

弱目标箱粒子标签多伯努利多目标检测与跟踪算法

蔡如华¹, 杨标¹, 吴孙勇^{1,2*}, 李瞳¹, 孙希延³

(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;
3. 广西精密导航技术与应用重点实验室, 广西 桂林 541004)

摘要:针对红外弱目标跟踪问题,提出箱粒子标签多伯努利多目标检测与跟踪(Box Particle Labeled Multi-Bernoulli Detection And Tracking, BOX-LMB-DT)算法,该算法首先通过使用均值滤波对获得的灰度图像进行降噪处理;其次,通过将所有像素处依强度大小进行排序,选出强度较大的区域作为当前时刻的区间量测;最后利用箱粒子标签多伯努利滤波(Box-Labeled Multi-Bernoulli Filter, Box-LMB)器对目标进行跟踪。仿真结果表明,所提箱粒子标签多伯努利多目标检测与跟踪算法能够对多目标的航迹和状态进行稳定有效的跟踪,且在相同条件下,相较于区间量测下的LMB粒子滤波,达到相同的跟踪性能时 BOX-LMB 滤波运算效率提升了 22.59%。

关 键 词:多目标跟踪;红外图像量测;箱粒子滤波;标签多伯努利滤波;均值滤波

中图分类号:TP391.4 文献标识码:A

Weak targets box particle labeled multi-bernoulli multi-target detection and tracking algorithm

CAI Ru-Hua¹, YANG Biao¹, WU Sun-Yong^{1,2*}, LI Tong¹, SUN Xi-Yan³

(1. School of Mathematics & Computer Science, GuiLin University of Electronic Technology, Guilin 541004, China;
2. Guangxi Key Laboratory of Cryptography and Information Security, Guilin 541004, China;
3. Guangxi Key Laboratory of Precision Navigation Technology and Application, Guilin 541004, China)

Abstract: For tracking infrared weak targets, a box particle labeled multi-bernoulli multi-target detection and tracking algorithm was proposed. To begin with, the algorithm uses the mean filter to denoise the grayscale image. Then, the region with higher intensity is selected as the interval measurement at current time by sorting the intensity of all the pixels. Finally, the box particle labeled multi-bernoulli filter is applied to tracking. Simulation are presented to demonstrate that the BOX-LMB-DT algorithm has stable and effective performance. In the same conditions, compared with the LMB particle filter under interval measurement, the operation efficiency of the BOX-LMB filtering is improved by 22.59% when the same tracking performance is achieved.

Key words: muti-target tracking, infrared image measurement, box particle filter, labeled multi-Bernoulli filter, mean filter

PACS: 07. 05. Pj

引言

红外弱目标^[1]的检测与跟踪技术一直是国内外学者关注的热点,其主要分为检测前跟踪(Track-

Before-Detect, TBD)和检测后跟踪(Track-After-Detect, TAD),检测前跟踪主要通过对目标在其航迹上的能量积累来实现对目标的检测和跟踪。检测后跟踪则是通过设置强度门限,首先对量测进行处理,

收稿日期:2018-08-03,修回日期:2018-12-20

Received date: 2018-08-03, revised date: 2018-12-20

基金项目:国家自然科学基金(61561016),广西自然科学基金(2016GXNSFAA380073, 2014GXNSFAA118352, 2014GXNSFBA118280)

Foundation items: Supported by National Natural Science Foundation of China (61561016), Natural Science Foundation of Guangxi Province of China (2016GXNSFAA380073, 2014GXNSFAA118352, 2014GXNSFBA118280)

作者简介(Biography):蔡如华(1983-),男,副教授,主要从事小波分析、信号处理、粒子滤波等。E-mail:934019492@qq.com

* 通讯作者(Corresponding author): E-mail:wusunyong121991@163.com

选取高强度区域作为目标的点量测,再进行滤波跟踪.

红外弱目标的量测多为强度量测,是非线性的,粒子滤波与 TBD 技术相结合能够实现对单个弱目标的跟踪.而对于多个目标的跟踪,随机有限集^[2](Random Finite Set, RFS)则能够有效地避免传统的多目标跟踪中产生的数据爆炸问题,在文献[3-6]中,基于随机有限集的概率假设密度^[7](Probability Hypothesis Density, PHD)滤波器、势概率假设密度^[8](Cardinality Probability Hypothesis Density, CPHD)滤波器、多伯努利^[2](Multi-Target Multi-Bernoulli, MeMBer)滤波器和势平衡多伯努利^[9](Cardinality Balanced Multi-Target Multi-Bernoulli, CB-MeMBer)滤波器与 TBD 技术结合,实现了对多个弱目标的跟踪.虽然上述方法都能有效的估计目标的状态以及数目,但是却无法真正得到目标的航迹.

2013 年,BaNgu Vo 团队将标签的概念引入随机有限集,提出了标签随机有限集理论^[10],并在标签随机有限集理论的基础上提出了广义标签多伯努利^[10-11](Generalized Labeled Multi-Bernoulli filter, GLMB)滤波器,GLMB 滤波器不仅继承了对目标状态的优良估计性能,而且实现了对目标航迹的输出.之后,Stephan Reuter 等在 GLMB 滤波器的基础上提出了标签多伯努利^[12](Labeled Multi-Bernoulli filter, LMB)滤波器,通过航迹分组和并行计算方式大大减轻了运算量.文献^[13-14]将分别将 GLMB 和 LMB 滤波器与 TBD 技术相结合,实现了对多弱小目标状态进行估计并输出航迹.

为进一步减轻计算量,2017 年国内学者姬红兵首次将箱粒子滤波^[15]的区间分析^[16-17]法引入到 GLMB 滤波器,提出了箱粒子广义标签多伯努利滤波器^[18](Box-Generalized Labeled Multi-Bernoulli filter, BOX-GLMB),箱粒子广义标签多伯努利滤波器不仅继承了 GLMB 滤波器对多目标状态的稳定估计并输出目标航迹,更兼备箱粒子滤波器能够减轻计算量的优势.同年,国内学者冯新喜首次运用区间分析和 LMB 滤波器实现了箱粒子鲁棒标签多伯努利^[19]滤波器(Box-R-LMB),并验证了其计算效率上的优势.

不同于 TBD 技术,本文结合区间分析和 LMB 滤波给出了 BOX-LMB 滤波的贝叶斯封闭解,并利用检测后跟踪的思想,利用均值滤波对量测进行去噪处理,选取量测,最后使用滤波进行跟踪(如图 1).

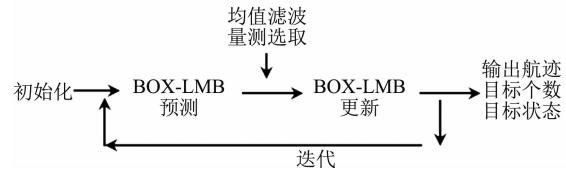


图 1 BOX-LMB-DT 算法流程

Fig. 1 Flow chart of the BOX-LMB-DT algorithm

1 系统模型

1.1 符号

依文献[10]中符号表示方法,将全文上下所有的未带标签的单目标状态用小写字母表示,带标签的单目标状态用小写字母 x 和小写字母 l 共同表示为 (x, l) ,其中小写字母 l 为特定的标签,是唯一的,不同目标所携带的标签互不相同.为简便,后文中带有标签的单目标状态也简写为黑体小写字母 \mathbf{x} .未带标签的多目标状态随机有限集用大写字母 X 表示,带有标签的多目标标签随机有限集用黑体大写字母 \mathbb{X} 表示.

定义状态空间为所有出现目标的状态所组成的空间,标签空间为所有出现的目标所携带的标签组成的空间.直到当前时刻所有目标状态所组成的状态空间用黑板粗体符号 \mathbb{X} 表示,直到当前时刻所有目标所携带的标签组成标签空间用黑板粗体符号 \mathbb{L} 表示,直到下一时刻所有出现过的目标所携带的标签组成的标签空间用符号 \mathbb{L}_+ 表示,下一时刻新生目标所携带的标签组成的标签空间用黑板粗体符号 \mathbb{B} 表示,显然有 $\mathbb{L}_+ = \mathbb{L} \cup \mathbb{B}$,其中 \mathbb{L} 与 \mathbb{B} 互斥,即 $\mathbb{L} \cap \mathbb{B} = \emptyset$.

定义 \mathcal{L} 为从 $\mathbb{X} \times \mathbb{L}$ 到标签空间 \mathbb{L} 的映射, $\mathcal{L}(X) = \{\mathcal{L}(x, l) : (x, l) \in X\}$, 其中 $\mathcal{L}(x, l) = l$. 其中符号“ \times ”表示空间运算符.例:假设当前时刻单目标状态 x 取自状态空间 \mathbb{X} ,其标签 l 取自当前时刻标签空间 \mathbb{L} ,则有 $(x, l) \in \mathbb{X} \times \mathbb{L}$.假设当前时刻带有标签的多目标状态组成的标签随机有限集为 X ,则 X 中所有元素均取自 $\mathbb{X} \times \mathbb{L}$.

对于实值函数 p (文中 $p(x, l)$ 表示携带标签 l 的单目标状态 (x, l) 的后验空间概率密度),状态集 X 为时 \emptyset ,它在状态集 X 上的多目标指数符号为 $p^\emptyset = 1$;状态集 X 不为 \emptyset 时,它在状态集 X 上的多目标指数符号为:

$$p^X = \prod_{(x, l) \in X} p(x, l)$$

$\Delta(X) = \delta_{|X|}(\mathcal{L}(X))$ 为离散的标签指示器, 其中 $|\cdot|$ 表示势. 当 $|\mathcal{L}(X)| = |X|$, 且 X 中所有目标携带的标签互不相同时, $\Delta(X) = 1$, 否则 $\Delta(X) = 0$. 集合 X 上的指示函数定义为:

$$\delta_X(Y) = \begin{cases} 1, & Y \in X \\ 0, & Y \notin X \end{cases}$$

集合 X 上的广义狄拉克 δ 脉冲函数定义为:

$$\delta_X(Y) = \begin{cases} 1, & Y = X \\ 0, & Y \neq X \end{cases}$$

1.2 状态模型

$$x_k = f(x_{k-1}, v_{k-1})$$

其中 f 为状态转移函数(线性或非线性), $k-1$ 和 k 为时间指标, v 表示过程噪声, $x = [x_p; x_v; y_p; y_v; I]$ 为单目标状态, 其中 x_p 和 y_p 分别包含目标在二维空间中横坐标和纵坐标的位置信息, x_v 和 y_v 分别包含目标在二维空间中横坐标和纵坐标的速度信息, I 为目标强度. 对于 k 时刻的多目标状态我们可表示为随机有限集:

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

其中 n 为 k 时刻目标最大个数. 若将每个目标都加上标签, 则 k 时刻的多目标状态可描述为一个标签随机有限集:

$$X_k = \{(x_{k,1}, l_1), (x_{k,2}, l_2), \dots, (x_{k,n}, l_n)\} \quad . \quad (1)$$

1.3 传感器量测模型

在 k 时刻, 目标可能存在也可能不存在, k 时刻的目标存在变量定义为 E , 由二值马尔科夫链描述为 $E_k = \{0, 1\}$, 其中 0 表示目标存在, 1 表示目标不存在. 同样在时刻存在目标的新生和死亡, k 时刻目标新生和死亡的概率分别为 P_b 和 P_d :

$$P_b = \{E_k = 1 \mid E_{k-1} = 0\}$$

$$P_d = \{E_k = 0 \mid E_{k-1} = 1\}$$

则目标存活和没有目标新生的概率分别为:

$$1 - P_d = \{E_k = 1 \mid E_{k-1} = 1\}$$

$$1 - P_b = \{E_k = 0 \mid E_{k-1} = 0\}$$

传感器量测为观测区域上的一系列二维图像, 每一帧图像由 $n \times m$ 个分辨单元组成, 每个分辨单元大小为 $\Delta x \times \Delta y$, 定义分辨单元 (i, j) 的中心为 $i\Delta x \times j\Delta y$, 其中 $i = 1, 2, \dots, n, j = 1, 2, \dots, m$.

k 时刻分辨单元 (i, j) 处的强度量测值用 $z_k^{i,j}$ 表示为:

$$z_k^{i,j} = \begin{cases} h_k^{(i,j)}(x_k) + w_k^{(i,j)}; & \text{target exist} \\ w_k^{(i,j)}; & \text{no target exist} \end{cases} \quad , \quad (2)$$

其中 $h_k^{(i,j)}(x_k)$ 为 k 时刻目标 x_k 在分辨单元 (i, j) 处的贡献强度. $w_k^{(i,j)}$ 为 k 时刻分辨单元 (i, j) 处的噪声. 对于强度为 I_k 的目标在位置 (\tilde{x}, \tilde{y}) 处的贡献强度计算为:

$$h_k^{(i,j)}(x_k) \approx \frac{\Delta x \Delta y I_k}{2\pi \Sigma^2} \times \exp\left\{-\frac{(i\Delta x - \tilde{x}) + (j\Delta y - \tilde{y})}{2\Sigma^2}\right\} \quad , \quad (3)$$

其中 Σ 为传感器的模糊参数, 若观测噪声为服从均值为 0, 协方差为 σ^2 的高斯白噪声, 则信噪比 SNR 计算为:

$$\text{SNR} = 10 \log\left[\frac{I \Delta x \Delta y / 2\pi \Sigma^2}{\sigma}\right]^2 \quad , \quad (4)$$

则可得 k 时刻的量测为一个 $n \times m$ 的矩阵:

$$Z_k = \{z_k^{(i,j)}; i = 1, 2, \dots, n; j = 1, 2, \dots, m\} \quad . \quad (5)$$

2 量测选取

2.1 均值滤波

均值滤波是图像去噪方法中的一种典型线性滤波算法, 其原理为通过选择像素 (x', y') 四周包含 $n \times m$ 个像素的邻域为模板(模板用符号 S 表示), 并以模板中所有像素处量测强度的均值, 取代 (x', y') 处的量测强度. 即经过均值滤波后, 像素 (x', y') 处量测强度 $h(x', y')$ 为:

$$h(x', y') = \frac{1}{n \times m} \sum_{(x_i, y_j) \in S} h(x_i, y_j) \quad , \quad (6)$$

其中 $h(x_i, y_j)$ 表示量测图像中像素 (x_i, y_j) 处的量测强度, 像素 (x_i, y_j) 包含于所选模板区域 S 内.

2.2 传感器量测

由 2.2 节中传感器量测模型可知, 在任意时刻得到的量测都为一帧包含 $n \times m$ 个分辨单元的图像信息. 图像信息中包含目标信息和噪声, 且每个分辨单元上产生的噪声强度都是随机的.

图 2 为在没有噪声的情况下由传感器产生的量测. 在目标所处位置以及其周围一定范围内的分辨单元处量测强度受目标影响, 所以强度很高, 影响范围之外则不受影响. 通常认为量测图像中高亮区域为目标存在的高似然区域.

图 3 为包含噪声的情况下, 由传感器产生的量测图形. 如图 3 所示, 真实目标已淹没在噪声之中, 若认为高亮区域为目标存在的高似然区域, 直接选取量测强度较大处作为量测来估计真实目标位置, 必然会使得目标估计结果存在严重偏差, 因为信噪

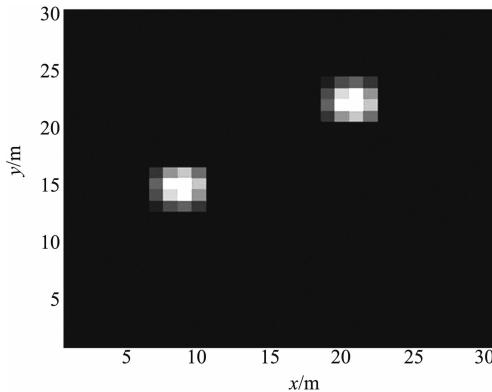


图2 目标强度量测
Fig. 2 Targets intensity

比较低时,某些分辨单元处噪声产生的量测强度要大于目标真实位置处的强度,受所选量测个数的限制,使得挑出的量测中可能不包含真实目标的信息。若增加量测挑选个数,虽然能够包含目标真实信息,但算法的复杂度也将随着量测个数的增加迅速增长。

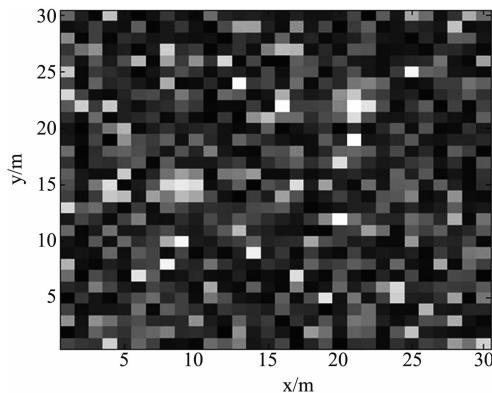


图3 噪声和目标强度量测
Fig. 3 Noise & Targets intensity

2.3 量测挑选

因为噪声是随机分布于整个观测区域内的,不同分辨单元处强度大小差异较大。若是以均值滤波的方法对传感器量测进行预处理。则杂波强度较大的分辨单元处的强度,将会被其周围邻域上所有像素处量测强度的均值所替代,具有高强度杂波的分辨单元处,在均值滤波后量测强度会显著下降(对比图3和图4可知)。

而对于目标所在真实位置处,因其周围分辨单元处量测强度受目标影响普遍较高,经过均值滤波后,真实目标附近的分辨单元处的强度也会普遍高于其它分辨单元处量测强度。如图4所示,经过均值滤波后,目标所在两个区域处量测强度明显要比其

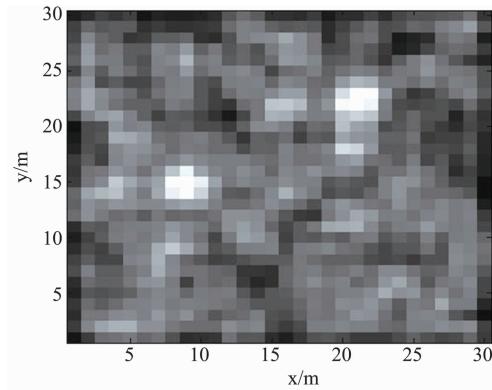


图4 均值滤波后噪声和目标强度量测
Fig. 4 Noise & Targets intensity after using mean filter

它区域高。

传感器量测经过均值滤波处理后,假设我们得到 k 时刻经过均值滤波处理后的强度量测集合 $Z_k = \{z_k^{(i,j)}\}, i=1,2,\dots,m; j=1,2,\dots,n$,则 k 时刻的量测选取通过以下步骤进行:

Step 1: 输入 k 时刻量测 $Z_k = \{z_k^{(i,j)}\}, i=1,2,\dots,m; j=1,2,\dots,n$.

Step 2: 根据强度大小将量测以降序方式排列,得 $Zh_k = \{z_k^1, z_k^2, \dots, z_k^{n \times m}\}$

Step 3: 挑选出 Zh_k 中前 Nz 个量测值,并找出每个量测强度在 Z_k 中对应的像素 (i,j) ,则分辨单元 (i,j) 附近区域为目标存在的高似然区域。

Step 4: 扩张 (i,j) 为区间 $\left[i - \frac{\Delta}{2}, i + \frac{\Delta}{2}\right] \times \left[j - \frac{\Delta}{2}, j + \frac{\Delta}{2}\right]$,认为真实目标位置落在区间 $\left[i - \frac{\Delta}{2}, i + \frac{\Delta}{2}\right] \times \left[j - \frac{\Delta}{2}, j + \frac{\Delta}{2}\right]$ 内,从而得到时刻的区间量测信息 $Zh'_k = \{[z_k^1], [z_k^2], \dots, [z_k^{Nz}]\}$ 。 $(\Delta$ 为区间长度,区间长度大于像素格的长度,小于目标强度影响区域半径).

Step 5: 通过对 Zh'_k 内区间量测两两进行区间相交运算,若相交则只保留其中一个,当所有的区间量测互不相交时,输出互不相交的区间量测,即为 k 时刻的量测集, k 时刻互不相交的区间量测集记为 $Zh''_k = \{[z_k^1], [z_k^2], \dots, [z_k^{Nz}]\}$,其中 $Mz \leq Nz$.

图5所示为Step 3中 Nz 取值为9,经过Step 4之后所获得的量测集,其中有真实目标产生,也有杂波,且存在相交。图6为经过Step 5之后得到的量测集合。

3 箱粒子标签多伯努利粒子滤波

假设当前时刻先验和新生都是标签多伯努利

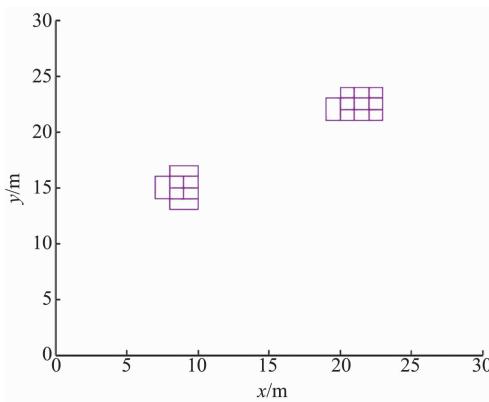


图 5 均值滤波后噪声和目标强度量测
Fig. 5 Noise & Targets intensity after using mean filter

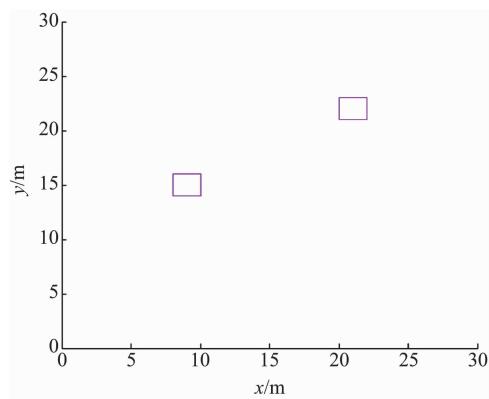


图 6 Step 5 后得到的量测集合
Fig. 6 Interval measurement set after step 5

(LMB)形式,先验概率密度函数 $\pi(X)$ 和新生的概率密度函数 $\pi_B(X)$ 可简记为^[12]:

$$\pi(X) = \Delta(X) W(\mathcal{L}(X)) p^x , \quad (7)$$

$$\pi_B(X) = \Delta(X) W_B(\mathcal{L}(X)) [p_B]^x , \quad (8)$$

其中:

$$W(L) = \prod_{i \in \mathbb{L}} (1 - r^{(i)}) \prod_{l \in L} \frac{1_{\mathbb{L}}^{(l)} r^{(l)}}{1 - r^{(l)}}$$

$$W_B(L) = \prod_{i \in \mathbb{B}} (1 - r_B^{(i)}) \prod_{l \in L} \frac{1_{\mathbb{B}}^{(l)} r_B^{(l)}}{1 - r_B^{(l)}}$$

3.1 BOX-LMB 预测

若 $k-1$ 时刻多目标后验概率密度可由 LMB 参数集 $\{r_{k-1}^{(l)}, p_{k-1}^{(l)}(x)\}_{l \in L}$ 表示, 其中 $r_{k-1}^{(l)}$ 表示标签为 l 的目标在 $k-1$ 时刻的存活概率, $p_{k-1}^{(l)}(x)$ 表示标签为 l 的目标在 $k-1$ 时刻的空间分布概率。在 $k-1$ 时刻标签为 l 的目标, 其空间分布概率 $p_{k-1}^{(l)}(x)$ 可由一组带权重的箱粒子 $\{w_{k-1,j}^{(l)}, [x_{k-1,j}^{(l)}]\}_{j=1}^{N(l)}$ 表示为:

$$p_{k-1}^{(l)}(x) = \sum_{j=1}^{N(l)} w_{k-1,j}^{(l)} U_{[x_{k-1,j}^{(l)}]}(x) , \quad (9)$$

其中 $U_{[x_{k-1,j}^{(l)}]}$ 表示以箱粒子 $[x_{k-1,j}^{(l)}]$ 作为支撑集的均匀分布函数(后文中符号“ U ”表示同样的含义), $[x_{k-1,j}^{(l)}]$ 表示 $k-1$ 时刻带有标签 l 的第 j 个箱粒子, $w_{k-1,j}^{(l)}$ 为箱粒子 $[x_{k-1,j}^{(l)}]$ 的权重, $N(l)$ 表示携带标签 l 的箱粒子个数。 k 时刻的多目标状态由状态转移方程进行预测:

$$[x_{kl,k-1,j}^{(l)}] = [f]([x_{k-1,j}^{(l)}]) + [v] , \quad (10)$$

其中 $[f]$ 为状态转移函数的包含函数, $[v]$ 为状态转移过程产生的噪声区间。 k 时刻的多目标后验概率密度预测为:

$$\pi_+(\mathbf{X}_+) = \Delta(\mathbf{X}_+) W_+(\mathcal{L}(\mathbf{X}_+)) p_+^{X_+} , \quad (11)$$

其中 \mathbf{X}_+ 为预测的多目标状态组成的标签随机有限集(形如式(1)); $p_+^{X_+}$ 表示所有目标的混合空间分布概率, 有 $p_+^{X_+} = \prod_{(x,l) \in X_+} p_+^{(l)}(x)$, $p_+^{(l)}(x)$ 表示带有标签 l 的目标 x 的空间分布概率; $\mathcal{L}(\mathbf{X}_+)$ 表示将预测的标签随机有限集 \mathbf{X}_+ 映射到预测的标签集合, 记 $\mathcal{L}(\mathbf{X}_+) = I_+$; $W_+(\mathcal{L}(\mathbf{X}_+))$ 表示预测得到的标签集 I_+ 的权重, 因为预测时存在目标的存活和新生, 故 I_+ 的权重可记为存活部分权重与新生部分权重的乘积, 即:

$$W_+(I_+) = W_B(I_+ \cap \mathbb{B}) W_S(I_+ \cap \mathbb{L})$$

其中 $W_B(I_+ \cap \mathbb{B})$ 表示新生部分权重, $W_S(I_+ \cap \mathbb{L})$ 表示存活部分权重。

k 时刻带有标签 l 的目标 x 可能为 k 时刻存活的目标, 也可能为 k 时刻新生的目标。假设 $p_{+,s}^{(l)}(x)$ 表示由 $k-1$ 时刻存活下来, 带有标签 l 的目标 x 的预测空间分布概率; $p_B^{(l)}(x)$ 为 k 时刻新生, 带有标签 l 的目标 x 的新生空间分布概率。则 k 时刻预测得到的带有标签 l 的目标的空间分布概率 $p_+^{(l)}(x)$ 为:

$$p_+^{(l)}(x) = 1_{\mathbb{L}}(l)p_{+,s}^{(l)}(x) + 1_{\mathbb{B}}(l)p_B^{(l)}(x) , \quad (12)$$

其中 $1_{\mathbb{L}}(l)$ 和 $1_{\mathbb{B}}(l)$ 为指示函数, 有:

$$1_{\mathbb{L}}(l) = \begin{cases} 1, & l \in \mathbb{L} \\ 0, & l \notin \mathbb{L} \end{cases}$$

$$1_{\mathbb{B}}(l) = \begin{cases} 1, & l \in \mathbb{B} \\ 0, & l \notin \mathbb{B} \end{cases}$$

$p_{+,s}^{(l)}(x)$ 和 $p_B^{(l)}(x)$ 可分别由一组服从均匀分布的预测箱粒子集合 $\{w_{k|k-1,i}^{(l)}, [w_{k|k-1,i}^{(l)}]\}_{i=1}^{N_s(l)}$, 以及一组服从均匀分布的新生箱粒子集合 $\{w_{T,j}^{(l)}, [w_{T,j}^{(l)}]\}_{j=1}^{N_T(l)}$ 表示为:

$$p_{+,s}^{(l)}(x) = \sum_{i=1}^{N_s(l)} w_{k|k-1,i}^{(l)} U_{[x_{k|k-1,i}^{(l)}]}(x)$$

$$p_B^{(l)}(x) = \sum_{j=1}^{N_T(l)} w_{T,j}^{(l)} U_{[x_{T,j}^{(l)}]}(x)$$

其中 $N_r(l)$ 为新生箱粒子个数, $w_{r,j}^{(l)}$ 为新生箱粒子权重初始化为 $w_{r,j}^{(l)} = 1/N_r(l)$; $N_s(l)$ 为存活的箱粒子个数, $w_{k|k-1,i}^{(l)}$ 为存活的携带标签 l 的第 i 个箱粒子预测权重, 有:

$$w_{k|k-1,i}^{(l)} = \frac{\sum_{j=1}^{N_s(l)} p_s([\bar{x}_{k|k-1,j}^{(l)}]) f([\bar{x}_{k|k-1,i}^{(l)} | [\bar{x}_{k|k-1,j}^{(l)}]) w_{k-1,j}^{(l)}}{\eta_s(l)}, \quad (13)$$

$$\eta_s(l) = \sum_{j=1}^{N_s(l)} p_s([\bar{x}_{k|k-1,j}^{(l)}]) w_{k-1,j}^{(l)}$$

其中 $f([\bar{x}_{k|k-1,i}^{(l)} | [\bar{x}_{k|k-1,j}^{(l)}])$ 为箱粒子 $[\bar{x}_{k|k-1,i}^{(l)}]$ 到箱粒子 $[\bar{x}_{k|k-1,j}^{(l)}]$ 进行的状态转移概率, $p_s(\cdot)$ 表示箱粒子 \cdot 的存活概率。

若记所有存活的目标所携带的标签集权重 $W_s(I_+ \cap \mathbb{L})$ 为 $W_s(L)$, 所有新生的目标所携带的的标签集权重 $W_B(I_+ \cap \mathbb{B})$ 为 $W_B(L)$, 预测得到的标签集 I_+ 简写为 I , 则由文献[12]中引理1可知:

$$W_s(L) = [\eta_s]^L \sum_{l \in L} [1 - \eta_s]^{I-l} W(I) = (1 - r^{(\cdot)} \eta_s)^L \left(\frac{r^{(\cdot)} \eta_s}{1 - r^{(\cdot)} \eta_s} \right)^L, \quad (14)$$

$$W_B(L) = \prod_{i \in \mathbb{B}} (1 - r_B^{(i)}) \prod_{l \in L} \frac{1_B(l) r_B^{(i)}}{1 - r_B^{(i)}}. \quad (15)$$

若记存活目标的存活概率 $r(\cdot) \eta_s$ 为 $r_{+,s}^{(l)}$, 存活目标的空间分布概率为 $p_{+,s}^{(l)}(x)$, 记新生目标的存活概率为 $r_B^{(l)}$, 存活目标的空间分布概率为 $p_B^{(l)}(x)$, 则多目标后验概率密度参数集可以表示为:

$$\pi_+ = \{(r_{+,s}^{(l)}, p_{+,s}^{(l)}(x))\}_{l \in \mathbb{L}} \cup \{(r_B^{(l)}, p_B^{(l)}(x))\}_{l \in \mathbb{B}} = \{(r_{+,s}^{(l)}, p_{+,s}^{(l)}(x))\}_{l \in \mathbb{L}_+}. \quad (16)$$

3.2 BOX-LMB 更新

由节可得多目标预测参数集为 $\{(r_{+,s}^{(l)}, p_{+,s}^{(l)}(x))\}_{l \in \mathbb{L}_+}$, 输入当前时刻的量测集 Z , 对预测得到的后验概率密度进行更新可得到多目标后验概率密度^[12]:

$$\pi(\cdot | Z) = \{(r_{+,s}^{(l)}, p_{+,s}^{(l)}(x))\} \quad (17)$$

其中 $r^{(l)}$ 表示标签为 l 的目标的后验存活概率, $p^{(l)}(x)$ 表示标签为 l 的目标的后验空间分布概率, 有:

$$r^{(l)} = \sum_{(L_+, \theta) \in \mathcal{F}(\mathbb{L}_+) \times \Theta_{L_+}} W^{(I_+, \theta)}(Z) \mathbf{1}_{I_+}(l), \quad (18)$$

$$p^{(l)}(x) = \frac{1}{r^{(l)}} \times \sum_{(L_+, \theta) \in \mathcal{F}(\mathbb{L}_+) \times \Theta_{L_+}} W^{(I_+, \theta)}(Z) \times \mathbf{1}_{I_+}(l) p^{(\theta)}(x, l), \quad (19)$$

$\theta(\theta(l) \rightarrow \{0, 1, \dots, |Z|\})$ 表示从标签集到量测指标集的映射, $\Theta_{I_+}(\Theta: \{\theta_0, \theta_1, \dots, \theta_s\})$ 表示从标签集 I_+

到量测集 Z 的所有映射的集合, $W^{(I_+, \theta)}(Z)$ 表示预测标签集 I_+ 在映射集 θ 下由量测集 Z 更新后的权重, 与预测得到的标签集 I_+ 的权重成正比:

$$W^{(I_+, \theta)}(Z) \propto W_+(I_+) [\eta_z^\theta]^{I_+}, \quad (20)$$

$p^{(\theta)}(x, l)$ 表示在映射 θ 下由量测更新后, 标签为 l 的目标 x 的空间分布概率, 若以 $w_{k,j}^{(l)}$ 表示 k 时刻带有标签 l 的第 j 个箱粒子更新后的权重, 则 $p^{(\theta)}(x, l)$ 可表示为:

$$p^{(\theta)}(x, l) = \sum_{j=1}^{N(l)} w_{k,j}^{(l)} U_{[\bar{x}_{k|k-1,j}^{(l)}]}(x), \quad (21)$$

$$w_{k,j}^{(l)} = w_{k|k-1,j}^{(l)} \frac{\psi'([\bar{x}_{k|k-1,j}^{(l)}]; \theta(l))}{\eta_z^\theta(l)}, \quad (22)$$

其中:

$$\eta_z^\theta(l) = \sum_{j=1}^{N(l)} w_{k|k-1,j}^{(l)} \psi'([\bar{x}_{k|k-1,j}^{(l)}]; \theta(l)) , \quad (23)$$

$$\psi'([\bar{x}_{k|k-1,j}^{(l)}]; \theta(l)) \begin{cases} \frac{p_D(x, l) g'([\bar{z}_{\theta(l)}] | [\bar{x}_{k|k-1,j}^{(l)}])}{\kappa([\bar{z}_{\theta(l)}])}, & \theta(l) > 0 \\ q_D(x, l), & \theta(l) = 0 \end{cases}, \quad (24)$$

$\kappa(\cdot)$ 表示服从泊松分布的杂波密度; $[\bar{z}_{\theta(l)}]$ 为在映射 θ 下, 标签为 l 的目标状态所对应的区间量测; $g'([\bar{z}_{\theta(l)}] | [\bar{x}_{k|k-1,j}^{(l)}])$ 为似然函数, 表示箱粒子 $[\bar{x}_{k|k-1,j}^{(l)}]$ 关于区间量测 $[\bar{z}_{\theta(l)}]$ 的似然度, 计算为:

$$g'([\bar{z}_{\theta(l)}] | [\bar{x}_{k|k-1,j}^{(l)}]) = \prod_{i=1}^n \frac{[\bar{x}'_{k|k-1,j}^{(l)}](i)}{[\bar{x}_{k|k-1,j}^{(l)}](i)}. \quad (25)$$

箱粒子 $[\bar{x}'_{k|k-1,j}^{(l)}]$ 由 $[\bar{x}_{k|k-1,j}^{(l)}]$ 箱粒子在更新阶段经收缩算法(3.3节)得到, $[\cdot](i)$ 表示箱粒子 $[\cdot]$ 的第 i 维。经过收缩算法后, 对箱粒子集合 $\{[\bar{x}'_{k|k-1,j}^{(l)}]\}_{j=1}^{N(l)}$ 进行随机划分重采样^[15]得到新的箱粒子集合 $\{[\bar{x}_{k,j}^{(l)}]\}_{j=1}^{N(l)}$.

k 时刻带有标签 l 的目标 x 状态估计为:

$$\bar{x}_k^l = \text{mid}\left(\sum_{j=1}^{N(l)} w_{k,j}^{(l)} [\bar{x}_{k,j}^{(l)}]\right), \quad (26)$$

其中 $\text{mid}([\cdot])$ 表示取箱粒子 $[\cdot]$ 的中心。

k 时刻存在的目标个数估计为:

$$\rho_k(n) = \sum_{(I_+, \theta) \in F(L_+) \times \Theta_{L_+}} W^{(I_+, \theta)}(Z) \delta_n(|I_+|) , \quad (27)$$

其中 $|\cdot|$ 表示势, $\delta_n(|I_+|)$ 为狄拉克脉冲函数, 满足:

$$\delta_n(|I_+|) = \begin{cases} 1, & \text{if } |I_+| = n \\ 0, & \text{else } |I_+| \neq n \end{cases}$$

3.3 收缩算法

收缩算法用于箱粒子滤波的更新阶段的似然函数计算和箱粒子更新上,通过收缩算法使得更新后的箱粒子大小控制在一个合适的范围之内. 其实质是在约束集中求解满足条件的最小约束问题:

$$S = \{x_n \mid [f](x) = 0\}$$

其中 x_n 指 n 维的状态, $[f]$ 为包含函数, 实际是为了求解满足条件的最小 $[x']_n$, 使得 $S \subset [x']_n \subset [x]_n$. 并将箱粒子 $[x]_n$ 更新为 $[x']_n$.

对于 n 维箱粒子 $[x]_n$, 假设量测函数用 h 表示, 当前区间量测值为 $[z]$, h^{-1} 为量测函数 h 的逆, 且满足 $hh^{-1}([z]) = [z]$. 收缩算法具体为:

Step 1: 利用量测函数 h 计算箱粒子 $[x]_n$ 所对应的量测值 $[z'] = h([x]_n)$.

Step 2: 判断当前区间量测值 $[z]$ 与箱粒子 $[x]_n$ 所对应的区间量测值 $[z']$ 是否存在交集.

(1) 若 $[z] \cap [z'] \neq \emptyset$, 则将箱粒子 $[x]_n$ 收缩为 $[x']_n$, 且满足 $h([x']_n) \subset [z]$, $h([x']_n + [\varepsilon]_n) \not\subset [z]$. 其中 $[\varepsilon]_n$ 表示 n 维任意小的区间, 且似然函数 $g([z] \mid [x]_n)$ 计算为:

$$g([z] \mid [x]_n) = \prod_{i=1}^n \frac{[x'](i)}{[x](i)}$$

其中 $[\cdot](i)$ 表示箱粒子 $[\cdot]$ 的第 i 维.

(2) 若 $[z] \cap [z'] = \emptyset$, 则通过收缩算法后箱粒子 $[x]_n$ 保持不变, 即 $[x']_n = [x]_n$, 但似然函数 $g([z] \mid [x]_n) = 0$.

4 数值实验

4.1 环境设置

实验计算机系统为 windows 10 专业版, 64 位操作系统, Intel(R) Core(TM) i5 处理器, CPU 为 3.20 GHz, 8.00 GB 内存.

实验跟踪时长为 45 s, 采样间隔为 1 s, 观测区域为 $[30 \text{ m}, 30 \text{ m}]$, 每次观测生成一帧 $n \times m = 30 \times 30$ 的强度量测, 分辨单元大小为 $\Delta x = 1 \text{ m}$, $\Delta y = 1 \text{ m}$, 过程噪声为:

$$B = q_1 \begin{bmatrix} \frac{T^3}{3} & \frac{T^2}{2} & 0 & 0 & 0 \\ \frac{T^2}{2} & T & 0 & 0 & 0 \\ 0 & 0 & \frac{T^3}{3} & \frac{T^2}{2} & 0 \\ 0 & 0 & \frac{T^2}{2} & T & 0 \\ 0 & 0 & 0 & 0 & q_2 T \end{bmatrix},$$

其中 $q_1 = 0.001$, $q_2 = 0.01$. 传感器模糊参数设置为 $\Sigma = 1.0$. 观测区域内新生目标初始强度都为 $I = 15 \text{ dB}$. 试验中每个目标用一个箱粒子来描述. 箱粒子大小为 $[1.6 \text{ m}, 1.6 \text{ m}]$. 为综合考虑本文所提 BOX-LMB-DT 算法在对多数目估计以及状态估计方面的性能, 故采用最优子模式分配^[21] (Optimal Subpattern Assignment, OSPA) 距离来评估算法的性能. 试验中多目标数目估计惩罚参数为 $c = 100$, 多目标位置估计惩罚参数 $p = 1$.

试验中假定目标的检测概率只受到信噪比和量测选取个数的影响, 信噪比和量测选取个数都相同时, 不同目标的检测概率相同, 且为时不变的. 经过均值滤波去噪处理后, 选取区间量测值, 记 k 时刻的目标个数为 N , 对于目标 j , k 时刻所有获得的区间量测值中若包含目标 j 的信息, 则记录 $m_{i,j} = 1$, 否则 $m_{i,j} = 0$. 其中 i 为第 i 次蒙特卡洛实验. 若蒙特卡洛试验总次数记为 MC , 检测概率记为 P_d , 则:

$$P_d = \frac{\sum_{i=1}^{MC} \sum_{j=1}^N m_{i,j}}{N \times MC}. \quad (28)$$

记录第 i 次蒙特卡洛实验获得的所有不包含真实目标信息的区间量测个数为 num_i 即第 i 次蒙特卡洛实验产生的杂波数为 num_i , 若记 $P_{clutter}$ 为平均杂波率, 则:

$$P_{clutter} = \frac{\sum_{i=1}^{MC} num_i}{MC}. \quad (29)$$

本文试验中的检测概率为对第 k 时刻的目标进行 1 000 次蒙特卡洛实验统计获得, 图 7 为当在第 2.3 节量测挑选 Step 3 步中 Nz 分别等于 5, 9, 13, 17, 21 时, 经过 1 000 次蒙特卡洛实验后不同信噪比下的检测概率, 图 8 为相应的杂波率.

图 7 显示, 随着 2.3 节量测选择的 Step 3 中选择区间量测个数固定时, 随着信噪比的提升, 目标被检测到概率越来越高, 并逐渐向 1 逼近; 当 2.3 节量测选择的 Step 3 中选择区间量测个数较少(如图 7 中 $Nz = 5$)时, 相同信噪比下检测概率明显要低于 $Nz = 9, 13, 17, 21$ 时; 对比 $Nz = 9, 13, 17, 21$ 可知, 当信噪比小于 6.5 dB 时, 随着 Nz 的增加, 目标被检测到概率也会随之增加, 但信噪比高于 6.5 dB 时, $Nz = 9, 13, 17, 21$ 时目标被检测到概率几乎一致. 即信噪比较低时, 随着 2.3 节量测选择的 Step 3 中选择区间量测个数的增加, 目标被检测到概率也随之增加, 信噪比较高时, 随着 2.3 节量测选择的 Step 3 中选

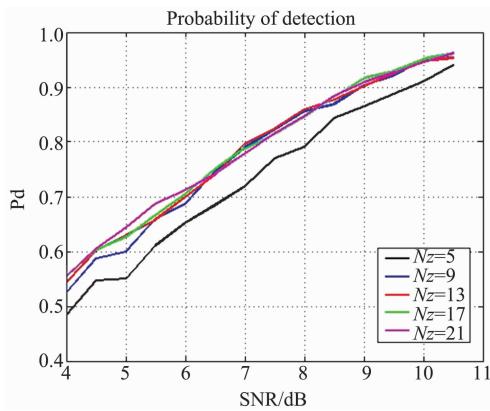


图7 不同信噪比下检测概率

Fig. 7 Probability of detection in different SNR ($\Sigma = 1.0, k = 22, 1000MC$)

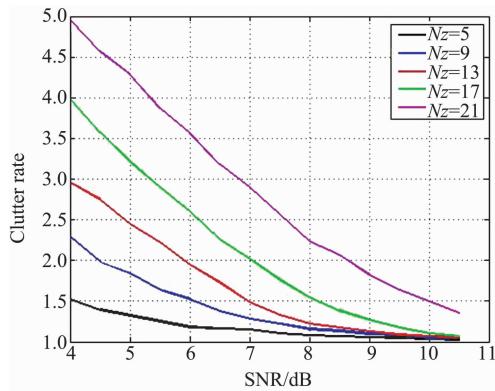


图8 不同信噪比下检测概率和杂波率

Fig. 8 Probability of detection & Clutter rate in different SNR ($\Sigma = 1.0, k = 22, 1000MC$)

择区间量测个数超过一定值后, 目标被检测到概率不再随之变化。

图8表明相同信噪比条件下, 随着2.3节量测选择的Step 3中选择区间量测个数的增加, 杂波个数也会越来越多;当2.3节量测选择的Step 3中选择区间量测个数固定时, 随着信噪比的增大, 杂波个数随之减少。

本文的其它实验中, 第2.3节量测挑选Step 3步中设定 $Nz=9$. 表1为 $Nz=9$ 时, 不同信噪比下对应的检测概率数值以及对应的杂波率数值. 在不同信噪比环境下使用所对应的检测概率和杂波率进行滤波跟踪.

表1 不同信噪比下检测概率和杂波率($Nz=9, 1000MC$)Table 1 Probability of detection & clutter rate for different SNR ($N=9, 1000MC$)

SNR/dB	4	4.5	5.0	5.5	6.0	6.5	7.0	7.5	8.0	8.5	9.0	9.5	10.0	10.5
P_d	0.525	0.587	0.600	0.660	0.687	0.746	0.790	0.823	0.856	0.869	0.903	0.921	0.951	0.954
$P_{clutter}$	2.291	1.979	1.841	1.639	1.527	1.376	1.283	1.222	1.157	1.133	1.098	1.081	1.049	1.046

4.2 实验1

实验1中目标运动模型匀速直线(Constant Velocity, CV)运动模型, 跟踪过程中共出现四个目标. 四个目标都服从匀速直线运动模型:

$$x_k = \begin{bmatrix} 1 & T & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & T & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} x_{k-1} + v_k .$$

新生目标概率为 $r^{(i)} = 0.02$, 新生目标分布为服从 $p^{(i)} = N(x; m^{(i)}, P)$, $i = 1, 2, 3, 4$ 的高斯分布, 其中:

$$\begin{aligned} m^{(1)} &= [5 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 26 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}] ; \\ m^{(2)} &= [4 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 10 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}] ; \\ m^{(3)} &= [22 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 25 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}] ; \\ m^{(4)} &= [6 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 3 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}] ; \\ P &= [2.25 \text{ m}^2; 0.8 \text{ m}^2 \cdot \text{s}^{-2}; 2.25 \text{ m}^2; 0.8 \text{ m}^2 \cdot \text{s}^{-2}; 2^2 \text{ dB}^2] . \end{aligned}$$

试验中共有四个目标随机出现在观测区域内, 目标1的初始状态为 $[5 \text{ m}; 0.7 \text{ m} \cdot \text{s}^{-1}; 26 \text{ m}; -0.5 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}]$, 存活时间 $1 \sim 15 \text{ s}$, 目标2的初始状态为 $[4 \text{ m}; 0.4 \text{ m} \cdot \text{s}^{-1}; 10 \text{ m}; 0.4 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}]$, 存活时间 $10 \sim 25 \text{ s}$, 目标3的初始状态为 $[22 \text{ m}; -0.3 \text{ m} \cdot \text{s}^{-1}; 25 \text{ m}; -0.7 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}]$, 存活时间 $18 \sim 32 \text{ s}$, 目标4的初始状态为 $[6 \text{ m}; 0.2 \text{ m} \cdot \text{s}^{-1}; 3 \text{ m}; 0.4 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}]$, 存活时间为 $28 \sim 58 \text{ s}$.

图9为在信噪比为7.5 dB时的目标跟踪效果图. 由图9可以看出在信噪比为7.5 dB时利用经过均值滤波处理后选取的量测和箱粒子标签多伯努利滤波能够对多目标进行有效的跟踪, 并且能够清晰的区分出各个目标的航迹.

图10为不同信噪比下目标数目的估计. 图10显示当信噪比较低时, 目标数目一旦发生变化, BOX-LMB-DT算法需要调整的时间较长. 如图第33时刻, 当目标消失时, BOX-LMB-DT算法在信噪比为6.5 dB时, 经过三个时刻依旧无法恢复对目标的正确估计, 但信噪比为7.5 dB、8.5 dB和9.5 dB时只需要3个时刻就恢复了对目标的正确估计. 通过图10可以看出不同信噪比下BOX-LMB-DT算法都能

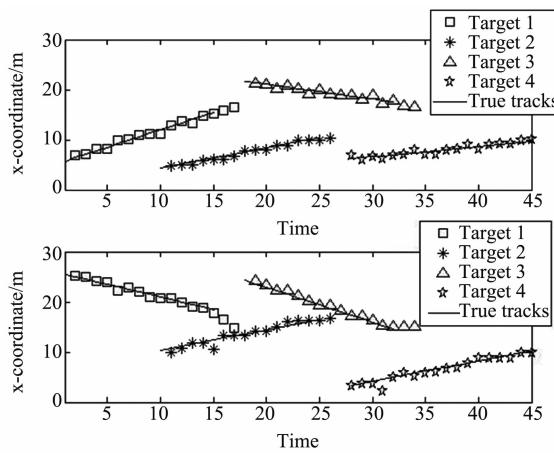


图 9 目标状态以及航迹估计 (SNR = 7.5 dB)
Fig. 9 Trajectory of targets estimation (SNR = 7.5 dB)

对目标数目进行有效的估计。信噪比越高, BOX-LMB-DT 算法对目标的新生和死亡越敏感, 当目标数目发生变化时需要进行调整的时间越短。

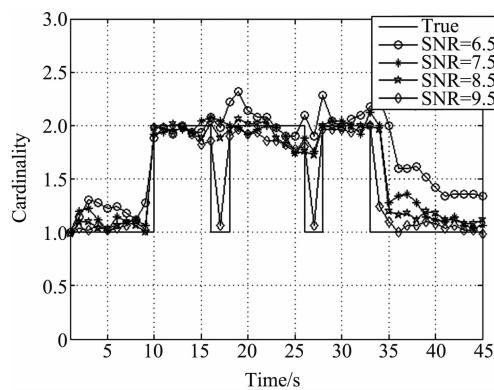


图 10 不同信噪比下目标数估计 (100MC)
Fig. 10 Cardinality for targets estimation (100MC)

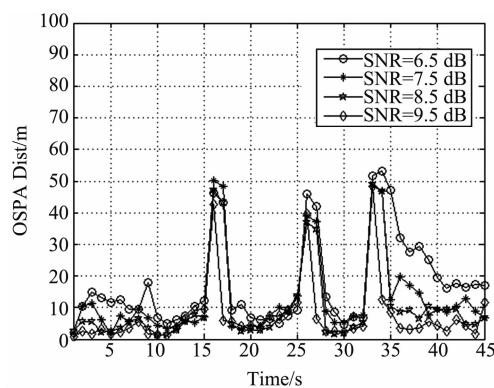


图 11 不同信噪比下 OSPA 距离估计 (100MC)
Fig. 11 OSPA for different SNRs (100MC)

图 11 为不同信噪比下 100 次蒙特卡洛实验得到的 OSPA 距离。不同的信噪比下在初始时刻、第

10、18、28 时刻有目标新生, 在第 15、25、32 时刻有目标消失, 所以在这些时刻附近 OSPA 距离出现峰值, 即在目标新生和消失时, 算法在对目标的位置以及目标个数的估计会出现较大的误差。在目标数目不发生改变时, OSPA 距离虽然会随着信噪比的减小而增大, 但是都在一个较小值附近保持稳定, 说明通过均值滤波选取量测并结合箱粒子标签多伯努利滤波能够稳定有效的估计多目标的状态和数目。

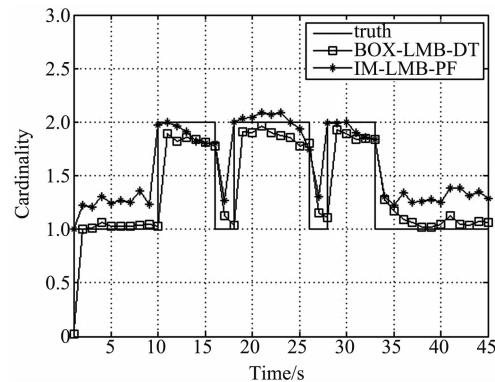


图 12 BOX-LMB-DT 算法和 IM-LMB-PF 算法对目标个数的估计 ($N_z = 9$, SNR = 7.5dB, 100MC)
Fig. 12 Cardinality for BOX-LMB-DT algorithm and IM-LMB-PF algorithm ($N_z = 9$, SNR = 7.5dB, 100MC)

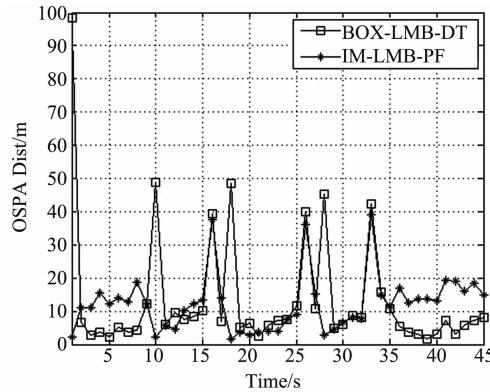


图 13 BOX-LMB-DT 算法和传统 IM-LMB-PF 算法对目标状态估计 OSPA 距离 ($N_z = 9$, SNR = 7.5dB, 100MC)
Fig. 13 OSPA distance for BOX-LMB-DT algorithm and IM-LMB-PF algorithm ($N_z = 9$, SNR = 7.5dB, 100MC)

图 12 和图 13 分别为 BOX-LMB-DT 算法和区间量测下标签多伯努利粒子滤波 (LMB Particle Filter with Interval Measurement, IM-LMB-PF) 在相同实验条件下对目标的个数估计和 OSPA 距离估计。

由图 12 可以看出 BOX-LMB-DT 在目标出现时候会有一个估计延时, 而 IM-LMB-PF 则不会有这个延时, 但是 IM-LMB-PF 易多估计目标的个数。由图

13 可知,在目标死亡(15 s, 25 s, 32 s)时刻附近, BOX-LMB-DT 算法和 IM-LMB-PF 算法都会产生误差峰值,在目标新生(1 s, 10 s, 18 s, 28 s)时刻附近, BOX-LMB-DT 算法估计会产生误差峰值。

表 2 为 BOX-LMB-DT 算法与 IM-LMB-PF 算法的试验结果对比。通过记录 100 次蒙特卡洛实验的运行时间并求均值。

由表 2 可知相同条件下当 BOX-LMB-DT 算法与 IM-LMB-PF 算法性能接近时, BOX-LMB-DT 算法的运算效率提升了 22.59%。

**表 2 BOX-LMB-DT 算法与 IM-LMB-PF 算法性能对比
($N_z = 9$, SNR = 7.5dB, 100MC)**

Table 2 Performance comparison of BOX-LMB-DT algorithm and IM-LMB-PF algorithm ($N_z = 9$, SNR = 7.5dB, 100MC)

算法	所用粒子数	运行时间	OSPA 均值
BOX-LMB-DT	15	15.45 s	1.237 1 m
IM-LMB-PF	2 900	18.94 s	1.273 5 m

4.3 实验 2

实验中目标运动模型为变速曲线(Variable speed curve, VSC)运动模型, 目标的速度在不同时刻是变化的:

$$x_k = \begin{bmatrix} 1 & T & 0 & 0 & 0 \\ 0 & 0.9 & 0 & 0 & 0 \\ 0 & 0 & 1 & T & 0 \\ 0 & 0 & 0 & 1.02 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} x_{k-1} + v_k$$

有 5 个目标(图 14)随机出现在观测区域内:目标 1 的初始状态为 [10 m; 0.7 m · s⁻¹; 22 m; -0.5 m · s⁻¹; 15 dB], 存活时间 1 s-22 s; 目标 2 的初始状态为 [9 m; 0.4 m · s⁻¹; 11 m; 0.3 m · s⁻¹; 15 dB], 存活时间 1 s-25 s; 目标 3 的初始状态为 [20 m; 0.7 m · s⁻¹; 22 m; -0.5 m · s⁻¹; 15 dB], 存活时间 10 s-35 s; 目标 4 的初始状态为 [20 m; 0.7 m · s⁻¹; 22 m; -0.5 m · s⁻¹; 15 dB], 存活时间 15 s-45 s; 目标 5 的初始状态为 [20 m; 0.7 m · s⁻¹; 22 m; -0.5 m · s⁻¹; 15 dB], 存活时间 26 s-41 s。

新生目标概率为 $r^{(i)} = 0.02$, 新生目标分布为服从 $p^{(i)} = N(x; m^{(i)}, P)$, $i = 1, 2, 3$ 的高斯分布, 其中:

$$\begin{aligned} m^{(1)} &= [10 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 22 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}]; \\ m^{(2)} &= [9 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 11 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}]; \\ m^{(3)} &= [20 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 22 \text{ m}; 0 \text{ m} \cdot \text{s}^{-1}; 15 \text{ dB}]; \\ P &= [2.25 \text{ m}^2; 0.8 \text{ m}^2 \cdot \text{s}^{-2}; 2.25 \text{ m}^2; 0.8 \text{ m}^2 \cdot \text{s}^{-2}]; \end{aligned}$$

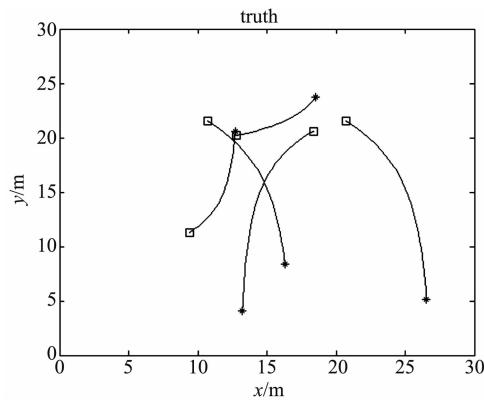


图 14 真实航迹

Fig. 14 Truth trajectories

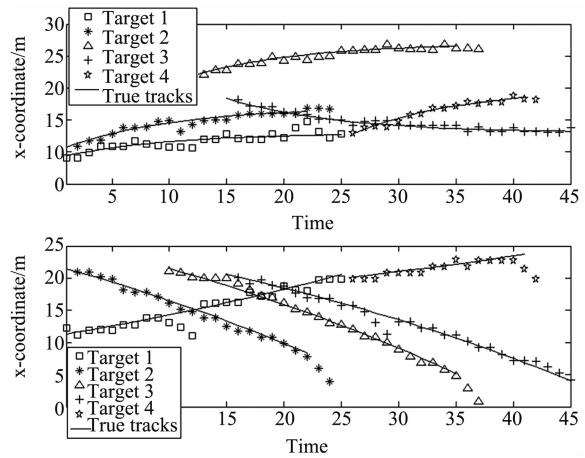


图 15 状态估计(SNR = 7.5 dB)

Fig. 15 Trajectory of targets estimation (SNR = 7.5 dB)

$2^2 \text{ dB}^2]$.

除上述实验条件外,其它实验条件均与实验 1 中相同。图 15 的实验结果表明本文所提 BOX-LMB-DT 算法对于变速的曲线运动目标时,当目标消失后,会多估计 1-2 个时刻的状态,但也能够实现有效的跟踪。

图 16 为不同信噪比下, BOX-LMB-DT 算法对目标的势估计,由图 16 结果可以看出, BOX-LMB-DT 算法在不同信噪比下,能够有效的对作变速曲线运动目标的势进行估计,由图 16 还可以知道,随着信噪比的提升, BOX-LMB-DT 算法对于目标的消失越来越敏感,如第 35 s 后,信噪比越高,越容易恢复对目标数目的准确估计。

图 17 为不同信噪比下, BOX-LMB-DT 算法对目标状态估计的 OSPA 距离图,显然随着信噪比的提升, BOX-LMB-DT 算法对目标状态的估计越准确,结合图 16 可以看出,除了目标新生以及死亡时刻

(如:15 s、23 s、36 s、42 s), BOX-LMB-DT 算法对目标的估计会出现较大误差, 其他时刻 BOX-LMB-DT 算法都能有效的对变速曲线运动目标的状态进行估计。

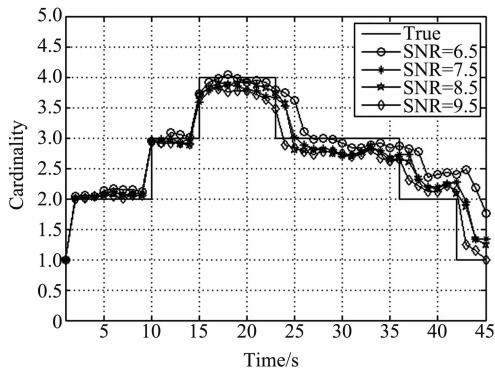


图 16 BOX-LMB-DT 算法不同信噪比下对目标个数的估计($N_z = 9$, 100MC)

Fig. 16 In different signal-to-noise ratios, Cardinality for BOX-LMB-DT algorithm ($N_z = 9$, 100MC)

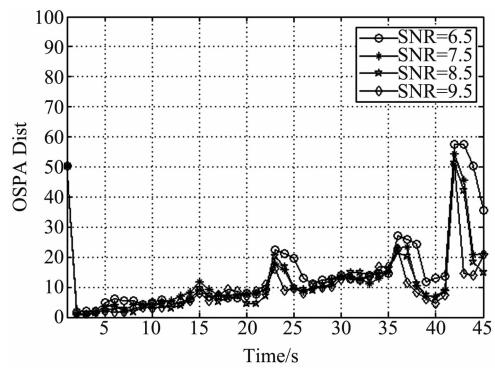


图 17 BOX-LMB-DT 算法不同信噪比下对目标状态估计 OSPA 距离($N_z = 9$, 100MC)

Fig. 17 In different signal-to-noise ratios, OSPA distance for BOX-LMB-DT algorithm ($N_z = 9$, 100MC)

5 结论

利用检测后跟踪的思想, 通过均值滤波对红外图像进行降噪处理, 利用强度挑选出区间量测, 结合箱粒子标签多伯努利滤波器提出 BOX-LMB-DT 算法。仿真实验表明, 对于红外图像量测, 在信噪比较低时, BOX-LMB-DT 算法能够有效的估计多目标的状态和个数, 同时输出各目标的航迹。相较于 IMLMB-PF 算法, BOX-LMB-DT 算法在运算效率上提升了 22.59%。

References

- [1] YANG Wei, FU Yao-Wen, PAN Xiao-Gang, et al. Track-before-detect technique for dim targets: an overview [J].

- Acta Electronica Sinica*, (杨威, 傅耀文, 潘小刚, 等. 弱目标检测前跟踪技术研究综述. 电子学报) 2014, **42** (9): 1786–1793.
- [2] Mahler R P S. *Statistical multisource-multitarget information fusion* [M]. London: Artech House, 2007.
- [3] LIN Zai-Ping, ZHOU Yi-Yu, AN Wei. Improved multitarget track-before-detect using probability hypothesis density filter [J]. *J Infrared Millim W*, (林再平, 周一宇, 安玮. 改进的概率假设密度滤波多目标检测前跟踪算法[J]. 红外与毫米波学报), 2012, **31**(5): 475–480.
- [4] Vo B T, Vo B N, Pham N T, et al. Joint detection and estimation of multiple objects from image observation [J]. *IEEE Trans. on Signal Process*, 2010, **58**(10): 5129–5141.
- [5] Punithakumar K, Kirubarajan T. A sequential Monte Carlo probability hypothesis density algorithm for multitarget track-before-detect [J]. *Proceedings of SPIE - The International Society for Optical Engineering*, 2005, 59131S-59131S-8.
- [6] LIN Zai-Ping, ZHOU Yi-Yu, AN Wei. Track-before-detect algorithm based on cardinalized probability hypothesis density filter [J]. *J Infrared Millim W*, (林再平, 周一宇, 安玮. 基于势概率假设密度滤波的检测前跟踪新算法. 红外与毫米波学报) 2013, **32**(5): 437–443.
- [7] Mahler R P S. Multitarget Bayes filtering via first-order multitarget moments [J]. *IEEE Transactions on Aerospace & Electronic Systems*, 2004, **39**(4): 1523–1178.
- [8] Mahler R P S, Mahler R. PHD filters of higher order in target number [J]. *IEEE Transactions on Aerospace & Electronic Systems*, 2007, **43**(4): 1523–1543.
- [9] Vo B T, Vo B N, Cantoni A. The cardinality balanced multi-target multi-bernoulli filter and its implementations [J]. *IEEE Transactions on Signal Processing*, 2009, **57**(2): 409–423.
- [10] Vo B T, Vo B N. Labeled random finite sets and multi-object conjugate priors [J]. *IEEE Transactions on Signal Processing*, 2013, **61**(13): 3460–3475.
- [11] Vo B N, Vo B T, Phung D. Labeled random finite sets and the bayes multi-target tracking filter [J]. *IEEE Transactions on Signal Processing*, 2013, **62**(24): 6554–6567.
- [12] Reuter S, Vo B T, Vo B N, et al. The labeled multi-bernoulli filter [J]. *IEEE Transactions on Signal Processing*, 2014, **62**(12): 3246: 409–3260.
- [13] Papi F. Constrained d-GLMB filter for multi-target track-before-detect using radar measurements [C]. In European Intelligence and Security Informatics Conference, Manchester, UK, 2015, Sept 7-9, 2015.
- [14] Rathnayake T, Gostar A K, Hoseinnezhad R, et al. Labeled multi-Bernoulli track-before-detect for multi-target tracking in video [C]. 18th International Conference on Information Fusion (Fusion), Washington, DC, USA, 2015, July 6-9.
- [15] Abdallah F, Gning A, Bonnifait P. Box particle filtering for nonlinear state estimation using interval analysis [J]. *Automatica*, 2008, **44**(3): 807–815.
- [16] Jaulin L. *Applied interval analysis* [M]. Berlin, Germany: Springer, 2001.
- [17] Andrew A M. Applied interval analysis, with examples in parameter and state estimation, robust control and robotics [J]. *Kybernetika*, 2002, **31**(5): 117–123.

(下转第 253 页)