

基于 Mean Shift 迭代的新生未知多扩展目标跟踪

李翠芸[†], 桂 阳, 刘 靳

(西安电子科技大学 电子工程学院, 西安 710071)

摘 要: 针对当前基于随机集的多扩展目标跟踪算法存在计算量大、量测划分不准确和跟踪误差大的问题, 在 PHD 滤波基础上提出一种基于均值漂移 (Mean Shift) 迭代的新生未知多扩展目标跟踪算法. 首先, 对聚类后量测数据进行关联, 得到新生目标状态, 解决目标新生问题; 然后, 通过 Mean Shift 迭代获得目标量测集质心, 将扩展目标的多量测问题转化为少量测处理; 最后, 给出其粒子实现方式. 仿真实验表明, 所提出的算法可以降低跟踪复杂度, 提高跟踪效率, 在交叉时刻具有稳定的跟踪性能.

关键词: 多扩展目标跟踪; PHD 滤波; 均值漂移; 新生未知; 粒子滤波

中图分类号: TP391

文献标志码: A

Unknown newly born multiple extended targets tracking based on mean shift iteration

LI Cui-yun[†], GUI Yang, LIU Jin

(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

Abstract: Currently the traditional multiple extended target tracking algorithms based on random finite set (RFS) cause a large amount of computing, misclassification and low tracking performance. Therefore, this paper proposes an unknown newly born multiple extended targets tracking algorithm using mean shift iteration based on probability hypothesis density (PHD). Firstly, the state of newly born targets are obtained by associating the clustered measurements. Then, the centroids of measurement set are obtained by mean shift iteration which maps the multiple measurements to a single measurement. Finally, the proposed algorithm is performed by using the Sequential Monte Carlo method. The simulation shows that the proposed algorithm has significantly lower complexity, the higher tracking efficiency and the more robust performance than the traditional algorithm at targets crossing.

Keywords: multiple extended targets tracking; probability hypothesis density (PHD); mean shift; unknown newly born targets; particle filter

0 引 言

由于传感器精度的不断提高或传感器对目标的近距离跟踪, 每个目标在每一个采样周期可产生多个量测, 这类目标被称为扩展目标^[1-2]. 作为目标跟踪领域内越来越受关注的方向, 扩展目标跟踪技术有广泛的应用, 例如自动雷达对车辆的跟踪、激光测距雷达对人运动情况的跟踪以及地面或海事雷达站对近距飞机或舰船的跟踪^[3].

2009 年, Mahler^[4] 提出扩展目标 PHD (ET-PHD) 算法, 该算法导出了量测更新方程. 随后, Granström 等^[5-6] 提出了该方法的高斯混合实现形式. 为了解决非线性非高斯条件下扩展目标跟踪的问题, Li 等^[7]

于 2013 年提出了扩展目标粒子 PHD (ET-P-PHD) 及其实现. 上述算法的精确滤波更新都需要当前量测集的所有可能划分, 而量测集的所有可能划分数目随量测数的增加而急剧增加, 进而增加了计算量. 同时, 由于有些划分的不合理, 导致其权值很小, 对目标估计几乎不产生影响, 却带来了很大的运算负荷. 针对这一问题, 文献 [8] 提出了一种基于 Mean Shift 聚类的扩展目标量测集划分算法, 该算法通过对量测密度梯度估计进行迭代搜索, 获得量测聚类结果, 改进了量测划分方式, 相比传统的量测划分方式, 减低了运算复杂度, 但仍然存在量测划分所带来的问题.

在传统的 PHD 多扩展目标跟踪中, 新生目标的

收稿日期: 2016-03-24; 修回日期: 2016-06-20.

基金项目: 国家自然科学基金项目 (61372003); 国家自然科学基金青年基金项目 (61301289).

作者简介: 李翠芸 (1976—), 女, 副教授, 博士, 从事非线性滤波方法、数字图像处理、红外弱小目标检测与跟踪等研究; 桂阳 (1991—), 女, 硕士生, 从事扩展目标跟踪方法的研究.

[†] 通讯作者. E-mail: cyli@xidian.edu.cn

初始状态是先验已知的,然而在实际场景中,目标可能在传感器视场中的任何位置出现,此时预先假定的目标新生强度无法覆盖所有新生目标.针对这一问题,Ristic等^[9]提出了基于量测驱动的自适应目标新生滤波器,文献[10]对该算法做出了改进,但是此算法滤波性能不是很好.

本文提出一种基于Mean Shift迭代的新生未知多扩展目标PHD跟踪算法.通过Mean Shift与PHD滤波的迭代更新,收敛至目标的量测质心,将多扩展目标跟踪问题转化为多点目标跟踪;利用量测与目标状态相互映射的方法,避免了对量测进行划分,提高了跟踪效率.同时,本文所提出算法利用前后时刻量测关联简要获取新生目标的位置和速度信息.

1 基于Mean Shift迭代的新生未知多扩展目标跟踪

在实际情况中,每个目标都有空间形态或形状.当目标的形状不能忽略时,为了估计出扩展目标的形状等信息,可以采用不同模型对扩展目标建模,例如随机矩阵模型^[11-13]、随机超曲面模型^[14-16].在一些应用场景中,当不需要对扩展目标的形态信息进行估计,只关注扩展目标的位置和速度信息时,目标的量测集可以建模为目标源加上杂波,此时可将扩展目标的跟踪问题转化为点目标的跟踪问题,避免量测划分带来的计算复杂度高、跟踪时间长、精度低的问题.

1.1 目标跟踪模型

1.1.1 目标状态模型

假设 k 时刻扩展目标的状态集表示为

$$X_k = \{x_k^i\}_{i=1}^{N_{x,k}} = \{[c_{x,k}^i, v_{x,k}^i, c_{y,k}^i, v_{y,k}^i]^T\}_{i=1}^{N_{x,k}},$$

量测集表示为 $Z_k = \{z_k^j\}_{j=1}^{N_{z,k}}$.其中: $N_{x,k}$ 和 $N_{z,k}$ 分别为 k 时刻的状态数和量测数, $(c_{x,k}^i, c_{y,k}^i)$ 和 $(v_{x,k}^i, v_{y,k}^i)$ 分别为第 i 个目标 k 时刻在 X 和 Y 方向上的位置和速度.目标的运动状态模型为线性高斯动态模型,即

$$x_{k,i} = F_k x_{k-1,i} + G_k v_{k-1}, \quad 1 \leq i \leq N_{x,k}. \quad (1)$$

其中: $x_{k,i}$ 表示目标的状态变量; F_k 表示状态转移矩阵; G_k 表示输入矩阵; v_{k-1} 表示过程噪声,服从高斯分布,协方差为 Q_k .

1.1.2 目标量测模型

对于扩展目标,一个目标可以产生多个量测,在不考虑目标形态的情况下,同一个目标产生的量测可以用分布在目标源周围的一个量测集进行近似,量测集中元素的个数为服从泊松分布的随机变量.量测模型为

$$z_{k,i}^j = H_k x_{k,i} + e_k^j, \quad 1 \leq j \leq N_{z,k}^i. \quad (2)$$

其中: $z_{k,i}^j$ 为 k 时刻第 i 个目标产生的第 j 个量测; $N_{z,k}^i$ 为第 k 时刻第 i 个目标产生的量测数目; H_k 为观测矩阵; e_k 为高斯白噪声,其噪声协方差为 R_k .

1.2 算法提出

对于点目标,一个目标最多产生一个量测,用量测集对状态集更新,可以得到多目标的状态.对于扩展目标,一个目标可以产生多个量测,因此用量测集对目标进行更新,就会出现多估现象,导致目标状态估计错误.此时,若一个目标对应的量测集按照一定的映射关系转化为单个量测,则可解决多估的现象.

1.2.1 新生目标估计

假设空间有两个目标, k 时刻质心对应的量测估计值分别为 $\hat{z}_{k,1}$ 和 $\hat{z}_{k,2}$,且

$$\hat{z}_{k,i} = \frac{1}{N_{z,k}^{(i)}} \sum_{j=1}^{N_{z,k}^{(i)}} z_{k,i}^j, \quad i = 1, 2. \quad (3)$$

以 $z_{k,i}^j$ 为中心, R 为协方差矩阵的高斯分布对每个真实量测点采样 N_p 个粒子,得到虚拟量测采样点,则

$$z_{p,i}^j = \frac{1}{N_p} \sum_{l=1}^{N_p} z_{p,i}^{(j)(l)}, \quad (4)$$

其中 $z_{p,i}^{(j)(l)}$ 表示虚拟量测采样点.当 N_p 足够大时

$$\hat{z}_{k,i} = \frac{1}{N_{z,k}^{(i)} N_p} \sum_{j=1}^{N_{z,k}^{(i)}} \sum_{l=1}^{N_p} z_{p,i}^{(j)(l)}, \quad i = 1, 2. \quad (5)$$

即通过采样,目标质心对应的量测估计值不会发生变化.以 $r = \alpha \sqrt{\sigma_x \sigma_y}$ ($\alpha \geq 1$)为半径,以每个 $z_{k,i}^j$ 为初始值,采用Mean Shift算法进行聚类,将聚类后距离非常近的量测点认为是同一个目标产生的量测点划分至同一个单元,每个单元的量测均值视为目标质心对应的量测估计值.对 $k-1$ 时刻和 k 时刻的量测集划分得到划分后的量测质心估计集分别为 $\{\hat{z}_{k-1}^{(1)}, \hat{z}_{k-1}^{(2)}, \dots, \hat{z}_{k-1}^{(N_{z,est}^{k-1})}\}$ 和 $\{\hat{z}_k^{(1)}, \hat{z}_k^{(2)}, \dots, \hat{z}_k^{(N_{z,est}^k)}\}$,其中 $N_{z,est}^{k-1}$ 和 $N_{z,est}^k$ 分别表示划分后的量测数.分别从 $k-1$ 时刻和 k 时刻划分后的量测质心集中取两个量测 $(\hat{z}_{k-1}^{(\alpha)}, \hat{z}_k^{(\beta)})$, $1 \leq \alpha \leq N_{z,est}^{k-1}$, $1 \leq \beta \leq N_{z,est}^k$,进行关联,并对 k 时刻的状态进行预测得到的状态作为 $k+1$ 时刻的新生目标状态.若预测的新生目标状态集记为 Γ ,则真实的新生目标状态 $x_{birth} \in \Gamma$.

综上所述,根据前后时刻关联得到的新生目标数目为 $N_{birth} = N_{z,est}^{k-1} \cdot N_{z,est}^k$,并随着 $N_{z,est}^{k-1}$ 和 $N_{z,est}^k$ 的增大成倍数增长.为了减少计算量,根据跟踪的目标特性设置速度阈值 v_{min} 和 v_{max} .当估计的新生目标速度满足 $v_{min} \leq v_{birth} \leq v_{max}$ 时保留,否则舍弃.

1.2.2 预测

选取估计新生目标的状态集 Γ 作为目标状态预测的初始值.

目标预测的蒙特卡洛实现,分别对存活目标

的建议分布 $q_k(\cdot|x_{k-1}^{(i)}, Z_k)$ 和新生目标的建议分布 $p_k(\cdot|Z_k)$ 进行采样, 每个目标状态的粒子数为 M_p . 由上一步可以知道 k 时刻新生目标的数目为 N_{birth} , 对新生目标的 Monte Carlo 采样粒子数为 $J_k = N_{\text{birth}} \times M_p$, 没有新生目标则不进行采样. 存活的目标数目为 N_s , 有 $L_{k-1} = N_s \times M_p$ 个粒子存活.

对于 $i = 1, 2, \dots, L_{k-1}$, 采样 $x_{k|k-1}^{(i)} \sim q_k(\cdot|x_{k-1}^{(i)}, Z_k)$, 预测存活粒子的权值为

$$w_{k|k-1}^{(i)} = \frac{p_{s,k}(x_{k-1}^{(i)})\varphi_{k|k-1}(x_k^{(i)}, x_{k-1}^{(i)})}{q_k(x_k^{(i)}|x_{k-1}^{(i)}, Z_k)} w_{k-1}^{(i)}. \quad (6)$$

其中: $p_{s,k}(x_{k-1}^{(i)})$ 为目标在 k 时刻的生存概率, $\varphi_{k|k-1}(x_k^{(i)}, x_{k-1}^{(i)})$ 为 k 时刻单目标的转移概率密度.

对 $i = L_{k-1} + 1, L_{k-1} + 2, \dots, L_{k-1} + J_k$, 采样 $x_{k|k-1}^{(i)} \sim p_k(\cdot|Z_k)$, 预测新生粒子的权值为

$$w_{k|k-1}^{(i)} = \frac{1}{J_k} \frac{\eta_k(x_k^{(i)})}{p_k(x_k^{(i)}|Z_k)}, \quad (7)$$

其中 $\eta_k(x_k^{(i)})$ 表示新生目标集 Γ 的 PHD.

1.2.3 量测集一次 Mean Shift

算法的原理是根据预测的目标状态对量测集中的目标量测点进行简单的距离判断, 再利用 Mean Shift 对粒子滤波器中众多的粒子进行聚类分析和 PHD 滤波, 使每个粒子收敛于局部最优值, 这样就得到每个目标量测集质心和更新后目标的最优值.

第 k 时刻, 量测 Mean Shift 初始值选择预测后的目标状态集作为目标迭代的初始值. 因为 Mean Shift 算法是收敛的, 所以在当前时刻中通过反复 Mean Shift 算法和 PHD 更新迭代搜索特征空间中样本点最密集的区域, 搜索点沿着样本点密度增加的方向“漂移”到局部密度极大点, 也就是被认为的目标位置, 从而达到目标跟踪的目的.

假设目标第 r 次迭代后的状态为 $\hat{x}_{k,i}^r (r > 0)$, 第 $r + 1$ 次迭代的量测质心为 $\hat{z}_{k,i}^{r+1}$, 核函数的估计式为

$$\hat{f}(\hat{z}_{k,i}^{r+1}) = \frac{1}{N_n} \sum_{j=1}^m \kappa(\hat{z}_{k,i}^{r+1} - h(\hat{x}_{k,i}^r)). \quad (8)$$

其中: r 表示迭代次数, N_n 表示每一个量测集内分配的量测点的个数, $\kappa(\cdot)$ 表示核函数.

Mean Shift 算法本质上是一个基于概率密度估计的迭代过程, 使得每个点都指向概率密度最大的方向. 本文所提算法采用的高斯核函数为

$$\kappa(\cdot) = p(z_k^j|\hat{x}_{k,i}^r) = \frac{1}{2\pi|R_k|} \exp\left(-\frac{1}{2}(z_k^j - h(\hat{x}_{k,i}^r))^T \times R_k^{-1}(z_k^j - h(\hat{x}_{k,i}^r))\right). \quad (9)$$

Mean Shift 向量为

$$m(\hat{z}_{k,i}^{r+1}) = E[z_k^j|\hat{x}_{k,i}^r] - \hat{x}_{k,i}^{r+1} = \sum_{j=1}^{N_{z,k}} p(z_k^j|\hat{x}_{k,i}^r) z_k^j / \sum_{j=1}^{N_{z,k}} p(z_k^j|\hat{x}_{k,i}^r) - \hat{x}_{k,i}^{r+1}. \quad (10)$$

要使 $\hat{\nabla} f(\hat{z}_{k,i}^{r+1}) = 0$, 当且仅当 $m(\hat{z}_{k,i}^{r+1}) = 0$, 可以得出

$$\hat{z}_{k,i}^{r+1} = \sum_{j=1}^{N_{z,k}} p(z_k^j|\hat{x}_{k,i}^r) z_k^j / \sum_{j=1}^{N_{z,k}} p(z_k^j|\hat{x}_{k,i}^r). \quad (11)$$

所以可以得到 k 时刻, 一次 Mean Shift 后的量测集合

$$Z_{k,r+1} = \{z_{k,r+1}^{(1)}, z_{k,r+1}^{(2)}, \dots, z_{k,r+1}^{(N_{\text{birth}}+N_s)}\}.$$

1.2.4 更新

对 $i = 1, 2, \dots, L_{k-1} + J_k$, 用一次 Mean Shift 后的量测集合 $Z_{k,r+1} = \{z_{k,r+1}^{(1)}, z_{k,r+1}^{(2)}, \dots, z_{k,r+1}^{(N_{\text{birth}}+N_s)}\}$, 更新粒子权值, $z_{k,r+1} \in Z_{k,r+1}$.

$$w_k^{(i)} = \left[\left(1 - P_{D,k}(x_{k|k-1}^{(i)})\right) + \sum_{z \in Z_{k,r+1}} \frac{\psi_{k,z_{k,r+1}}(x_{k|k-1}^{(i)})}{K_k(z_{k,r+1}) + C_k(z_{k,r+1})} \right] w_{k|k-1}^{(i)}, \quad (12)$$

$$C_k(z_{k,r+1}) = \sum_{j=1}^{L_{k-1}+J_k} \psi_{k,z_{k,r+1}}(x_{k|k-1}^{(j)}) w_{k|k-1}^{(j)}, \quad (13)$$

$$\psi_{k,z_{k,r+1}}(x_{k|k-1}^{(i)}) =$$

$$P_{D,k}(x_{k|k-1}^{(i)}) g_k(z_{k,r+1}|x_{k|k-1}^{(i)}). \quad (14)$$

其中: $P_{D,k}(x_{k|k-1}^{(i)})$ 表示目标在 k 时刻的检测概率, $g_k(z_{k,r+1}|x_{k|k-1}^{(i)})$ 表示单目标观测的似然函数, $K_k(\cdot)$ 表示 k 时刻虚警随机集 K_k 的 PHD.

由于估计状态与真实状态有一定的偏差, 更新后的估计量测质心与真实量测质心也会产生偏差. 为了减小量测质心偏差, 采用迭代更新的方法, 由 1.2.3 和 1.2.4 节步骤构成了迭代更新步骤, 迭代终止条件为

$$\begin{cases} d(x^{r+1}, x^r) < \tau_x, \\ d(z^{r+1}, z^r) < \tau_z. \end{cases} \quad (15)$$

其中: $d(\cdot, \cdot)$ 表示距离函数, 本文采用欧氏距离; τ_x 和 τ_z 表示迭代终止门限.

1.2.5 重采样

对更新后的粒子集重采样 $M_p \times (N_{\text{birth}} + N_s)$ 个粒子, 得到粒子集为 $\{(x_{k|k,i}^{(j)}, \omega_{k|k,i}^{(j)})\}_{j=1}^{M_p \times (N_{\text{birth}}+N_s)}$.

1.3 算法复杂度说明

扩展目标粒子 PHD 滤波算法一个时刻更新步骤所用的时间为 $pN_{z,\text{est}}C_s$. 其中: p 表示量测集划分方式的种类, $N_{z,\text{est}}$ 表示量测集中量测数据数, C_s 表示一个粒子完成一次更新所需要的时间.

本文所提算法一个时刻更新步骤所用的时间为 $(N_{\text{birth}} + N_s)mC_s$. 其中: $(N_{\text{birth}} + N_s)$ 表示目标个数; m 表示完成一次 Mean Shift 的平均迭代次数, 一般

为4到6次. $(N_{\text{birth}} + N_s)mC_s$ 的值远小于 $pN_{z,\text{est}}C_s$ 的值,因此本文所提算法降低了运算的复杂度.


2 仿真结果

本节针对所提出的基于 Mean Shift 迭代的粒子 PHD 多扩展目标跟踪算法 (MS-P-PHD) 进行性能仿真实验,并与传统 ET-P-PHD 算法进行对比.采用 OSPA 距离作为评价标准,实验参数设置如下:


$$F_x = \begin{bmatrix} 1 & \frac{\sin(w \times T_s)}{w} & 0 & \frac{\cos(w \times T_s) - 1}{w} \\ 0 & \cos(w \times T_s) & 0 & -\sin(w \times T_s) \\ 0 & \frac{1 - \cos(w \times T_s)}{w} & 1 & \frac{\sin(w \times T_s)}{w} \\ 0 & \sin(w \times T_s) & 0 & \cos(w \times T_s) \end{bmatrix},$$

$$G_k = \begin{bmatrix} \frac{T^2}{2} & T & 0 & 0 \\ 0 & 0 & \frac{T^2}{2} & T \end{bmatrix}^T, H_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}.$$

其中:角速度 $w = -1.5 \text{ rad}$,时间 $T_s = 1 \text{ s}$. 过程噪声 $v_{k-1} \sim N(0, \sigma_w^2 I)$, $\sigma_w = 1$. e_k^j 为高斯白噪声, $e_k^j \sim N(0, \sigma_e^2 I)$, 其中每一时刻的量测标准差 $\sigma_e = 10$. 对每个量测采样得到的虚拟量测点个数 N_p 为 50. 目标运动区域为 $[-500, 500] \times [-500, 500]$, 目标的检测概率 $P_d = 0.98$, 目标存活概率 $P_S = 0.98$. 速度阈值 $v_{\min} = 2 \text{ m/s}$ 和 $v_{\max} = 18 \text{ m/s}$, 迭代终止门限 $\tau_x = 0.05$, $\tau_z = 0.05$. 针对每个目标状态设置 $M_p = 500$ 个粒子. 每一时刻的量测个数服从参数为 20 的泊松分布, 杂波均匀分布在目标的活动区域, 杂波个数服从参数为 8 的泊松分布. 目标的初始状态和持续时间如表 1 所示.



(a) X轴跟踪结果



(b) Y轴跟踪结果

图 1 目标运动轨迹估计

表 1 目标运动参数

目标	初始状态	开始时刻	结束时刻
1	(-250, 5, 250, -2)	1	100
2	(10, -5, -140, 2)	1	100
3	(150, -5, -140, 5)	50	100

图 1 给出了一次实验目标的真实运动轨迹和估计轨迹. 从图 1 可以看出, 本文算法能够实现对目标的有效跟踪, 对目标位置估计准确度较高.

以前两个时刻为例, 通过仿真数据说明新生目标捕获过程. 表 2 和表 3 分别表示第 1 时刻和第 2 时刻的量测质心估计集.

表 2 第 1 时刻量测质心估计集

	1	2	3
X 方向	362.0574	225.8498	-477.8749
Y 方向	208.0312	-257.2952	-272.5054
	4	5	6
X 方向	-378.4132	-241.0418	4.4044
Y 方向	-117.6635	245.8170	-135.3692

表 3 第 2 时刻量测质心估计集

	1	2	3
X 方向	354.2894	-323.0488	-380.7399
Y 方向	35.1414	228.1705	40.4374
	4	5	6
X 方向	-246.0964	220.8258	9.1844
Y 方向	247.7688	135.5545	-138.6865

表 4 给出了通过对表 2 和表 3 中数据关联, 设置速度阈值为 $v_{\min} = 2 \text{ m/s}$ 和 $v_{\max} = 18 \text{ m/s}$, 筛选得到的新生目标状态.

表 4 捕获到的新生目标

目标	捕获到的新生目标状态
1	(-241.0418, 5.0546, 245.8170, -1.9518)
2	(4.4004, -4.7800, 137.6376, 1.0480)

通过 100 次蒙特卡洛仿真实验, 本文算法和扩展目标粒子 PHD (ET-P-PHD) 算法对目标的目标数估计对比如图 2(a) 所示, OSPA 距离对比如图 2(b) 所示.

图 2(a) 中, MS-P-PHD 和 ET-P-PHD 均对目标数目作出了平稳的估计, 但由于距离划分, ET-P-PHD 滤波算法在目标交叉时刻会出现少估现象, 对交叉目标估计不理想, 而 MS-P-PHD 可以有效解决在交叉时刻出现的目标数目少估现象. 从图 2(a) 可以看出, 本文算法在新目标出现的时刻, 1 s 和 50 s, 都出现了延迟现象, 原因在于本文算法同时解决新生未知情况下扩展目标跟踪问题, 延迟两个时刻用来捕获新生目标, 而所对比的算法不能处理新生目标未知的情况. 在图 2(b) 中, 在目标新生时刻, 本文所提算法误差较大, 这是由于新生未知, 速度关联获取新生目标的情况下, 对新生目标估计的延迟引起的 OSPA 距离偏大, 其

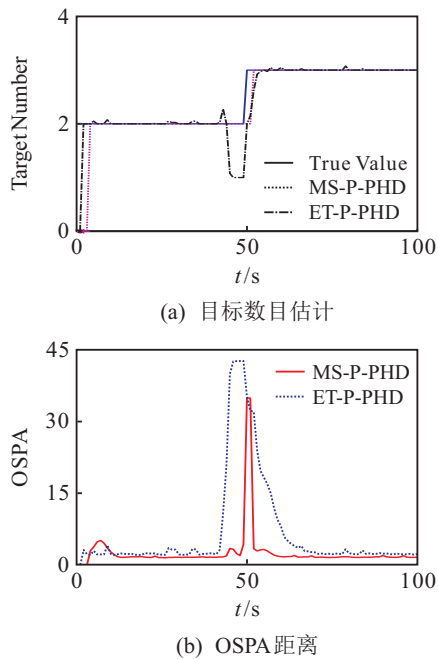


图2 MS-P-PHD与ET-P-PHD性能对比

余时刻OSPA平均距离小于ET-P-PHD算法,误差较小。

图2(b)显示了在目标新生阶段出现OSPA误差先略增大后收敛稳定的情况,原因在于对新生目标的初始状态估计时,速度分量估计存在较大误差,尤其是方向上会偏离真实轨迹,但在后面时刻滤波过程中可逐渐得到校正。

100次仿真实验MS-P-PHD算法和ET-P-PHD算法,平均单次运行时间分别为2.4420s和11.6089s。可以看出,MS-P-PHD滤波算法所需时间远低于传统算法,原因是利用Mean Shift将量测集与目标状态相互映射,避免了量测划分,提高了跟踪效率。

3 结语

本文提出了基于Mean Shift迭代的新生未知多扩展目标跟踪算法,将扩展目标跟踪问题转化为点目标跟踪问题。同时,对于多量测问题采用迭代的方式,采用加权均值代替量测。从实现效果上可以看出,本文所提算法能够估计出扩展目标的新生信息,而且能够有效解决目标交叉的情况,还可以对目标实时跟踪,其性能优于ET-P-PHD滤波算法。但是,在目标新生的时候跟踪滞后,如何解决该问题是今后需要开展的工作。

参考文献(References)

- [1] Gilholm K, Godsill S, Maskell S, et al. Poisson models for extended target and group tracking[C]. Proc of Signal and Data Processing of Small Targets. San Diego: SPIE, 2005: 230-241.
- [2] Gilholm K, Salmond D. Spatial distribution model for tracking extended objects[J]. IEEE Proc of Radar, Sonar and Navigation, 2005, 152(5): 364-371.
- [3] Koch J W. Bayesian approach to extended object and

cluster tracking using random matrices[J]. IEEE Trans on Aerospace and Electronic Systems, 2008, 44(3): 1042-1059.

- [4] Mahler R. PHD filters for nonstandard targets, I: Extended targets[C]. Int Conf on Information Fusion. Seattle: WA, 2009: 915-921.
- [5] Granström K, Lundquist C, Orguner U. A Gaussian mixture PHD filter for extended target tracking[C]. Proc of the Int Conf on Information Fusion. Edinburgh: IEEE, 2010: 915-921.
- [6] Granström J, Lundquist C, Orguner U. Extended target tracking using a Gaussian-Mixture PHD filter[J]. IEEE Trans on Aerospace and Electronic Systems, 2012, 48(4): 3268-3286.
- [7] Li Y, Xiao H, Song Z, et al. A new multiple extended target tracking algorithm using PHD filter[J]. Signal Processing, 2013, 93(12): 3578-3588.
- [8] 刘风梅, 葛洪伟, 杨金龙, 等. 基于均值漂移聚类的扩展目标量测集划分算法[J]. 计算机工程, 2014, 40(12): 182-187.
(Liu F M, Ge H W, Yang J L, et al. Extended target measure set partition algorithm based on Mean Shift clustering[J]. Computer Engineering, 2014, 40(12): 182-187.)
- [9] Streit R L, Stone L D. Bayes derivation of multitarget intensity filters[C]. Proc. of the 11th Int Conf on Information Fusion. IEEE: 2008: 1-8.
- [10] Zhu Y, Zhou S, Zou H, et al. Probability hypothesis density filter with adaptive estimation of target birth intensity[J]. IET Radar, Sonar & Navigation, 2016, 10(5): 901-911.
- [11] Koch J W. Bayesian approach to extended object and cluster tracking using random matrices[J]. IEEE Trans on Aerospace & Electronic Systems, 2008, 44(3): 1042-1059.
- [12] Granstrom K, Willett P, Bar-Shalom Y. An extended target tracking model with multiple random matrices and unified kinematics[C]. The 18th Int Conf on Information Fusion. 2015: 1007-1014.
- [13] Lan J, Li X R. Tracking of maneuvering non-ellipsoidal extended object or target group using random matrix[J]. IEEE Trans on Signal Processing, 2014, 62(9): 2450-2463.
- [14] Baum M, Hanebeck U D. Random hyper-surface Models for extended object tracking[C]. IEEE Int Symposium on Signal Processing and Information Technology(ISSPIT). Ajman: IEEE, 2009: 178-183.
- [15] 李翠芸, 林锦鹏, 姬红兵. 一种基于椭圆RHM的扩展目标Gamma高斯混合CPHD滤波器[J]. 控制与决策, 2015, 30(9): 1551-1558.
(Li C Y, Lin J P, Ji H B. A Gamma gaussian-Mixture CPHD filter based on ellipse random hypersurface models for extended targets[J]. Control and Decision, 2015, 30(9): 1551-1558.)
- [16] Zea A, Faion F, Hanebeck U D. Tracking extended objects using extrusion random hypersurface models[C]. IEEE Isif Workshop on Sensor Data Fusion: Trends, Solutions, Applications. Bonn: IEEE, 2014: 1-6.