

基于观测数据聚类划分的扩展目标跟踪算法

章涛^{1,2} 来燃¹ 吴仁彪¹

(1. 中国民航大学天津市智能信号与图像处理重点实验室, 天津, 300300; 2. 天津大学电子信息工程学院, 天津, 300072)

摘要: 针对高斯混合假设概率密度滤波扩展目标跟踪算法中的观测集合划分问题, 本文分析了距离门限划分方法存在的问题, 提出了一种利用聚类方法进行观测数据集合划分的方法。该方法利用极大似然方法获得目标数的估计值, 以此作为聚类数利用 K-means 聚类对观测数据集合进行聚类划分, 并利用椭圆门限对观测数据进行处理以降低杂波观测对聚类划分的影响。实验结果表明, 该方法能够获得正确的划分观测集合, 计算复杂度较距离门限划分方法有较大降低, 同时, 在多目标跟踪效果方面优于观测数据距离门限划分的假设概率密度滤波扩展目标跟踪算法。

关键词: 多目标跟踪; 扩展目标跟踪; 概率假设密度滤波; 观测集合划分; K-means 聚类

中图分类号: TP391 **文献标志码:** A

Extended Target Tracking with Clustering of Measurement Partitioning

Zhang Tao^{1,2}, Lai Ran¹, Wu Renbiao¹

(1. Tianjin Key Laboratory for Advanced Signal Processing, Civil Aviation University of China, Tianjin, 300300, China;
2. School of Electronic Information Engineering, Tianjin University, Tianjin, 300072, China)

Abstract: A novel K-means algorithm of measurement partitioning is proposed to overcome the problem of distance partitioning algorithm in Gaussian mixture probability hypothesis density filter for extended target tracking. The number of the targets is estimated by maximum-likelihood estimator and then the estimates of the target number are used as the cluster number of K-means. An elliptical gate is introduced to remove the clutter measurements for depressing the influence of clusters. Simulation results show that the proposed algorithm reduces the computational complexity obviously, and obtains an improved performance.

Key words: multiple-target tracking; extended target tracking; GM-PHD filter; measurement partitioning; K-means clustering

引 言

多目标跟踪在多传感器数据融合领域既是重要的理论问题又是重要的应用问题。目前的多目标跟踪方法可以分为传统的基于数据关联的方法^[1-3]和基于随机有限集理论^[4](Random finite set, RFS)的非

关联方法。概率假设密度(Probability hypothesis density, PHD)滤波方法^[5~7]是非关联多目标跟踪方法的代表。无论是传统的基于数据关联的多目标跟踪方法,还是基于随机有限集理论的方法,绝大多数方法都需要满足这样一个假设:每一个观测都来自于一个可以被看作质点的目标。然而由于传感器分辨率、目标存在多个反射点以及传感器与目标相对位置关系等原因,这一假设并不一定能成立,从而出现了单个目标同时产生多个观测形成的扩展目标问题,如图1所示。

在随机有限集框架下,2003年Mahler提出传递后验概率密度的一阶统计矩的PHD滤波器^[5]。2006年Vo提出了线性高斯条件下PHD滤波器的近似形式GM-PHD(Gaussian mixture PHD)滤波器^[8]。2009年Mahler提出了利用假设概率密度滤波算法解决扩展目标的跟踪问题,并给出了相关算法理论框架,即ET-PHD(Extended target PHD)算法^[9]。2012年,Granstrom提出了基于ET-PHD框架线性条件下的高斯混合模型实现方法,即ET-GM-PHD滤波算法^[10]。在Mahler提出的ET-PHD扩展目标跟踪算法理论框架中,需要将观测数据(包括目标及杂波)划分为多种可能的集合,然后利用所有可能集合划分进行目标状态更新计算,这种方法对于目标数和杂波较多的情况几乎是无法计算的^[10]。Granstrom针对这个问题提出了一种利用距离门限实现观测数据集合划分的方法^[10]。但距离门限范围的设置依赖于实验数据,导致算法性能与观测距离门限范围参数选取情况密切相关,跟踪估计性能很不稳定。

本文提出了一种利用K-means聚类进行观测数据集合划分的方法。该方法利用极大似然方法获得目标数的估计值,以此作为聚类数并利用K-means对观测数据集合进行划分,并利用椭圆门限对观测数据进行处理以降低杂波观测对聚类划分的影响。实验结果表明,该方法能够获得正确的观测集合划分,计算复杂度较距离门限划分方法有较大降低,同时,在多目标跟踪效果方面优于距离门限划分的假设概率密度滤波扩展目标跟踪算法。



图1 扩展目标示意图
Fig. 1 Sketch map of extended target

1 概率假设密度滤波扩展目标跟踪

1.1 目标跟踪模型

概率假设密度滤波算法将多目标跟踪问题转换为一个集值估计问题,避免了数据关联过程。若 k 时刻扩展目标数为 N_k ,单个扩展目标的状态为 \mathbf{x}_k ,则可以利用一个有限集合 $\mathbf{X}_k = \{\mathbf{x}_k^{(i)}\}_{i=1}^{N_k}$ 来描述多个扩展目标的状态,其中 $\mathbf{x}_k^{(i)}$ 表示 k 时刻第 i 个目标的状态。每个目标状态可由下面动态模型描述

$$\mathbf{x}_{k+1}^{(i)} = \mathbf{F}_k \mathbf{x}_k^{(i)} + \mathbf{w}_k^{(i)} \quad (1)$$

式中: \mathbf{F}_k 表示 k 时刻状态转移矩阵, $\mathbf{w}_k^{(i)}$ 为协方差为 $\mathbf{Q}_k^{(i)}$ 的高斯白噪声。

传感器在 k 时刻获得 M_k 个观测,单个观测用 \mathbf{z}_k 表示,则可以用一个有限集合 $\mathbf{Z}_k = \{\mathbf{z}_k^{(i)}\}_{i=1}^{M_k}$ 描述 M_k 个观测,其中 $\mathbf{z}_k^{(i)}$ 表示 k 时刻第 i 个观测。每个观测可由下面观测模型描述,即有

$$\mathbf{z}_{k+1}^{(i)} = \mathbf{H}_k \mathbf{x}_k^{(i)} + \mathbf{n}_k^{(i)} \quad (2)$$

式中: \mathbf{H}_k 为观测矩阵, $\mathbf{n}_k^{(i)}$ 为协方差为 $\mathbf{R}_k^{(i)}$ 的高斯白噪声。

在传统的目标跟踪问题中,一般假设每一个观测都来自于一个可以被看作质点的目标,但对于扩展目标,这一假设将不再成立,一个目标会产生多个观测,Mahler在其提出的ET-PHD滤波框架中将每一个目标产生的扩展观测数假设为Poisson分布。

1.2 扩展目标观测集合划分

观测数据集合划分是ET-PHD扩展目标跟踪框架中一个重要环节,对于扩展目标的跟踪性能有着重要影响。由于多个观测可能来自于同一个目标,多个扩展目标产生的观测集合 \mathbf{Z} 可以被划分为多个

观测子集^[9]。例如观测数据集合 $\mathbf{Z} = \{\mathbf{z}_1, \mathbf{z}_2, \mathbf{z}_3\}$, 集合的势 $|\mathbf{Z}| = 3$, 则观测数据集合可以划分为下面 5 种可能, \mathbf{W}_i^j 表示第 j 个划分可能中的第 i 个划分子集:

$$\begin{aligned} p_1: \mathbf{W}_1^1 &= \{\mathbf{z}_1, \mathbf{z}_2, \mathbf{z}_3\} \\ p_2: \mathbf{W}_1^2 &= \{\mathbf{z}_1\}, \mathbf{W}_2^2 = \{\mathbf{z}_2\}, \mathbf{W}_3^2 = \{\mathbf{z}_3\} \\ p_3: \mathbf{W}_1^3 &= \{\mathbf{z}_1, \mathbf{z}_2\}, \mathbf{W}_2^3 = \{\mathbf{z}_3\} \\ p_4: \mathbf{W}_1^4 &= \{\mathbf{z}_1, \mathbf{z}_3\}, \mathbf{W}_2^4 = \{\mathbf{z}_2\} \\ p_5: \mathbf{W}_1^5 &= \{\mathbf{z}_1\}, \mathbf{W}_2^5 = \{\mathbf{z}_2, \mathbf{z}_3\} \end{aligned}$$

在 ET-PHD 滤波扩展目标跟踪框架中, 观测集合划分方法是将观测任意组合构成多个观测集合划分可能, 并利用观测集合的所有集合划分可能对扩展目标的状态进行更新, 当观测数较大时计算量过大, 对于目标数较多和杂波较多的情况几乎是无法实现的。

为了降低计算量, 2012 年 Granstrom 提出了使用距离阈值进行观测集合划分的方法^[10]。该方法对观测集合 \mathbf{Z} 设定一个距离阈值集合 $\{d_i\}_{i=1}^N$, 集合中的阈值按升序排列, 即 $d_i < d_{i+1}$ 。利用任意 d_i 可将观测集合划分为若干个观测子集, 使划分的每一个子集单元中的观测间距离都小于 d_i 。对于任意两个观测 $\mathbf{z}_k^{(i)}$ 和 $\mathbf{z}_k^{(j)}$, 其 Mahalanobis 距离可以表示为

$$(\mathbf{z}_k^{(i)} - \mathbf{z}_k^{(j)})^T \mathbf{R}_k^{-1} (\mathbf{z}_k^{(i)} - \mathbf{z}_k^{(j)}) \quad (3)$$

式中: \mathbf{R}_k 为观测噪声协方差矩阵。该距离服从 χ^2 分布, 因此可以通过设置概率 P_g 获得在该概率下合理的观测集合划分距离阈值。文献[10]通过实验方法, 总结出阈值取值满足 $P_g \in (0.3, 0.8)$ 时可较好地兼顾正确集合划分和算法计算复杂度, 但由于这种阈值范围的选取依赖于实验数据所总结的经验, 导致跟踪估计性能对于不同数据很不稳定。

1.3 ET-GM-PHD 滤波器

Granstrom 在 ET-PHD 扩展目标跟踪框架的基础上, 提出了线性高斯条件下的实现方法, 即 ET-GM-PHD 滤波器。扩展目标不同于传统的点目标, 一个目标会产成多个传感器观测, Mahler 用 Poisson 模型描述每一个目标产生的传感器观测, $\gamma(\mathbf{x}_k^{(i)})$ 表示 k 时刻第 i 个目标状态 $\mathbf{x}_k^{(i)}$ 产生的观测数的期望, 则第 i 个目标至少产生一个观测的概率为

$$1 - e^{-\gamma(\mathbf{x}_k^{(i)})} \quad (4)$$

若 $P_D(\mathbf{x}_k^{(i)})$ 表示第 i 个目标的检测概率, 则目标状态 $\mathbf{x}_k^{(i)}$ 至少产生一个观测并被传感器检测到的概率, 即有效检测概率为

$$(1 - e^{-\gamma(\mathbf{x}_k^{(i)})}) P_D(\mathbf{x}_k^{(i)}) \quad (5)$$

假设每个目标都满足式(1)线性动态模型, 每个传感器观测满足式(2)线性观测模型, 目标的存活概率与检测概率状态独立, 目标的强度函数可以表示为高斯混合形式, 则针对扩展目标的 ET-GM-PHD 算法的递推公式可以分为预测步和更新步两个步骤, 其中预测步与传统点目标 GM-PHD 方法相同, 即预测步为

$$v_{k|k-1}(\mathbf{x}) = \sum_{j=1}^{J_{k|k-1}} \omega_{k|k-1}^{(j)} N(\mathbf{x}; \mathbf{m}_{k|k-1}^{(j)}, \mathbf{P}_{k|k-1}^{(j)}) \quad (6)$$

式中: $J_{k|k-1}$ 为目标强度函数高斯项个数; $\omega_{k|k-1}^{(j)}$ 为目标强度函数的高斯项权值; $\mathbf{m}_{k|k-1}^{(j)}$ 和 $\mathbf{P}_{k|k-1}^{(j)}$ 分别为目标强度函数高斯项的均值和方差; $N(\mathbf{x}; \mathbf{m}, \mathbf{P})$ 表示高斯分布。

更新步为

$$v_{k|k}(\mathbf{x}) = v_{k|k}^{\text{ND}}(\mathbf{x}) + \sum_{p \in \mathcal{Z}_k} \sum_{\mathbf{W} \in \mathcal{W}} v_{k|k}^{\text{D}}(\mathbf{x}, \mathbf{W}) \quad (7)$$

式中: $v_{k|k}^{\text{ND}}(\mathbf{x})$ 表示传感器未探测到的目标高斯形式强度函数, 可表示为

$$v_{k|k}^{\text{ND}}(\mathbf{x}) = \sum_{j=1}^{J_{k+1}} \omega_{k|k}^{(j)} N(\mathbf{x}; \mathbf{m}_{k|k}^{(j)}, \mathbf{P}_{k|k}^{(j)}) \quad (8)$$

其中

$$\omega_{k|k}^{(j)} = (1 - (1 - e^{-\gamma^{(i)}})) P_{\text{D}}^{(i)} \omega_{k|k-1}^{(j)} \quad (9)$$

$$\mathbf{m}_{k|k}^{(j)} = \mathbf{m}_{k|k-1}^{(j)} \quad (10)$$

$$\mathbf{P}_{k|k}^{(j)} = \mathbf{P}_{k|k-1}^{(j)} \quad (11)$$

式中: $\gamma^{(i)}$, $P_{\text{D}}^{(i)}$ 分别为 $\gamma(\mathbf{m}_{k|k-1}^{(i)})$, $P_{\text{D}}(\mathbf{m}_{k|k-1}^{(i)})$ 的缩写, 一般情况下假设扩展观测数均值为常数即 $\gamma^{(i)} = \gamma$, 目标检测概率也为常数, 即 $P_{\text{D}}^{(i)} = P_{\text{D}}$ 。

式(7)中 $v_{k|k}^{\text{D}}(\mathbf{x}, \mathbf{W})$ 表示传感器探测到的目标高斯形式强度函数, 可表示为

$$v_{k|k}^{\text{D}}(\mathbf{x}, \mathbf{W}) = \sum_{j=1}^{J_{k+1}} \omega_{k|k}^{(j)} N(\mathbf{x}; \mathbf{m}_{k|k}^{(j)}, \mathbf{P}_{k|k}^{(j)}) \quad (12)$$

其中

$$\omega_{k|k}^{(j)} = \omega_p \frac{\Gamma^{(i)} P_{\text{D}}^{(i)}}{d_{\text{W}}} \Phi_{\text{W}}^{(i)} \omega_{k|k-1}^{(j)} \quad (13)$$

$$\mathbf{m}_{k|k}^{(j)} = \mathbf{m}_{k|k-1}^{(j)} + \mathbf{K}_k^{(j)} (\mathbf{z}_{\text{W}} - \mathbf{H}_{\text{W}} \mathbf{m}_{k|k-1}^{(j)}) \quad (14)$$

$$\mathbf{P}_{k|k}^{(j)} = (\mathbf{I} - \mathbf{K}_k^{(j)} \mathbf{H}_{\text{W}}) \mathbf{P}_{k|k-1}^{(j)} \quad (15)$$

$$\omega_p = \frac{\prod_{\text{W} \in \rho} d_{\text{W}}}{\sum_{\rho' \subset \mathcal{Z}_k} \prod_{\text{W}' \in \rho'} d_{\text{W}'}} \quad (16)$$

$$d_{\text{W}} = \delta_{|\text{W}|, 1} + \sum_{i=1}^{J_{k+1}} \Gamma^{(i)} P_{\text{D}}^{(i)} \Phi_{\text{W}}^{(i)} \omega_{k|k-1}^{(i)} \quad (17)$$

$$\Gamma^{(i)} = e^{-\gamma^{(i)}} (\gamma^{(i)})^{|\text{W}|} \quad (18)$$

$$\Phi_{\text{W}}^{(i)} = \varphi_{\text{W}}^{(i)} \prod_{\mathbf{z}_k \in \text{W}} \frac{1}{\lambda_k c_k(\mathbf{z}_k)} \quad (19)$$

$$\varphi_{\text{W}}^{(i)} = N(\mathbf{z}_{\text{W}}; \mathbf{H}_{\text{W}} \mathbf{m}_{k|k-1}^{(j)}, \mathbf{H}_{\text{W}} \mathbf{P}_{k|k-1}^{(j)} \mathbf{H}_{\text{W}}^{\text{T}} + \mathbf{R}_{\text{W}}) \quad (20)$$

$$\mathbf{K}_k^{(j)} = \mathbf{P}_{k|k-1}^{(j)} \mathbf{H}_{\text{W}}^{\text{T}} (\mathbf{H}_{\text{W}} \mathbf{P}_{k|k-1}^{(j)} \mathbf{H}_{\text{W}}^{\text{T}} + \mathbf{R}_{\text{W}})^{-1} \quad (21)$$

$$\mathbf{z}_{\text{W}} = \begin{bmatrix} \mathbf{z}_1 \\ \vdots \\ \mathbf{z}_{|\text{W}|} \end{bmatrix} \quad (22)$$

$$\mathbf{H}_{\text{W}} = \left. \begin{bmatrix} \mathbf{H}_k \\ \vdots \\ \mathbf{H}_k \end{bmatrix} \right\} |\text{W}| \quad (23)$$

$$\mathbf{R}_{\text{W}} = \text{blkdiag}(\underbrace{\mathbf{R}_k, \mathbf{R}_k, \dots, \mathbf{R}_k}_{|\text{W}|}) \quad (24)$$

式中: 观测 \mathbf{z}_k 属于观测子集 W , 集合的势为 $|\text{W}|$; 每个周期观测中杂波观测数服从 Poisson 分布, 其均值为 λ_k , 一般情况下假设杂波观测数均值为常数, 即 $\lambda_k = \lambda$; $c_k(\mathbf{z}_k)$ 为观测空间中杂波的分布函数, 假设其服从均匀分布, 即 $c_k(\mathbf{z}_k) = 1/V$, V 为观测空间; \mathbf{H}_{W} , \mathbf{R}_{W} 分别表示扩维后的观测矩阵及观测噪声协方差矩阵; $\text{blkdiag}(\cdot)$ 表示块对角矩阵计算; $\delta_{|\text{W}|, 1}$ 为克罗内克 (Kronecker delta) 函数; ρ 表示观测集合划分的每一种可能; W' 表示每一个观测集合划分可能中的观测子集; ω_p 表示当前观测划分可能的权重。

2 观测数据聚类划分

2.1 目标数估计

每一个周期获得的观测包括目标的扩展观测和杂波观测, 每个目标的扩展观测数服从 γ 为均值的

Poisson 分布, 杂波观测数服从 λ 为均值的 Poisson 分布。由于多个独立 Poisson 分布的和仍然服从 Poisson 分布, 因此每一个周期获得的观测服从均值为 $\gamma N_{X,k} + \lambda$ 的 Poisson 分布, 即

$$p(M_k | (\gamma N_{X,k} + \lambda)) = \frac{(\gamma N_{X,k} + \lambda)^{M_k}}{M_k!} e^{-(\gamma N_{X,k} + \lambda)} \quad (25)$$

式中: $N_{X,k}$ 表示 k 时刻的目标数, M_k 表示 k 时刻的观测数。

每个目标的扩展观测数均值 γ 已知, 杂波观测数均值 λ 已知, 对于 k 时刻获得的 M_k 个观测可通过极大似然估计方法获得目标数 $N_{X,k}$ 的估计值, 即

$$\hat{N}_{X,k} = \operatorname{argmax} p(M_k | (\gamma N_{X,k} + \lambda)) \quad (26)$$

2.2 观测数据 K-means 聚类划分

K-means 聚类算法可以通过相似度准则将观测数据集合划分为设定的 n 个聚类子集, 并使得所获得的观测数据子集满足: 同一子集中的观测数据相似度较高, 而不同子集中的观测数据相似度较小。这里将通过式(26)获得的目标数估计值作为 K-means 聚类个数, 即取 $n = \hat{N}_{X,k}$, 将观测集合划分为 n 个观测数据子集。

由于每一个周期获得的观测中不仅包括目标观测还包括杂波观测, 但是杂波均匀分布在观测空间中, 离散分布的杂波观测会严重影响聚类划分的效果。如图 2(a) 所示, 由于杂波存在影响了 K-means 的相似度计算, 使得 A, B 两目标的观测被划分到同一观测子集中。为了解决这个问题, 本文首先利用椭球门限对进行更新计算的观测数据进行门限处理, 以减少观测数据中的杂波成分, 从而改善了观测数据集划分效果。如图 2(b) 所示, 对观测数据进行椭球门限处理后, 部分杂波被剔除掉, K-means 聚类能够正确划分观测子集。



(a) Partitioning before clutter removal (b) Partitioning after clutter removal

图 2 杂波对聚类划分影响的示意图

Fig. 2 Influence of clutter measurements on partitioning

在 k 时刻预测步计算后, 残差向量可以表示为

$$\mathbf{e}^{(ji)} = \mathbf{z}_k^{(i)} - \mathbf{H}_k \mathbf{m}_{k|k-1}^{(j)} \quad (27)$$

残差协方差矩阵可以表示为

$$\mathbf{S}_k^{(j)} = \mathbf{H}_k \mathbf{P}_k^{(j)} \mathbf{H}_k^T + \mathbf{R}_k \quad (28)$$

式中: \mathbf{H}_k 为测量矩阵; $\mathbf{P}_k^{(j)}$ 为第 j 个预测协方差矩阵; \mathbf{R}_k 为观测噪声矩阵。

利用椭球门限^[11]判别对观测数据进行门限处理, 以减少观测数据中的杂波成分, 即有

$$(\mathbf{e}^{(ji)})^T (\mathbf{S}_k^{(j)})^{-1} \mathbf{e}^{(ji)} \leq T_g \quad (29)$$

当观测空间的维数为 2 时, 椭球门限阈值表示为

$$T_g = -2 \ln(1 - P_g) \quad (30)$$

式中: P_g 为目标观测落入椭球门限的概率。

2.3 算法流程

本文提出的基于观测数据聚类划分的扩展目标递归跟踪算法流程归纳如下。

(1) 已知 $k-1$ 时刻的目标强度函数 $v_{k-1}(\mathbf{x})$;

(2) 利用式(6)预测目标强度函数得到 $v_{k|k-1}(\mathbf{x})$;

(3) 利用式(25,26)估计目标数,以此作为观测数据集合划分的子集个数,即 $n = \hat{N}_{X,k}$;

(4) 对 k 时刻的观测值进行门限处理,去除处于门限外的观测数据;并利用 K-means 聚类算法将门限内的观测数据集合 $\mathbf{Z}_{k,g}$ 划分为 $n = \hat{N}_{X,k}$ 个观测数据子集;

(5) 将门限内的观测数据 $\mathbf{Z}_{k,g}$ 划分的 $n = \hat{N}_{X,k}$ 个观测数据子集代入式(7~21)对目标的强度函数进行更新,获得 $v_{k|k}(\mathbf{x})$;

(6) 对目标强度函数 $v_{k|k}(\mathbf{x})$ 的高斯项进行裁剪合,具体方法详见参考文献[12]。

3 仿真试验

验证本文算法的实验场景为一个 $[-100, 100] \times [-100, 100]$ 的监视区域,4 个目标匀速直线运动(如图 3 所示)。传感器采样周期为 1 s,仿真获得 40 个采样周期数据,目标状态用向量 $[x, x', y, y']^T$ 表示,其中 (x, y) 表示目标的位置, (x', y') 表示目标的速度,观测获得目标的二维位置信息(即 $n_z = 2$),目标运动方程及观测方程满足线性高斯模型,目标存活概率设置为 $P_s = 0.99$,检测概率设置为 $P_D = 0.9$,杂波服从 Poisson 分布,强度设置为 $\lambda = 10$,杂波位置均匀分布在观测空间中。每个目标扩展观测数服从 $\gamma = 5$ 的 Poisson 分布。新生目标的概率假设密度函数为

$$\gamma_k(\mathbf{x}) = 0.1N(\mathbf{x}; \mathbf{m}_\gamma^{(1)}, \mathbf{P}_\gamma) + 0.1N(\mathbf{x}; \mathbf{m}_\gamma^{(2)}, \mathbf{P}_\gamma) + 0.1N(\mathbf{x}; \mathbf{m}_\gamma^{(3)}, \mathbf{P}_\gamma) + 0.1N(\mathbf{x}; \mathbf{m}_\gamma^{(4)}, \mathbf{P}_\gamma) \quad (31)$$

式中: $\mathbf{m}_\gamma^{(1)} = [-10, 0, 20, 0]^T$, $\mathbf{m}_\gamma^{(2)} = [20, 0, -20, 0]^T$, $\mathbf{m}_\gamma^{(3)} = [-40, 0, 20, 0]^T$, $\mathbf{m}_\gamma^{(4)} = [-20, 0, -20, 0]^T$, $\mathbf{P}_\gamma = [5, 1, 5, 1]^T$ 。处理观测数据的椭圆门限参数 $P_g = 0.9$ 。高斯项修剪阈值设置为 $T = 10^{-5}$,高斯项最大个数设置为 $J_{\max} = 200$,合并门限设置为 $U = 4$ 。

对上述数据及相同参数分别进行本文聚类划分方法的扩展目标跟踪及距离门限划分的扩展目标跟踪。利用本文聚类方法划分观测数据后对扩展目标进行跟踪得到的状态估计结果如图 4 所示。距离门限划分方法与本文聚类划分方法的观测集合划分数比较如图 5 所示。由于距离门限阈值范围的选取依赖于实验数据所总结的经验,为了保证划分的观测集合中包含正确的观测划分,则需要选取较大的距离门限阈值范围(实验使用文献[10]中参数 $P_g \in (0.3, 0.8)$),这不仅导致产生出较多的错误观测集合划分,增大了后续扩展目标状态估计误差,也使得算法计算量大大增加,而本文方法则能够较为准确地估计真实目标数,以此作为观测划分的依据,利用椭圆门限消除了部分杂波,不仅减少了错误的观测集合划分,同时也降低了计算量。进行 100 次 Monte Carlo 实验,目标数估计结果比较及 OSPA 距离^[12]比较(本文实验误差调节因子设置为 $c = 20$)分别如图 6,7 所示。图 6 中,本文聚类划分方法的扩展目标跟踪方法较利用距离门限划分的扩展目标跟踪方法对目标数估计更加准确。图 7 中,利用本文方法进行观测数据划分后的目标跟踪 OSPA 更小,说明本文方法获得了较距离门限划分方法更为准确的扩展目标观测集合划分。在相同运行环境下,本文聚类划分方法为 1.58 s,距离门限划分方法为 12.17 s,由于本文方法利用 K-means 方法进行观测数据集合划分,其计算复杂度为 $O(M_k \cdot n \cdot k)$,与观测数 M_k 成正比,其中 n 为聚类数, k 为迭代次数;而距离门限划分进行观测数据集合划分,其计算复杂度为 $O(M_k^4)$ ^[13],观测数 M_k 的 4 次方成正比,可以看出本文方法计算复杂度远小于距离门限划分方法。

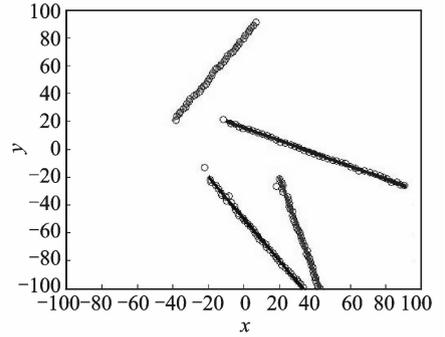


图 3 目标运动轨迹及观测值

Fig. 3 True trajectories and measurements

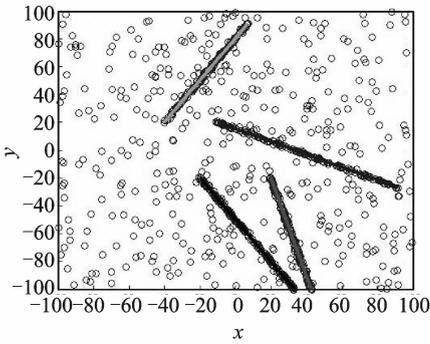


图4 本文方法的状态估计结果
Fig. 4 Estimates of proposed algorithm

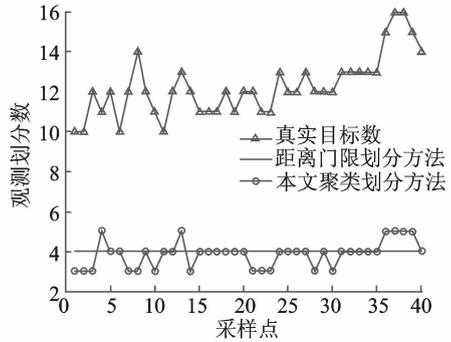


图5 观测划分分数比较
Fig. 5 Comparison of partition number

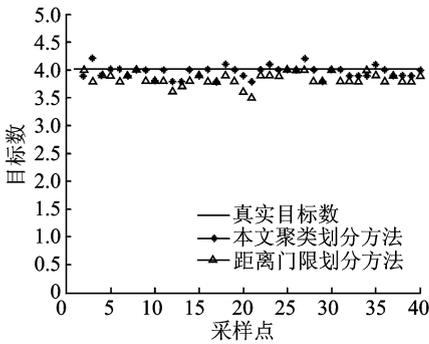


图6 目标数估计结果比较
Fig. 6 Comparison of target number estimation

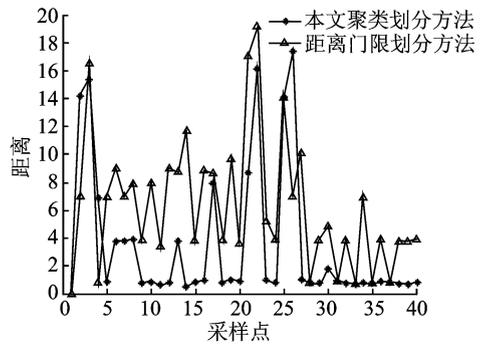


图7 OSPA 距离比较
Fig. 7 Comparison of OSPA distance

4 结束语

本文提出了一种基于观测数据聚类划分的扩展目标跟踪算法,该方法首先利用椭圆门限对观测数据进行处理以降低杂波观测对聚类划分的影响,然后利用极大似然方法获得目标数估计,并以此作为聚类数利用 K-means 对观测数据进行划分。实验结果表明,该方法在正确划分观测集合的基础上,计算复杂度有较大降低,同时在多目标跟踪效果方面优于观测数据距离门限划分的假设概率密度滤波扩展目标跟踪算法。

参考文献:

- [1] Bar-Shalom Y, Li X R. Multitarget-multisensor tracking: Principles and techniques [M]. Storrs, CT: YBS Publishing, 1995.
- [2] Bar-Shalom Y, Fortmann T E. Tracking and data association [M]. San Diego, CA: Academic Press, 1988, 1-6.
- [3] 李鹏飞, 黄建军, 黄敬雄, 等. 一种模糊 Kalman 滤波机动目标跟踪的新算法 [J]. 数据采集与处理, 2009, (4):483-486.
Li Pengfei, Huang Jianjun, Huang Jingxiong, et al. Fuzzy Kalman filter for maneuvering target tracking [J]. Journal of Data Acquisition and Processing, 2009, (4):483-486.
- [4] Mahler R. Random sets: Unification and computation for information fusion—A retrospective assessment [C] // 7th International Conference on Information Fusion. Stockholm, Sweden: IEEE Computer Society Press, 2004:1-20.
- [5] Mahler R. Multi-target Bayes filtering via first-order multi-target moments [J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4):1152-1178.

- [6] 章涛, 吴仁彪. 自适应门限 GM-CPHD 多目标跟踪算法[J]. 数据采集与处理, 2014, 29(4):549-554.
Zhang Tao, Wu Renbiao. Adaptive gating GM-CPHD for multitarget tracking [J]. Journal of Data Acquisition and Processing, 2014, 29(4):549-554.
- [7] 连峰, 韩崇昭, 刘伟峰, 等. 高斯混合扩展目标概率假设密度滤波器的收敛性分析[J]. 自动化学报, 2012, 38(8):1343-1352.
Lian Feng, Han Chongzhao, Liu Weifeng, et al. Convergence analysis of the Gaussian mixture extended-target probability hypothesis density filter [J]. Acta Automatica Sinica, 2012, 38(8):1343-1352.
- [8] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091-4104.
- [9] Mahler R. PHD Filter for nonstandard targets, I: Extended targets[C] // 12th International Conference on Information Fusion. Seattle, WA, USA;IEEE Computer Society Press, 2009: 915-921.
- [10] Granstrom K, Orgune U. Extended target tracking using a Gaussian-mixture PHD filter [J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(4): 3268-3286.
- [11] Blackman S S, Popoli R. Design and analysis of modern tracking systems [M]. Norwood, MA: Artech House, 1999.
- [12] 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.
- [13] Granström K, Orguner U. Implementation of the GIW-PHD filter [M]. Stockholm, Sweden: Linköping University Electronic Press, 2013.

作者简介:



章涛(1980-),男,博士,研究方向:目标跟踪、雷达信号处理, E-mail: t-zhang@cauc.edu.cn。



来燃(1990-),男,硕士研究生,研究方向:多目标跟踪, E-mail: rlai@cauc.edu.cn。



吴仁彪(1966-),男,博士,教授,研究方向:自适应信号处理和阵列信号处理在雷达、通信和导航中的应用, E-mail: rbwu@cauc.edu.cn。

