k|k-1,i} \quad (10)$$

取 $[w_{k-1}]$ 为 $k-1$ 时刻的过程噪声区间, $[f_{k-1}]$ 为 $k-1$ 时刻的状态转移函数的包含函数; $p_{\text{Sur}}([\cdot])$ 表示箱粒子 $[\cdot]$ 的存活概率, 则 $[x_{\text{Sur},k|k-1,i}]$ 可由状态转移方程得到:

$$[x_{\text{Sur},k|k-1,i}] = [f_{k-1}][x_{k-1,i}] + [w_{k-1}] \quad (11)$$

$$w_{\text{Sur},k|k-1,i} = p_{\text{Sur}}([x_{k-1,i}]) f([x_{k-1,i}][x_{k-1}]) w_{k-1,i} \quad (12)$$

3.2 MS-BOX-PHD 滤波更新

3.2.1 量测融合

量测融合分两步进行:

Step 1: 输入 k 时刻 S 个传感器产生的量测集 $\{Z_k^s\}_{s=1}^S$, 将 S 个传感器产生的区间量测转换到同一坐标系下, 步骤如下:

输入 k 时刻区间量测和传感器坐标:

$$\begin{aligned} Z_k^s &= \{[z_{k,1}^s], [z_{k,2}^s], \dots, [z_{k,M_s}^s]\}_{s=1}^S \\ \{(d_x^s, d_y^s)\}_{s=1}^S \end{aligned}$$

对 S 个传感器循环:

For $s=1:S$

$$\tilde{Z}_k^s = []$$

对 k 时刻第 s 个传感器产生所有量测循环:

For $n=1:M_s$

$$[x] = [z_{k,1}^s(2)] \cos([z_{k,1}^s(1)]) + d_x^s;$$

$$[y] = [z_{k,1}^s(2)] \sin([z_{k,1}^s(1)]) + d_y^s;$$

$$[\tilde{z}] = \begin{bmatrix} \arctan\left(\frac{[y]}{[x]}\right) \\ \sqrt{[x]^2 + [y]^2} \end{bmatrix};$$

$$\tilde{Z}_k^s = [\tilde{Z}_k^s, [\tilde{z}]];$$

End

End

Step 2: 对 S 个传感器产生的量测集 $\{\tilde{Z}_k^s\}_{s=1}^S$ 进行

融合。若各传感器区间量测间有交集, 则保留相交的区间量测的交集以及其他互不相交的区间量测值作为当前时刻区间量测集。

以两个传感器为例, 对 k 时刻 S 个传感器产生的区间量测进行分析, 共分为 3 种情况(如图 1(a)、1(b)、1(c))。

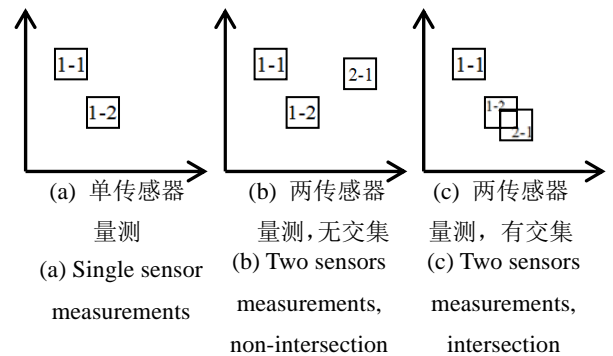


图1 传感器量测分析

Fig.1 Sensor measurements analysis

假设 k 时刻传感器 1 产生量测集经过坐标转换后

记为 \tilde{Z}_k^1 ，传感器 2 产生量测集经过坐标转换后为记为 \tilde{Z}_k^2 。

情形 1: $\tilde{Z}_k^1 = \{[1-1], [1-2]\}$ 包含两个区间量测， $\tilde{Z}_k^2 = \emptyset$ 没有产生量测（如图 1(a)）。则传感器 1 和传感器 2 的 k 时刻量测融合为：

$$Z_k = \tilde{Z}_k^1 \cup \tilde{Z}_k^2 = \{[1-1], [1-2]\}$$

情形 2: $\tilde{Z}_k^1 = \{[1-1], [1-2]\}$ 包含两个区间量测， $\tilde{Z}_k^2 = \{[2-1]\}$ 包含一个区间量测，但传感器产生的区间量测没有相交（如图 1(b)）。则传感器 1 和传感器 2 的 k 时刻量测融合为：

$$Z_k = \tilde{Z}_k^1 \cup \tilde{Z}_k^2 = \{[1-1], [1-2], [2-1]\}$$

情形 3: $\tilde{Z}_k^1 = \{[1-1], [1-2]\}$ 包含两个区间量测， $\tilde{Z}_k^2 = \{[2-1]\}$ 包含一个区间量测，传感器产生的区间量测有相交（如图 1(c)）。则取两传感器相交量测的交区间以及其他全部不相交的区间量测，作为传感器 1 和传感器 2 的 k 时刻量测融合：

$$Z_k = (\tilde{Z}_k^1 \cap \tilde{Z}_k^2) \cup (\tilde{Z}_k^1 - \tilde{Z}_k^1 \cap \tilde{Z}_k^2) \cup (\tilde{Z}_k^2 - \tilde{Z}_k^1 \cap \tilde{Z}_k^2) = \{[1-1], [1-2] \cap [2-1]\}$$

显然因为量测融合同时考虑到多个传感器的区间量测，包含目标真实信息的可能性也会更大。若其中一个传感器无法对目标进行有效检测时，其他传感器也能够对其检测并产生量测。若多个传感器同时检测到目标，则通过情形 3 可知，通过区间量测相交运算则能够对目标量测进行压缩，保证较小的量测区间即可包含目标信息。

通过量测融合后得到的 k 时刻量测融合集 Z_k 仍然是一个随机有限集，包括真实目标产生量测和杂波。将其看作是由一个虚拟传感器产生的量测集，若第 s 个传感器的杂波空间分布率和杂波空间密度分别用 λ_s 和 pdf_s 表示，则虚拟传感器的量测集中杂波概率假设密度为：

$$K(z) = \sum_{s=1}^S \lambda_s \times \text{pdf}_s \quad (13)$$

若第 s 个传感器的检测概率表示为 p_D^s ，则虚拟传感器的检测概率为：

$$p_D = 1 - \prod_{s=1}^S (1 - p_D^s) \quad (14)$$

3.2.2 滤波更新

输入 k 时刻 S 个传感器融合后的区间量测集 Z_k ，对预测得到的箱粒子集 $\{[x_{k|k-1,i}], w_{k|k-1,i}\}_{i=1}^{L_{k|k-1}}$ 进行更新。

箱粒子 $[\tilde{x}_{k,i}]$ 及其对应似然度 $g([z] | [\tilde{x}_{k,i}])$ 由预测得到的箱粒子 $[x_{k|k-1,i}]$ 通过收缩算法得到（具体步骤按照第 2 章进行）：

$$\tilde{w}_{k,i} = (1 - p_D) w_{k|k-1,i} + \sum_{z \in Z_k} \frac{p_D([z] | [\tilde{x}_{k,i}]) g([z] | [x_{k|k-1,i}]) w_{k|k-1,i}}{K_k(z) + \int p_D([z] | [\tilde{x}_{k,i}]) g([z] | [x_{k|k-1,i}]) w_{k|k-1,i}} \quad (15)$$

记更新之后的箱粒子集合为 $\{[\tilde{x}_{k,i}], \tilde{w}_{k,i}\}_{i=1}^{L_{k|k-1}}$ ，则 k 时刻的目标个数估计为：

$$N \approx \sum_{i=1}^{L_{k|k-1}} \tilde{w}_{k,i} \quad (16)$$

再对箱粒子集 $\{[\tilde{x}_{k,i}], \frac{\tilde{w}_{k,i}}{N}\}_{i=1}^{L_{k|k-1}}$ 按照随机划分重采样得到 k 时刻的箱粒子集合 $\{[x_{k,i}], w_{k,i}\}_{i=1}^{L_k}$ 。则 k 时刻的后验 PHD 可表示为：

$$D_{k|k}(x_k) = \sum_{i=1}^{L_k} w_{k,i} \quad (17)$$

取重采样之后，箱粒子集 $\{[x_{k,i}], w_{k,i}\}_{i=1}^{L_k}$ 中各个箱粒子的中心，组成点粒子的集合 $\{\tilde{x}_{k,i}, w_{k,i}\}_{i=1}^{L_k}$ ，其中 $\tilde{x}_{k,i} = \text{mid}([x_{k,i}])$ 。对点粒子集合使用标准 k -均值聚类方法可得到 k 时刻的 N 个状态估计 $\{x_{k,j}\}_{j=1}^N$ 。

4 数值实验

实验计算机系统为 Windows 10 专业版，64 位操作系统。处理器为 Intel(R) Core(TM) i5-6500 CPU @3.20 GHz，运行内存为 8.00 GB。

实验中设置所有目标在观测区域中服从匀速直线（constant velocity, CV）运动模型：

$$\mathbf{x}_k = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \times \mathbf{x}_{k-1} + \mathbf{w}_k$$

式中: 过程噪声 \mathbf{w}_k 为服从协方差为 \mathbf{Q} 的高斯分布:

$$\mathbf{Q} = \sigma_v \begin{bmatrix} \frac{T^3}{3} & \frac{T^2}{2} & 0 & 0 \\ \frac{T^2}{2} & T & 0 & 0 \\ 0 & 0 & \frac{T^3}{3} & \frac{T^2}{2} \\ 0 & 0 & \frac{T^2}{2} & T \end{bmatrix}$$

参数 $\sigma_v = 5 \times 10^{-2} \text{m}^2/\text{s}^2$ 。传感器 1 和传感器 2 的量测噪声 v_k 都服从协方差为 $\mathbf{R} = \text{diag}([\Delta\theta^2, \Delta r^2])$ 的高斯噪声。其中 $\Delta\theta = 0.25 \times \pi/180 \text{rad/s}$, $\Delta r = 2.5 \text{m/s}$ 。试验中量测为区间量测, 角度量测区间大小为 $\pi/45 \text{rad}$ 。距离量测区间大小为 12m 。

本文综合考虑位置估计误差和势估计误差, 使用最优子模式分配距离^[17] (optimal subpattern assignment, OSPA) 来对 MS-BOX-PHD 滤波器的跟踪性能进行评估。对于任意的两个多目标集合 X 和 Y , 若 X 中包含 $m = |X|$ 个状态, Y 中包含 $n = |Y|$ 个状态, 则 X 和 Y 之间的 OSPA 距离定义为:

1) 当 $m \leq n$ 时:

$$\bar{d}_p^{(c)}(X, Y) := \frac{1}{n} \times \{\min \sum_{i=1}^m (d^{(c)}(x_i, y_{\pi(i)})^p) + c^p (n - m)\}^{1/p}$$

2) 当 $m \geq n$ 时:

$$\bar{d}_p^{(c)}(Y, X) := \bar{d}_p^{(c)}(X, Y)$$

3) 当 $m = n = 0$ 时:

$$\bar{d}_p^{(c)}(X, Y) = 0$$

$$d^{(c)}(x_i, y_{\pi(i)})^p = \min(c, d(x_i, y_{\pi(i)})^p)$$

式中: c 为目标个数误差惩罚参数; p 为阶数, 用来惩罚目标位置估计误差。本文实验中 $c = 100$, $p = 1$ 。

4.1 场景 1

设置传感器 1 位于坐标原点 $[0, 0]$ 的观测角度范围为 $\theta_1 \in [0, \pi/2]$, 距离范围为 $r_1 \in [0 \text{m}, 1500 \text{m}]$, 杂波率为 $\lambda_1 = 2$; 传感器 2 位于 $[400, 0]$, 观测角度范围为 $\theta_2 \in [\pi/2, \pi]$, 距离范围为 $r_2 \in [0 \text{m}, 1500 \text{m}]$, 杂波率为 $\lambda_2 = 2$; 传感器 3 位于 $[700, 600]$, 观测角度范围为

$\theta_3 \in [-\pi/2, -\pi]$, 距离范围为 $r_3 \in [0 \text{m}, 1500 \text{m}]$, 杂波率为 $\lambda_3 = 2$ 。场景 1 中共有 10 个目标随机出现和消失在所有传感器的观测区域内。试验中所有目标存活并进行状态转移的概率为 $p_{\text{sur}} = 0.98$ 。

图 2 为单次蒙特卡洛实验下, 传感器检测概率为 0.65 时的目标真实位置以及传感器产生的区间量测。表 1 为 10 个目标的信息。包括目标的初始位置信息、速度信息、出生时刻和死亡时刻。




图 2 目标真实位置和区间量测

Fig.2 True targets location and interval measurements

表 1 目标信息

Table 1 Information of targets

Targets	Original targets	Survival
	state/[m;m/s;m/m/s]	time/s
1	[400;-5;650;-5.5]	1 → 78
2	[600;-5;700;2.5]	1 → 30
3	[-100;5;300;5.5]	1 → 55
4	[-400;5;300;5]	1 → 66
5	[400;-5;350;5.5]	13 → 93
6	[100;5;200;6.5]	15 → 90
7	[600;-5;400;5.5]	24 → 100
8	[200;5;150;5.5]	28 → 100
9	[-300;5.5;500;-2.5]	41 → 100
10	[200;-5.5;200;5.5]	45 → 100

图 3 为单次蒙特卡洛实验下, MS-BOX-PHD 滤波器在传感器检测概率都为 0.65 时对目标的跟踪效果图, 由图 3 可知所提 MS-BOX-PHD 滤波器在检测概率较低时也能够有效地对多目标状态进行跟踪。

图 4 为 100 次蒙特卡洛实验下, MS-BOX-PHD 滤波器和 Single-BOX-PHD 滤波器在不同检测概率下对目标的势估计图, 由图 4 可以看出 Single-BOX-PHD 滤波在检测概率逐渐减小时, 对目标个数的估计也随之减少。相对于 Single-BOX-PHD 滤波器, 本文所提 MS-BOX-PHD 滤波器虽然对目标的个数估计也会受到检测概率的影响, 但受影响幅度明显较

小,在检测概率为0.95、0.85、0.75、0.65时都能有效地对多目标的个数进行估计。




图3 在x轴和y轴目标状态估计

Fig.3 Targets state estimation in *x*-axis and *y*-axis

图5为100次蒙特卡洛实验下,MS-BOX-PHD滤波和Single-BOX-PHD滤波在不同检测概率下对目标状态估计的OSPA距离。

图5(b)为位置OSPA距离,由图5(b)可以看出对于位置估计MS-BOX-PHD滤波器与Single-BOX-PHD滤波器相差不大,Single-BOX-PHD滤波器位置OSPA距离普遍稍小是因为随着检测概率的减小,目标个数的估计会越来越小,当少估计目标个数时候,OSPA距离只会统计估计到的目标在位置上的误差,所以随着检测概率的减小,在位置上的OSPA距离却越来越小。对于MS-BOX-PHD滤波器,能够在检测概率较小时对目标个数进行正确的估计,但在位置估计上会统计所有估计到的目标的位置OSPA距离,所以普遍稍大。且检测概率越大,对位置的估计会越精确;图5(c)为势估计OSPA距离,由图5(c)可以看出在对目标个数估计上Single-BOX-PHD滤波器明显会受到检测概率的影响,检测概率越低,对目标个数的估计误差也越大;图5(a)为综合考虑目标位

置估计和个数估计的OSPA距离,由图5(a)可以看出MS-BOX-PHD滤波器对多目标估计的性能会受到检测概率的影响,但所受影响相对于Single-BOX-PHD滤波器受检测概率的影响要小得多,且只有在目标新生或者死亡时才会出现较大的估计误差,如第1、13、15、24、28、41、45时刻都有目标新生。说明MS-BOX-PHD滤波器在检测概率较低时,能够有效地估计多目标的状态和个数。

4.2 场景2

设置传感器1和传感器2的观测角度范围都为 $\theta \in [0 \text{ rad}, \pi \text{ rad}]$,距离观测范围都为 $r \in [37.5 \text{ m}, 1000 \text{ m}]$,杂波率为 $\lambda_1 = \lambda_2 = 2$;场景2中共有2个目标,两个目标的航迹都在传感器1和传感器2的观测区域内。目标1的初始状态为 $[-800 \text{ m}; 16 \text{ m/s}; 100 \text{ m}; 7 \text{ m/s}]$,存活时间为 $1 \text{ s} \rightarrow 100 \text{ s}$,目标2的初始状态为 $[800 \text{ m}; -16 \text{ m/s}; 100 \text{ m}; 7 \text{ m/s}]$,存活时间为 $30 \text{ s} \rightarrow 90 \text{ s}$ 。试验中所有目标存活并进行状态转移的概率为 $p_{\text{Sur}} = 0.98$,每个目标被传感器检测到的概率都是 $p_D = 0.65$ 。

图6为100次蒙特卡洛实验下,MS-BOX-PHD滤波器和粒子数分别为3000个、4000个、4500个、5000个、8000个时,IM-PHD-PF滤波器对目标势估计对比图。

由图6可以看出IM-PHD-PF滤波器随着粒子数的增多,对势的估计也会越来越准确。但在粒子数为3000个、4000个、4500个、5000个时都没有箱粒子数为8个时MS-BOX-PHD滤波器对目标势估计准确,而在IM-PHD-PF滤波器粒子数提高到8000个时,IM-PHD-PF滤波器对目标的估计个数已经接近于真实目标个数。

图7为100次蒙特卡洛实验下,MS-BOX-PHD滤波器和粒子数分别为3000个、4000个、4500个、5000个、8000个时,IM-PHD-PF滤波器对多目标状态估计的OSPA距离。




图4 不同检测概率下势估计(100MC)

Fig.4 Cardinality estimation under different detection probabilities (100MC)

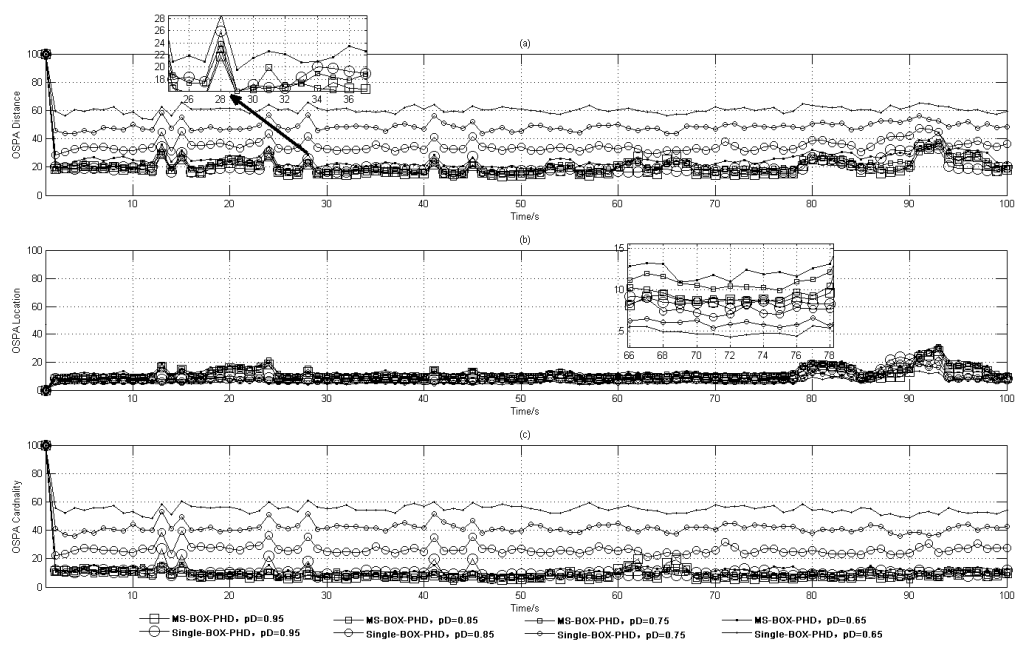


图5 不同检测概率下 OSPA 距离估计 (100MC)

Fig.5 OSPA distance estimation under different detection probabilities (100MC)




图6 MS-BOX-PHD 滤波器和不同粒子数下 IM-PHD-PF 滤波器对目标势估计 (100MC)

Fig.6 Cardinality estimation by utilizing MS-BOX-PHD filter and IM-PHD-PF filter with different number of particles, respectively (100MC)




图7 MS-BOX-PHD 滤波器和不同粒子数下 IM-PHD-PF 滤波器对目标状态估计的 OSPA 距离 (100MC)

Fig.7 OSPA distance estimation by utilizing MS-BOX-PHD filter and IM-PHD-PF filter with different number of particles, respectively (100MC)

其中图 7(c)为势估计 OSPA 距离,图 7(b)为位置估计 OSPA 距离,图 7(b)中,IM-PHD-PF 滤波器在位置估计 OSPA 距离要比 MS-BOX-PHD 滤波器位置估计 OSPA 距离小,因为箱粒子是一个区间,最终是使用箱粒子中心位置来对目标位置进行估计的,所以偏差要大于点粒子下 IM-PHD-PF 滤波器对目标位置的估计;图 7(c)则说明,粒子数越少 IM-PHD-PF 滤波器在对目标进行跟踪时,越容易丢失目标;图 7(a)综合考虑目标的位置估计误差和势估计误差,图 7(a)表明 MS-BOX-PHD 滤波器仅使用 8 个箱粒子对多目标状态估计的性能,要比 IM-PHD-PF 滤波器使用 3000、4000、4500、5000 个粒子的情况下要稳定得多。

图 7(a)中 MS-BOX-PHD 滤波器的 OSPA 距离均值为 28.4835,运行时间为 14.97 s。

表 2 为 100 次蒙特卡洛实验下 IM-PHD-PF 滤波器使用不同粒子数下的运行时间以及 OSPA 距离均值,由表 2 可以看出随着粒子数目的增多,区间量测下多传感器标准 PHD 粒子滤波器对多目标状态估计性能越来越好,但运行时间花费也越来越大。

综合表 2 以及图 6 和图 7 可知,在 IM-PHD-PF 滤波器使用 4500 个粒子时运行时间为 24.37 s,OSPA 距离均值为 30.14;MS-BOX-PHD 滤波器使用 8 个箱粒子,运行时间为 14.97 s,OSPA 距离均值为 28.4835。说明 IM-PHD-PF 滤波器和 MS-BOX-PHD 滤波器在对多目标状态估计性能相近时候,MS-BOX-PHD 滤波器要比 IM-PHD-PF 滤波器在计算效率上提升了 38.57%。

表 2 IM-PHD-PF 滤波器运行时间 (100MC)

Table 2 Time cost for IM-PHD-PF filter					
Particle number, N	3000	4000	4500	5000	8000
Run time/s	16.33	22.11	24.37	26.90	58.69
Average value of OSPA distance	34.78	32.58	30.14	26.02	14.80

5 结论

本文利用多传感器技术,结合 BOX PF 以及 PHD 滤波器给出了 MS-BOX-PHD 算法的实现。并通过数值实验,验证了对于低可观测目标 MS-BOX-PHD 算法的优越跟踪性能,并且验证了与区间量测下多传感器标准 PHD 粒子滤波器相比较,当跟踪性能接近时,MS-BOX-PHD 滤波器在计算效率上提升了 38.57%。

参考文献:

[1] Mahler R P S. *Statistical Multisource-Multitarget Information*

Fusion[M]. London: Artech House, 2007.

[2] Blackman S S. Multiple hypotheses tracking for multiple target tracking[J]. *Electronic Systems Magazine*, 2009, **19**(1): 5-18.

[3] CHANG K C, Bar-Shalom Y. Joint probabilistic data association for multitarget tracking with possibly unresolved measurements and maneuvers[J]. *IEEE Transactions on Automatic Control*, 1983, **29**(7): 585-594.

[4] Mahler R P S. Multitarget bayes filtering via first-order multitarget moments[J]. *IEEE Transactions on Aerospace & Electronic Systems*, 2004, **39**(4): 1523-1178.

[5] Abdallah F, Gning A, Bonnifait P. Box particle filtering for nonlinear state estimation using interval analysis[J]. *Automatica*, 2008, **44**(3): 807-815.

[6] Jaulin L. *Applied Interval Analysis*[M]. Belin: Springer, 2001.

[7] Andrew A M. Applied interval analysis, with examples in parameter and state estimation, robust control and robotics[J]. *Kybernete*, 2002, **31**(5): 117-123.

[8] Schikora M, Gning A, Mihaylova L, et al. Box-particle PHD filter for multi-target tracking[C]//*International Conference on Information Fusion of IEEE*, 2012: 106-113.

[9] 宋骊平, 严超, 姬红兵, 等. 基于箱粒子的多扩展目标 PHD 滤波[J]. *控制与决策*, 2015, **30**(10): 1759-1765.

SONG Liping, YAN Chao, JI Hongbing, et al. PHD filter for tracking multiple extended targets using box particle[J]. *Control and Decision*, 2015, **30**(10): 1759-1765.

[10] 宋骊平, 刘宇航, 程轩. 箱粒子 PHD 演化网络群目标跟踪算法[J]. *控制与决策*, 2018, **33**(1): 74-80.

SONG Liping, LIU Yuhang, CHENG Xuan. Box-particle evolution network PHD filter for group targets tracking[J]. *Control and Decision*, 2018, **33**(1): 74-80.

[11] 魏帅, 冯新喜, 王泉. 未知杂波状态下基于箱粒子滤波的 PHD 算法[J]. *探测与控制学报*, 2017, **39**(2): 94-99.

WEI Shuai, FENG Xinxi, WANG Quan. A PHD algorithm based on box particle in unknown clutter environment [J]. *Journal of Detection & Control*, 2017, **39**(2): 94-99.

[12] Mahler R. The multisensor PHD filter: I. General solution via multitarget calculus[C]//*Proceedings of SPIE*, 2009, **7336**: 73360E-73360E-12.

[13] Mahler R. The multisensor PHD filter: II. Erroneous solution via Poisson magic[C]//*Proceedings of SPIE - The International Society for Optical Engineering*, 2009, **7336**: 73360D-73360D-12.

[14] MENG F, HAO Y, XIA Q, et al. A Particle PHD Filter for Multi-Sensor Multi-Target Tracking Based on Sequential Fusion[C]//*International Conference on Information Engineering and Computer Science of IEEE*, 2009: 1-5.

[15] PAN J, ZHENG J, ZHANG P, et al. A superimposed intensity multi-sensor GM-PHD filter for passive multi-target tracking [C]//*Control Conference of IEEE*, 2017: 54-58.

[16] YANG F, LIU K, CHEN H, et al. Passive multi-sensor box particle PHD based on boundary constraint[C]//*IEEE International Conference on Information and Automation of IEEE*, 2017: 216-221.

[17] Ristic B, Vo B N, Clark D, et al. A metric for performance evaluation of multi-target tracking algorithms[J]. *IEEE Transactions on Signal Processing*, 2011, **59**(7): 3452-3457.