

基于 CFSFDP 的箱粒子 CPHD 扩展目标跟踪^①



王海, 杨小军

(长安大学 信息工程学院, 西安 710064)
通讯作者: 王海, E-mail: 1428077128@qq.com

摘要: 针对当前扩展目标跟踪量测划分方法中, 距离划分存在划分数过多、计算复杂度高的问题, 本文将密度峰值快速聚类算法 CFSFDP (Clustering by Fast Search and Find of Density Peaks) 与箱粒子势概率假设滤波器 (Box Cardinalized Probability Hypothesis Density filter, Box-CPHD) 相结合, 提出基于 CFSFDP 的箱粒子 CPHD 扩展目标滤波算法. 该算法采用 CFSFDP 进行量测划分, 基于量测信息密度的不同可以有效划分区间量测, 并剔除杂波量测, 然后采用箱粒子 CPHD 进行预测更新和目标状态估计. 仿真实验表明与经典的距离划分方法相比, 在箱粒子 CPHD 扩展目标算法流程中采用 CFSFDP 进行量测预处理, CFSFDP 在达到同等效果的前提下, 运行时间明显减少; 在剔除杂波之后的高杂波环境下, 杂波的变化只影响距离划分的运算时间而不再影响 CFSFDP 划分, 采用 CFSFDP 处理量测信息可以有效提高运行效率和算法实时性, 剔除杂波之后在一定程度上提高了目标位置估计精度.
关键词: 扩展目标跟踪; 量测划分; CFSFDP; 势概率假设密度滤波; 箱粒子滤波; 计算效率

引用格式: 王海, 杨小军. 基于 CFSFDP 的箱粒子 CPHD 扩展目标跟踪. 计算机系统应用, 2021, 30(10): 210-217. <http://www.c-s-a.org.cn/1003-3254/8109.html>

Box-CPHD Extended Target Tracking Based on CFSFDP

WANG Hai, YANG Xiao-Jun

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

Abstract: Regarding the problems of excessive divisions and high computational complexity in the current measurement division method of extended target tracking, this study combines the Clustering by Fast Search and Find of Density Peaks (CFSFDP) with the Box-Cardinalized Probability Hypothesis Density (Box-CPHD) filter to propose a Box-CPHD extended target filtering algorithm based on CFSFDP. The algorithm applies CFSFDP to measurement division and it can clearly divide the interval measurement and remove the clutter measurement with the difference in the measurement information density. Then, the Box-CPHD filter is used for prediction update and target state estimation. The simulation experiment shows that in comparison with the classic distance division method, CFSFDP is employed in the measurement preprocessing of the Box-CPHD extended target algorithm. CFSFDP significantly reduces the running time while achieving the same effect, and in the high-clutter environment after clutter removal, the change in clutter only affects the calculation time of distance division but no longer affects the CFSFDP division. The processing of measurement information with CFSFDP can greatly improve the operating efficiency and the real-time performance of the algorithm. After clutter removal, the accuracy of target position estimation is improved to a certain extent.

Key words: extended target tracking; measurement division; Clustering by Fast Search and Find of Density Peaks (CFSFDP); Cardinalized Probability Hypothesis Density (CPHD) filtering; box particle filtering; computational efficiency

① 基金项目: 国家自然科学基金 (61473047)

Foundation item: National Natural Science Foundation of China (61473047)

收稿时间: 2020-12-26; 修改时间: 2021-01-25; 采用时间: 2021-02-03

传统多目标跟踪算法是基于“点目标”假设的^[1],如果目标被检测到,最多只占据传感器的一个分辨率单元.随着传感器分辨率的提高和对目标形状估计等要求的提出,单个目标占据多个分辨率单元的现象不可避免,跟踪技术的“点目标”假设难以满足现实需要,对可能占用多个传感器单元的扩展目标跟踪问题成为研究的重点.

在传统的关联思想下,当目标数增加时,所有目标的量测信息会大幅增长,必须枚举度量集合的所有可能分区,然后以所有可能的方式分配分区单元来进行对象估计,这势必会极大地增加运算复杂度.量测集划分是多扩展目标跟踪滤波中解决的关键问题,在多扩展目标跟踪中,单目标或单量测单元对应多个量测,传感器无法建立量测集与目标的对应关系,在Mahler的随机集框架下考虑扩展目标跟踪问题^[2]成为一种有效的解决方案,针对扩展目标的量测划分问题,在文献[3]中提出了距离划分的方法,该算法利用距离阈值来限定给出对应距离门限的所有划分结果集,在目标量测很多时计算效率低;在文献[4]中提出K-means划分方法,而该方法需要设定聚类K值,此先验信息不好设定;在文献[5]中提出将均值漂移划分(mean shift)方法用于高斯混合概率假设滤波器(Gaussian Mixture Probability Hypothesis Density, GM-PHD),有效降低了运算时间;在此基础上,文献[6]利用mean shift和图结构来处理交叉时刻目标数漏估问题,在文献[7]中提出了快速模糊自适应谐振理论(Adaptive Resonance Theory, ART)划分方法,并将其应用于箱粒子PHD^[8];扩展目标CPHD滤波^[9]的提出有效提高了PHD在低检测率高杂波等条件下的目标估计精度;在文献[10]中提出了基于区间箱粒子形式的扩展目标CPHD滤波,文献[11]在此基础上通过给箱粒子加标签的方式来区分目标航迹.

密度峰值快速聚类算法CFSFDP(Clustering by Fast Search and Find of Density Peaks)^[12]于2014年由Alex Rodriguez和Alessandro Laio在Science杂志上提出,通过多种实测数据验证其准确检测非球面聚类和快速找到正确聚类数量的良好性能,而后该算法被广泛应用于各类数据分析中^[13-15].

针对扩展目标量测集划分的问题,本文提出将密度峰值快速聚类算法CFSFDP用于目标和杂波量测的划分处理,利用箱粒子CPHD滤波器进行扩展目标的预测更新,在降低计算复杂度的前提下,该算法可以有效识别聚类中心和离群点,划分之后直接剔除杂波量

测,进一步降低运算时间,提高了算法的实时性和运算效率,在一定程度上也提高了目标估计精度.

1 密度峰值快速聚类算法

在机器学习中,把未知标记信息的训练样本称为无监督学习,在无监督学习中利用聚类算法来寻找这些数据的内在联系,根据不同的规则将数据集划分为若干不相交的子集,达到数据处理的效果.

由于扩展目标处理的是多量测对应单目标的问题,在目标数增加、量测率增大、密集杂波等环境下,过多的量测势必造成计算负担,利用有效的划分方法将属于同一目标的量测聚到一起,将大大减少计算复杂度,提高运算效率.根据文献[16],采用泊松分布来表示扩展目标量测,检测点在目标周围呈空间分布,而实际情况中的杂波量测又类似服从空间区域内的均匀分布,目标量测和杂波在密度上是可以区分的,故而考虑将基于密度的新型聚类算法CFSFDP用于扩展目标量测集划分.

CFSFDP聚类算法是基于局部密度和距离的聚类算法.该算法具有能够发现任意形状类簇、逻辑简单易于理解、超参数少并且可以高效划分数据的优点,克服了之前聚类算法只能识别和发现基于距离的圆形簇的缺陷,可以得到不同形状的聚类簇,而且对噪声不敏感,并高效进行非中心样本点分配.

CFSFDP聚类算法基于以下两个假设来识别和查找聚类中心:聚类中心周围都是密度比其低的点,同时这些点距离该聚类中心的距离相比于其他聚类中心来说是最近的.基于这两个核心假设来识别聚类中心和离群点.对于每一个数据点,要计算两个量:点的局部密度和该点到具有更高局部密度的点的距离,而这两个值都取决于数据点间的距离.

根据文献[12],CFSFDP简要算法流程如下:

首先计算每一个数据点的局部密度,计算该点到具有更高局部密度点的距离;将同时具有较大局部密度和距离的数据点判定为聚类中心点,有较小局部密度和较大距离的数据点判定为离群点;然后对非聚类中心的数据点进行归类;最后利用边界区域划分核心点和离群点.

2 基于CFSFDP的扩展箱粒子CPHD算法

2.1 扩展目标动态模型

基于随机有限集理论,首先对扩展目标状态方程

和量测方程建模,使用两个随机有限集 X_k 和 Z_k 来分别表示 k 时刻的目标状态和量测信息.

$$X_k = \{x_k^1, x_k^2, \dots, x_k^{N_x}\} \quad (1)$$

$$Z_k = \{z_k^1, z_k^2, \dots, z_k^{N_z}\} \quad (2)$$

其中, N_x 和 N_z 表示目标数量和量测数量,假设多个扩展目标运动状态独立且是线性运动,则目标状态方程为:

$$x_k = F_{k-1}x_{k-1} + w_{k-1} \quad (3)$$

其中, x_k 表示扩展目标在 k 时刻的运动状态, F_k 为对应时刻的状态转移矩阵, w_k 为过程噪声,本文仿真取加性噪声.

多个扩展目标的量测方程为:

$$z_k = H_k x_k + v_k \quad (4)$$

其中, z_k 为 k 时刻量测值, H_k 为对应时刻的量测矩阵, v_k 为量测噪声.过程噪声和量测噪声均为均值为零的高斯白噪声.

2.2 距离划分

距离划分基于同一目标产生的多个测量值可能彼此接近,而不同目标产生的多个测量值可能彼此很远的思想,该方法利用距离阈值测度标准,将扩展目标量测信息进行聚类,利用两个最值阈值来限定所有可能的分区结果.

首先给定 k 时刻的量测集 $Z_k = \{z_k^{(i)}\}_{i=1}^{N_z}$ 和一组距离阈值 $\{d_i\}_{i=1}^{N_d}, d_i < d_{i+1}$.

k 时刻两个目标源量测之间的马氏距离为:

$$\begin{aligned} \Delta_{ij} &\stackrel{\Delta}{=} d(z_k^{(i)}, z_k^{(j)}) \\ &= \sqrt{(z_k^{(i)} - z_k^{(j)})^T R^{-1} (z_k^{(i)} - z_k^{(j)})}, 1 \leq i \neq j \leq N_z \end{aligned} \quad (5)$$

其中, R 为量测协方差, Δ_{ij} 服从自由度等于量测向量维度的 χ^2 分布.给定概率 P_G 条件下距离阈值用逆 χ^2 分布表示为:

$$\delta_{P_G} = \text{invchi2}(P_G) \quad (6)$$

进行分区时,要求两个目标源量测之间的马氏距离 Δ_{ij} 不超过距离阈值 d_i ,随着 d_i 的增大,每个分区包含更少的单元格,而每个单元格包含更多的量测信息.

距离阈值 $\{d_i\}_{i=1}^{N_d}, d_i < d_{i+1}$ 来自集合:

$$D \stackrel{\Delta}{=} \{0\} \cup \{\Delta_{ij} | 1 \leq i < j \leq N_z\} \quad (7)$$

如果将集合 D 中的所有元素都作为距离阈值,会得到 $N_d = N_z(N_z - 1)/2 + 1$ 种划分结果.去掉一些可能相同的分区以保证划分结果的唯一性,唯一分区中,当 $d_i = 0$

时相当于没有划分,共 N_z 个子集;当 $d_i = \infty$ 时则只有一个子集.采用两个最值阈值 δ_{P_L} 和 δ_{P_U} 限定距离阈值 d_i ,得到满足 $\delta_{P_L} < d_i < \delta_{P_U}$ 条件的子集,即为最终的量测划分分数.文献[3]中设置最小距离阈值概率 $P_L = 0.3$,最大距离阈值概率 $P_U = 0.8$.

2.3 CFSFDP 量测划分

基于CFSFDP算法的主要思想和核心计算流程,该算法利用局部密度和相对距离识别聚类中心和离群点,由此区分不同密度的聚类簇.

将CFSFDP算法在数据聚类方面的优势用于扩展目标跟踪的量测集划分.与传统基于距离划分的量测划分方法相比,由于CFSFDP聚类算法可以给出目标量测集的一种近似最优划分结果,而距离划分则给出所有可能的划分结果,所以可以有效提高算法实时性;划分之后根据标识集区分目标聚类簇和离散杂波点,利用此性质可以有效剔除杂波量测.

下面具体给出CFSFDP聚类算法用于扩展目标跟踪时进行量测集划分的算法流程.

算法 1. CFSFDP 量测划分

输入: 二维 N 个量测数据集 X

输出: 标识集 $\{h_i\}_{i=1}^N$

步骤 1. 初始化及预处理

1.1. 给定用于确定截断距离 d_c 的参数 $t \in (0, 1)$

1.2. 计算各个点之间的距离 d_{ij}

1.3. 确定截断距离 d_c

计算可得共有 $M = 0.5N(N-1)$ 个 d_{ij} 升序排列,取 $d_c = d_{f(M)}$, $f(\cdot)$ 表示四舍五入

1.4. 计算局部密度 $\{\rho_i\}_{i=1}^N$ 和其降序序列 $\{q_i\}_{i=1}^N$

$$\rho_i = \sum_{j \in S \setminus \{i\}} e^{-\left(\frac{d_{ij}}{d_c}\right)^2};$$

1.5. 计算距离 $\{\delta_i\}_{i=1}^N$ 和非聚类中心数据点属性编号 $\{n_i\}_{i=1}^N$

$n_i = 0;$

for $i = 2, 3, \dots, N$

$\delta_{q_i} = d_{\max};$

for $j = 1, 2, \dots, i-1$

if $\text{dist}(X_{q_i}, X_{q_j}) < \delta_{q_i}$

$\delta_{q_i} = \text{dist}(X_{q_i}, X_{q_j});$

$n_{q_i} = q_j;$

end if

end for

end for

$\delta_{q_1} = \max_{j \geq 2} \{\delta_j\};$

步骤 2. 确定聚类中心 $\{m_j\}_{j=1}^c$,并初始化数据点归类属性标记 $\{c_i\}_{i=1}^N$

$$c_i = \begin{cases} c, & \text{c-th cluster;} \\ -1, & \text{otherwise;} \end{cases}$$

步骤 3. 对非聚类中心数据点进行归类

```

for i=1,2,...,N
  if  $c_{q_i} = -1$ 
     $c_{q_i} = c_{n_{q_i}}$ ;
  end if
end for
步骤4. 将每个类别数据点分为核心点和离群点
4.1. 初始化标识 $h_i = 0$ 
4.2. 为每个类别生成平均局部密度上界 $\{\rho_i^b\}_{i=1}^{n_c}$ 
 $\rho_i^b = 0, i=1,2,\dots,n_c$ ;
for i=1,2,...,N-1
  for j=i+1,i+2,...,N
    if  $c_i \neq c_j$ 且 $dist(x_i, x_j) < d_c$ 
       $\bar{\rho} = 0.5(\rho_i + \rho_j)$ ;
      if  $(\bar{\rho} > \rho_{c_i}^b)$   $\rho_{c_i}^b = \bar{\rho}$ ;
      if  $(\bar{\rho} > \rho_{c_j}^b)$   $\rho_{c_j}^b = \bar{\rho}$ ;
    end if
  end for
end for
4.3. 标识离群点
for i=1,2,...,N
  if  $\rho_i < \rho_{c_i}^b$ 
     $h_i = 1$ ;
  end if
end for

```

算法结束后输出标识集 $\{h_i\}_{i=1}^N$, $h_i = 0$ 表示局部密度较大的核心区域, 记为目标索引 IDX ; $h_i = 1$ 表示离群点, 记为噪声索引 $isnoise$. 经过 CFSFDP 算法对量测集划分, 得到目标量测和杂波量测的不同索引标识, 利用聚类后的目标索引值 IDX 读取量测数据集 X , 可以得到划分之后的聚类结果, 在 IDX 中将聚类后得到的噪声索引值去掉, 则可以直接去除噪声, 达到去除区间量测中杂波量测的目的.

2.4 基于 CFSFDP 的扩展箱粒子 CPHD 算法

由于 CFSFDP 算法在聚类方面的良好特性, 将该算法用于量测集划分, 并加入扩展目标箱粒子 CPHD 算法^[9-11]的框架中, 下面给出基于 CFSFDP 量测划分的箱粒子扩展 CPHD 完整算法流程.

2.4.1 初始化生成箱粒子

假设 $k-2$ 时刻重采样后存活的持续箱粒子 $\{\{x_{k-1|k-1}^{per}, w_{k-1|k-1}^{per}\}_{n_2=1}^{N_p}\}$ 共 N_p 个持续箱粒子, 根据 $k-1$ 时刻的量测集 Z_{k-1} 产生一组新生箱粒子 $\{\{x_{k-1|k-1}^{bir}, w_{k-1|k-1}^{bir}\}_{n_1=1}^{N_b}\}$ 共 N_b 个新生箱粒子. 持续箱粒子和新生箱粒子合并为 $k-1$ 时刻的箱粒子集 $\{\{x_{k-1|k-1}^{(l)}, w_{k-1|k-1}^{(l)}\}_{l=1}^{N'}\}$, 其中, N' 为总箱粒子数, $N' = N_b + N_p$. 后验势分布 $\rho_{k-1}(n)$.

2.4.2 量测划分

由于在多扩展目标跟踪问题中, 存在单目标或单

量测单元对应多个量测信息的情况, 传感器无法建立量测集与目标的对应关系, 所以量测集划分是多扩展目标跟踪中需要解决的关键问题.

本文用 CFSFDP 算法对每步采样得到的量测信息进行预处理, 具体方法详见 2.3 节. 在预处理之后, 划分出目标量测集和杂波量测, 利用包含函数 $[f]$ 将划分后的目标量测 W_λ 包含成区间箱的形式, 表示为 $[z_m] = \{[f]W_\lambda\}$, 后续则使用箱量测 $[z_m]$ 来进行更新.

2.4.3 预测

目标的状态和权值预测为:

$$x_{k|k-1}^{(l)} = [f_k] \cdot x_{k-1|k-1}^{(l)} + [w_{k-1}] \quad (8)$$

$$w_{k|k-1}^{(l)} = p_s \left(x_{k-1|k-1}^{(l)} \right) \cdot w_{k-1|k-1}^{(l)} \quad (9)$$

其中, p_s 为存活概率.

利用马尔科夫转移矩阵 M 预测目标数的高阶势分布为:

$$\rho_{k|k-1}(n) = \sum_{n'=0}^{\infty} \rho_{k-1}(n') M(n, n') \quad (10)$$

$$M(n, n') = \sum_{l=0}^{\min\{n, n'\}} \rho_{\text{bir}}(n-l) \binom{n'}{l} p_s^l (1-p_s)^{n'-l} \quad (11)$$

其中, 利用新生势分布 $\rho_{\text{bir}}(n)$ 和存活概率 p_s 得到马尔科夫转移矩阵 M 进一步得到目标的预测势分布.

2.4.4 更新

利用划分后 k 时刻的量测 $\{[z_m]\}_{m=1}^{M_k}$ 和预测箱粒子集合 $\{w_{k|k-1}^{(l)}, [x_{k|k-1}^{(l)}]\}_{l=1}^{N'}$ 得到似然函数:

$$g_{k|k}([z_m] | [x_{k|k-1}^{(l)}]) = \frac{[h_{cp1}([x_{k|k-1}^{(l)}], [z_m])]}{[[x_{k|k-1}^{(l)}]]} \quad (12)$$

CPHD 同时更新检测部分 D 和漏检部分 $\neg D$, 则权值更新如下:

$$w_k^l = (1 - p_D) \frac{g_{k|k}([Z_k] | \neg D)}{g_{k|k}([Z_k])} w_{k|k-1}^l + p_D \frac{g_{k|k}([Z_k] | D)}{g_{k|k}([Z_k])} w_{k|k-1}^l \quad (13)$$

势分布也随之更新:

$$\rho_k(n) = \frac{g_{k|k}([Z_k] | n)}{g_{k|k}([Z_k])} \rho_{k|k-1}(n) \quad (14)$$

具体来说,

$$L([Z_k] | \neg D) = \frac{1}{n_{k|k-1}} \sum_{j=0}^{m_k} \alpha_k^{j+1} \beta_k^j \sigma_j(\{L_k^1, \dots, L_k^{m_k}\}) \quad (15)$$

$$L([Z_k]|D) = \sum_{j=1}^{m_k} l([z_m^s]|[x])L([Z_k]|\alpha_k^j = s) \quad (16)$$

$$L([Z_k]|\alpha_k^j = s) = \frac{1}{n_{k|k-1}} \sum_{j=1}^{m_k} \alpha_k^j \beta_k^j \sigma_{j-1}(\{L_k^1, \dots, L_k^{m_k}\} / \{L_k^s\}) \quad (17)$$

$$L([Z_k]) = \sum_{j=0}^{m_k} \alpha_k^j \beta_k^j \sigma_j(\{L_k^1, \dots, L_k^{m_k}\}) \quad (18)$$

$$L([Z_k]|n) = \sum_{j=0}^{\min(m,n)} \beta_k^j \frac{n!}{(n-j)!} (1-p_D)^{n-j} \sigma_j(\{L_k^1, \dots, L_k^{m_k}\}) \quad (19)$$

$$L_k^s = \frac{1}{n_{k|k-1}} \int p_D w_{k|k-1}([x]) l_k([z_m^s]|[x]) d[x] \quad (20)$$

$$\alpha_k^j \equiv \sum_{n=j}^{\infty} \frac{n!}{(n-j)!} \rho_{k|k-1}(n) (1-p_D)^{n-j} \quad (21)$$

$$\beta_k^j \equiv p_c (m-j) \frac{(m_k-j)!}{m_k!} \lambda^{-j} \quad (22)$$

$$\sigma_j(\{L_k^1, \dots, L_k^{m_k}\}) = \begin{cases} \sum_{j=1}^{m_k} L_k^1, \dots, L_k^{m_k}, j \neq 0 \\ 1, j = 0 \end{cases} \quad (23)$$

其中, p_c 表示虚警的存在概率, $[h_{cp}]$ 表示量测函数的包含函数, p_D 表示检测概率, $[g_{k|k}(\cdot)]$ 表示箱粒子量测似然. 因为量测是区间的形式, 所以似然函数就不能采用传统的目标集中式融合的方法, 此处的似然函数通过量测箱粒子和预测箱粒子的重叠面积比, 再采用收缩算法得到.

2.4.5 数目估计

对更新后的势分布 $\rho_k(n)$ 进行数目估计, 可以采用 EAP 和 MAP 两种方法, 由于 MAP 在低信噪比环境下更稳定^[17], 本文采用 MAP 进行数目估计:

$$\hat{N}_k = \arg \max \rho_k(n) \quad (24)$$

2.4.6 重采样

为了实现粒子的“优胜劣汰”, 对已经更新的粒子集 $\{w_k^{(l)}/\hat{N}_k, [x_{k|k-1}^{(l)}]\}_{l=1}^{\hat{N}_k}$ 采用分层统计的“随机重采样”方法, 可以得到采样后的新粒子集合为 $\{w_k'^{(l)}, [x_{k|k-1}^{(l)}]\}_{l=1}^{N'}$, $w_k'^l = 1/N'$. 其中, \hat{N}_k 为估计的目标数.

2.4.7 状态提取

利用 $mid([\cdot])$ 函数取中心的方式, 将采样后的箱粒

子集合 $\{w_k'^{(l)}, [x_{k|k-1}^{(l)}]\}_{l=1}^{N'}$ 取区间中心, 得到点粒子集:

$$x_{k|k-1}^{(l)} = mid\left([x_{k|k-1}^{(l)}]_{l=1}^{N'}\right) \quad (25)$$

箱粒子点化后利用 K-means 聚类进行多目标状态提取, 并将聚类状态均值作为每一时刻的状态估计值.

3 仿真实验

3.1 实验参数设置

实验仿真平台使用 Win10 64 位操作系统, Intel(R) Core(TM) i5-4258U CPU @ 2.40 GHz 2.10 GHz 处理器, 运行软件为 Matlab R2012a. 仿真实验场景构建为 $[-200 \text{ m}, 400 \text{ m}] \times [-800 \text{ m}, 600 \text{ m}]$ 的二维监控平面, 4 个扩展目标的初始状态及生死时刻如表 1 所示.

表 1 目标初始状态及生死时刻

目标数	初始状态	出生时间 (s)	死亡时间 (s)
1	(-160 m, 20 m/s, 220 m, -12 m/s)	1	25
2	(-100 m, 15 m/s, -400 m, 10 m/s)	5	30
3	(-50 m, 15 m/s, -600 m, 10 m/s)	10	35
4	(-150 m, 10 m/s, -205 m, 5 m/s)	15	40

根据式 (3) 采用文献 [18] 中近匀速状态方程为:

$$[x_k] = F_{k-1} \cdot [x_{k-1}] + G_{k-1} \cdot [w_{k-1}] \quad (26)$$

其中,

$$G = \begin{bmatrix} T^2/2 & 0 \\ 0 & T^2/2 \\ T & 0 \\ 0 & T \end{bmatrix}$$

箱粒子下目标状态为:

$$[x_k] = ([x], [\dot{x}], [y], [\dot{y}])^T = ([\underline{x}, \bar{x}], [\underline{\dot{x}}, \bar{\dot{x}}], [\underline{y}, \bar{y}], [\underline{\dot{y}}, \bar{\dot{y}}])^T \quad (27)$$

其中, $([x], [y])$ 表示目标的位置信息, $([\dot{x}], [\dot{y}])$ 表示目标在 x 方向和 y 方向上的速度信息, $([\cdot, \bar{\cdot}])$ 表示区间上下界, 过程噪声标准差 $\sigma_\omega = 0.5 \text{ m/s}^2$.

根据式 (4) 取量测方程为:

$$z_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} x_k + \begin{bmatrix} R_{1,k} \\ R_{2,k} \end{bmatrix} \quad (28)$$

量测噪声标准差 $\sigma_x = \sigma_y = 5 \text{ m}$.

设置采样间隔 $T=1 \text{ s}$, 每步目标量测泊松率为 20, 监控场景内均匀杂波的泊松平均率 $\lambda = 10$, 检测时长为 40 s, 目标存活概率 $p_s = 0.99$, 目标检测概率 $p_D = 0.98$, 每个时刻产生新生箱粒子 1 个, 存活箱粒子数 8 个. 箱

粒子扩展范围为 26 m. 取最小距离阈值 $P_L = 0.3$, 最大距离阈值 $P_U = 0.8$.

3.2 实验结果分析

在单次蒙特卡洛运行下, 图 1 为 4 个扩展目标的运动轨迹和杂波的区间量测图, 每步采样时刻目标有多个量测. 图 2 为最大距离划分区间量测图, 图 3 为 CFSFDP 聚类划分区间量测图, 根据文献 [9] 的理论利用包含函数将聚类后属于同一个目标的量测点利用区间的箱形式包含起来. 图 4 为利用 CFSFDP 去除杂波量测后的目标量测图, 可以看到每个采样时间内只有目标量测, 后续则利用该量测进行滤波.




图 1 目标轨迹及量测图

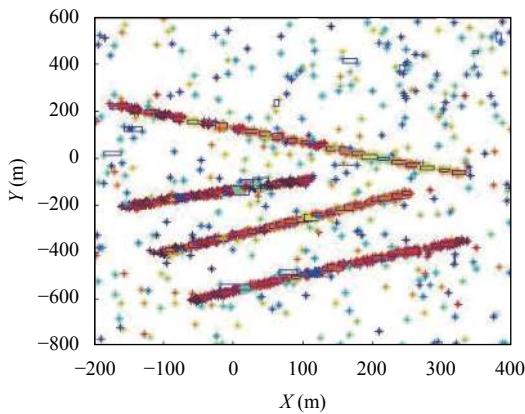


图 2 最大距离划分量测图

在 100 次蒙特卡洛运行下, 图 5 显示了每个采样时刻的划分数, 由于距离划分采用距离阈值门限给出所有可能的划分结果, 在目标数增多时量测划分数急剧增加, CFSFDP 则利用局部密度和相对距离划分目标量测和杂波量测, 每次划分只有一种近似最优结

果, 划分出目标和杂波并记录个数. 图 6 为两种算法的平均运行时间, 可以看出距离划分目标数增加时, 随着划分数增加, 运算时间增加, CFSFDP 算法基于一种划分结果, 运行效率较高.




图 3 CFSFDP 划分量测图




图 4 去除杂波后 CFSFDP 划分量测图

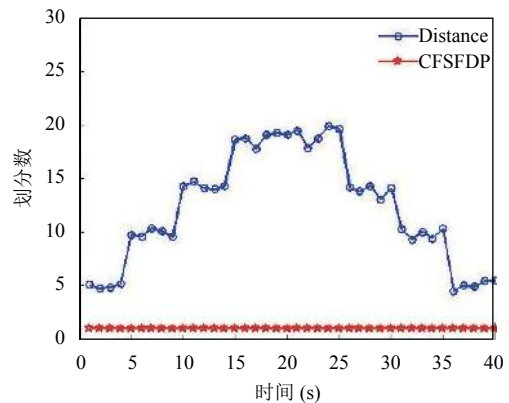


图 5 划分数比较

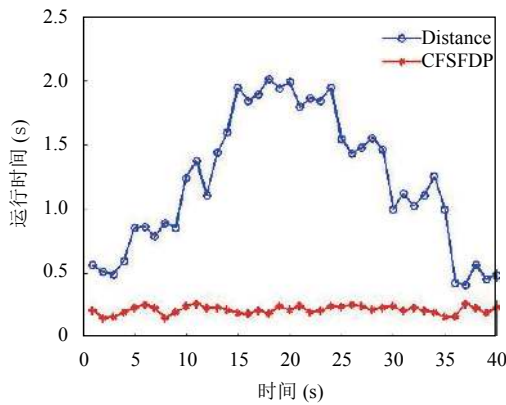


图6 运行时间比较

本文采用最优子模型分配距离 (Optimal SubPattern Assignment, OSPA)^[19] 对算法的估计精度进行评估。c 为目标数目估计惩罚参数, c 值越大, 在 OSPA 距离中目标数目估计误差所占比重越大, p 为阶数, 也称目标位置惩罚参数, p 值越大, 在 OSPA 距离中对目标位置估计误差越敏感, 位置估计误差所占比重越大。本文实验中 $p = 2, c = 70$ 。

图7为两种划分方法 OSPA 距离比较, 可以看出在目标新生时由于延时的存在, 会有较大的 OSPA 距离, 其余时刻基本无差别。从图8中可以看到在新目标出生时有 1 s 的延时, 是因为提取目标状态时是基于上一秒的目标信息, 延时之后可以进行有效估计。使用两种量测划分方法后箱粒子 CPHD 滤波器都可以准确估计目标数变化和稳定跟踪。

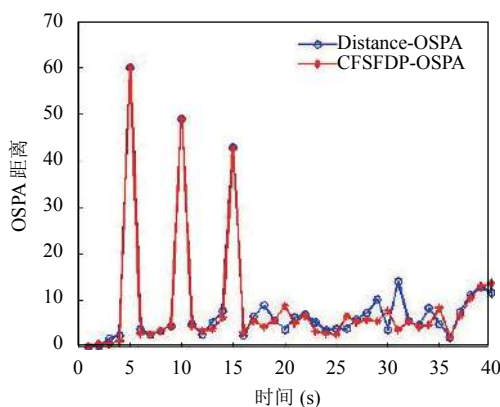


图7 OSPA 比较

表2所示为两种算法在不同杂波泊松平均率下的运行时间对比, 由于距离划分给出所有划分可能且无法去除杂波, 在杂波密度增加时, 运行效率下降。在利用 CFSFDP 算法去除杂波之后, 由于后续预测更新

直接处理的是目标量测, 泊松杂波率的变化则不再影响运行时间, 从表2可以看出在提高杂波密度情况下对比两种划分方法, CFSFDP 划分方法运行效率显著提升, 基于距离划分性能提升从 61.59% 到 92.22%。故而在高杂波等复杂情况下, 先利用 CFSFDP 算法进行量测预处理, 剔除杂波量测后只利用目标量测, 可以大大提高运算效率, 提高算法实时性。




图8 目标数估计

表2 不同杂波下平均运行时间

杂波率	Distance划分 (s)	CFSFDP划分 (s)
10	20.4079	7.8393
20	32.7172	7.6932
30	52.2281	7.5274
50	103.1495	8.0243

图7所示为剔除杂波之前, 泊松杂波率 $\lambda = 10$ 时两种算法的 OSPA 距离比较, 两者相差无几。与图7不同, 图9和图10显示在剔除杂波之后, 泊松杂波率分别为 30 和 50 的情况下, 两种算法的 OSPA 比较, 可以看出使用 CFSFDP 剔除杂波量测之后, 直接用目标量测信息进行预测更新, 其 OSPA 距离基本不再受杂波变化影响, 而使用距离划分方法时目标估计精度会随着杂波率的提高而降低, 说明使用 CFSFDP 剔除杂波量测可以在一定程度上提高目标估计精度。

4 实验结论

针对多扩展目标跟踪问题, 本文将机器学习中经典的无监督学习密度峰值快速聚类算法 CFSFDP 用于扩展目标量测集的划分, 利用 CFSFDP 进行量测预处理, 区分目标量测与杂波量测。然后利用箱粒子 CPHD 滤波算法进行目标跟踪。仿真实验表明在量测划分步骤中采用 CFSFDP 量测划分方法代替传统的距离划

分, CFSFDP 在达到相似跟踪性能的前提下, 减少了运算时间, 提高了运算效率; 使用 CFSFDP 方法剔除杂波量测之后, 可以充分利用目标量测准确估计目标数变化和运动状态, 杂波的变化不再影响滤波精度, 在一定程度上提高了目标估计精度, 并具有良好的鲁棒性。




图9 杂波率=30时 OSPA 比较

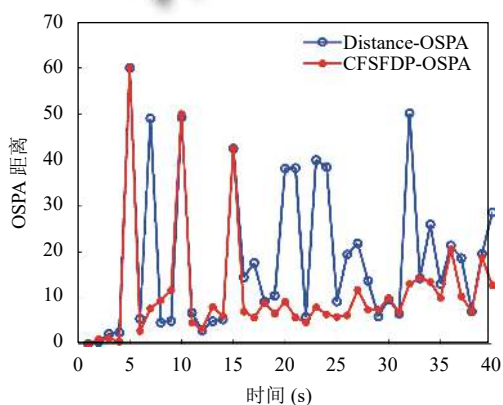


图10 杂波率=50时 OSPA 比较

参考文献

- Granström K, Baum M, Reuter S. Extended object tracking: Introduction, Overview, and Applications. *Journal of Advances in Information Fusion*, 2017, 12(2): 139–174.
- Mahler R. PHD filters for nonstandard targets, II: Unresolved targets. *Proceedings of 2009 12th International Conference on Information Fusion*. Seattle: IEEE, 2009. 922–929.
- Granström K, Lundquist C, Orguner U. A Gaussian mixture PHD filter for extended target tracking. *Proceedings of 2010 13th International Conference on Information Fusion*. Edinburgh: IEEE, 2010. 1–8.
- Li YX, Xiao H, Song ZY, *et al.* A new multiple extended target tracking algorithm using PHD filter. *Signal Processing*, 2013, 93(12): 3578–3588. [doi: 10.1016/j.sigpro.2013.05.011]
- 刘凤梅, 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. *计算机工程*, 2014, 40(12): 182–187, 194. [doi: 10.3969/j.issn.1000-3428.2014.12.034]
- 程轩, 宋骊平, 姬红兵. 基于 mean shift 和图结构的 GMPHD 扩展目标跟踪. *西北工业大学学报*, 2018, 36(3): 420–425. [doi: 10.3969/j.issn.1000-2758.2018.03.003]
- Zhang YQ, Ji HD. A novel fast partitioning algorithm for extended target tracking using a Gaussian mixture PHD filter. *Signal Processing*, 2013, 93(11): 2975–2985. [doi: 10.1016/j.sigpro.2013.04.006]
- Zhang YQ, Ji HB, Hu Q. A box-particle implementation of standard PHD filter for extended target tracking. *Information Fusion*, 2017, 34: 55–69. [doi: 10.1016/j.inffus.2016.06.007]
- Orguner U, Lundquist C, Granstrom K. Extended target tracking with a cardinalized probability hypothesis density filter. *Proceedings of 14th International Conference on Information Fusion*. Chicago: IEEE, 2011. 1–8.
- 宋志龙. 基于箱粒子滤波的多扩展目标跟踪算法研究 [硕士学位论文]. 西安: 西安电子科技大学, 2017.
- Zou ZB, Song LP, Cheng X. Labeled box-particle CPHD filter for multiple extended targets tracking. *Journal of Systems Engineering and Electronics*, 2019, 30(1): 57–67. [doi: 10.21629/JSEE.2019.01.06]
- Rodriguez A, Laio A. Clustering by fast search and find of density peaks. *Science*, 2014, 344(6191): 1492–1496. [doi: 10.1126/science.1242072]
- 陈俊芬, 张明, 赵佳成. 复杂高维数据的密度峰值快速搜索聚类算法. *计算机科学*, 2020, 47(3): 79–86. [doi: 10.11896/jsjcx.190400123]
- 陈春涛. 快速搜索与密度峰值发现算法的研究与应用 [硕士学位论文]. 上海: 华东师范大学, 2019.
- 王鹏飞, 杨余旺, 柯亚琪. 密度峰值快速聚类算法优化研究. *计算机工程与科学*, 2018, 40(8): 1503–1510. [doi: 10.3969/j.issn.1007-130X.2018.08.023]
- Gilholm K, Godsill S, Maskell S, *et al.* Poisson models for extended target and group tracking. *Proceedings of SPIE 5913, Signal and Data Processing of Small Targets 2005*. San Diego: SPIE, 2005. 59130R. [doi: 10.1117/12.618730]
- Mahler RPS. *Statistical Multisource-Multitarget Information Fusion*. Boston: Artech House, 2007.
- Li XR, Jilkov VP. Survey of maneuvering target tracking. Part I. Dynamic models. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1333–1364. [doi: 10.1109/TAES.2003.1261132]
- Ristic B, Vo BN, Clark D, *et al.* A metric for performance evaluation of multi-target tracking algorithms. *IEEE Transactions on Signal Processing*, 2011, 59(7): 3452–3457. [doi: 10.1109/tsp.2011.2140111]