

DOI: 10.3969/j.issn.1672-2337.2019.03.005

基于 PHD 的粒子滤波检测前跟踪改进算法

裴家正¹, 黄 勇¹, 董云龙¹, 何 友¹, 陈小龙¹, 陈唯实²

(1. 海军航空大学, 山东烟台 264001;
2. 中国民航科学技术研究院机场研究所, 北京 100028)

摘要: 针对在低信噪比目标检测问题中, 基于 PHD 的粒子滤波检测前跟踪算法(PHD-TBD)存在目标位置估计误差较大的缺陷, 提出一种结合粒子群优化算法的基于 PHD 的粒子滤波检测前跟踪方法(PSO-PHD-TBD)。该算法在滤波预测和更新步骤之间加入基于 NSGA-II 的多目标粒子群优化算法, 结合量测信息将预测完成的粒子集的分布进行优化, 将所有粒子转移到后验概率密度较大的区域, 进而改善了多目标位置估计的性能; 然后使用基于密度聚类的 DBSCAN 算法对粒子聚类, 提取目标状态。仿真实验表明, 在不同信噪比条件下, PSO-PHD-TBD 在多目标数目估计情况与 PHD-TBD 算法一致, 而位置估计精度明显优于 PHD-TBD 算法。

关键词: 概率假设密度; 粒子滤波; 粒子群优化; 基于密度聚类; 检测前跟踪

中图分类号: TN953; TN957 文献标志码: A 文章编号: 1672-2337(2019)03-0263-08

PHD-Based Particle Swarm Optimization Particle Filter Radar Track-Before-Detect Algorithm

PEI Jiazheng¹, HUANG Yong¹, DONG Yunlong¹, HE You¹, CHEN Xiaolong¹, CHEN Weishi²

(1. Naval Aviation University, Yantai 264001, China;
2. Airport Research Institute, China Academy of Civil Aviation Science and Technology, Beijing 100028, China)

Abstract: In the target detection under low signal-to-noise ratio, the PHD-based particle filter track-before-detect (PHD-TBD) algorithm has large estimation error of target position. A PF-PHD-TBD algorithm combined with particle swarm optimization is proposed. The algorithm adds a multi-objective particle swarm optimization algorithm based on NSGA-II between the filtering prediction and the updating steps. The measurement information is used to optimize the distribution of the predicted particle sets, and all of the particles are transferred to the high-posterior probability density to improve the performance of multi-target location estimation. Then the DBSCAN algorithm based on density clustering is applied to cluster the particles and extracts the target state simulation. The experiments under different SNR conditions show that the PSO-PHD-TBD is consistent with the PHD-TBD algorithm in terms of the multi-target number estimation, and its position estimation accuracy is significantly higher than the PHD-TBD algorithm.

Key words: probability hypothesis density; particle filter; particle swarm optimization; density based spatial clustering of applications with noise (DBSCAN); track-before-detect

0 引言

现代战场环境下随着以无人机为代表的航空

器的广泛应用, 其雷达散射截面积较小, 回波信号功率、信噪比会大大降低, 从而导致雷达的检测性能急剧下降^[1-2]。检测前跟踪(TBD)方法利用多帧原始观测数据联合实现检测和跟踪过程, 与传

收稿日期: 2018-07-03; 修回日期: 2018-08-23

基金项目: 国家自然科学基金(No. U1633122, 61501487, 61871392, 61471382, 61531020); 国防科技基金(No. 2102024); 中国博士后科学基金(No. 2017M620862); “泰山学者”和中国科协“青年人才托举工程”专项经费资助(No. YESS20160115)

统检测方法相比,针对低信噪比目标的检测性能更加优异,受到越来越多的关注^[3]。典型的 TBD 方法包括 Hough 变换^[4]、动态规划^[5]、粒子滤波^[6]等实现形式。由于当今多目标跟踪^[7]问题中,应用随机集理论(RFS)能够避免数据关联操作,将随机集理论迁移到 TBD 领域也已成为了一大研究趋势。

为减少 RFS 球论中多目标最优贝叶斯递推的算法复杂度,Mahler^[8]率先提出次最优的概率假设密度(PHD)滤波算法。该滤波迭代多目标后验概率密度的一阶矩,完成多目标的数目估计;其次根据目标估计数,在概率假设密度函数的峰值点处提取目标状态^[9]。作为 RFS 球论框架下的典型滤波器,PHD 滤波器自始至终迭代传递多目标整体的后验概率密度,因此在跟踪多个数量变化的目标同时,能有效地规避复杂的数据关联与配对,在保证算法实时性的同时,有效地提高跟踪精度^[10]。将 PHD 滤波器应用至 TBD 中,可以更好地解决多目标 TBD 问题,但该方面研究仍处于起步阶段,性能还需不断完善,为此不少文献^[11-12]提出了诸多改进方法。

本文针对现有基于 PHD 的粒子滤波检测前跟踪的位置估计精度较低的缺陷进行改进,受文献[13]的启发,结合当前量测值,在滤波的预测和更新步骤之间加入多目标粒子群优化,使粒子经过量测驱动向后验概率密度较大方向移动;然后在目标状态提取阶段,使用基于密度的 DBSCAN 数据聚类方法,将经由粒子群优化算法改良分布形态的粒子进行聚类提取目标的估计状态。经过仿真实验表明,改进后的算法相比原有的 PHD-TBD 在多目标位置估计上性能改善明显。

1 系统运动模型和观测模型

1.1 目标运动模型

目标运动模型设计为 CV 运动模型。多目标群体 $\mathbf{x}_{k,1}, \dots, \mathbf{x}_{k,Num}$ 中第 t 个目标的运动方程为

$$\mathbf{x}_{k,t} = \mathbf{F}_k \mathbf{x}_{k-1,t} + \mathbf{w}_k \quad (1)$$

式中: $\mathbf{x}_{k,t} = [x_{k,t}, \dot{x}_{k,t}, y_{k,t}, \dot{y}_{k,t}, I_{k,t}]$ 表示在 k 时刻目标 t 的状态向量,包含位置、速度和散射强度信息, $t = 1, \dots, Num$, Num 为目标总数; \mathbf{w}_k 为零

均值的高斯白噪声,协方差矩阵为 \mathbf{Q}_k , $\mathbf{Q}_k =$

$$\begin{bmatrix} \mathbf{Q} & & \\ & \mathbf{Q} & \\ & & q_2 T \end{bmatrix}, \mathbf{Q} = \begin{bmatrix} \frac{q_1}{3} T^3 & \frac{q_1}{2} T^2 \\ 0 & \frac{q_1}{2} T^2 \\ 0 & T \end{bmatrix}, T \text{ 表示采样周期},$$

q_1 和 q_2 分别表示目标运动噪声与目标强度噪声的标准差; $\mathbf{F}_k = \text{diag}(F_x, F_y, 1)$ 表示系统状态转移矩阵,其中 $F_x = F_y = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}$ 。

1.2 雷达系统观测模型

借鉴文献[14]在关于多普勒雷达的观测模型,雷达观测范围内共有 U_r 个距离分辨单元, U_d 个多普勒单元和 U_b 个方位单元。在雷达观测的 $U_r \times U_d \times U_b$ 个单元中,得到的功率观测值为

$$\mathbf{z}_k^{(i,j,l)} = |\mathbf{z}_{A,k}^{(i,j,l)}|^2 = \begin{cases} \left| \sum_{t=1}^{Num} A_{k,t} h_{k,t}^{(i,j,l)}(\mathbf{x}_{k,t}) + \mathbf{n}_k^{(i,j,l)} \right|^2, & H_1 \\ \left| \mathbf{n}_k^{(i,j,l)} \right|^2, & H_0 \end{cases} \quad (2)$$

式中, H_1 表示 (i, j, l) 单元中存在目标 t 的假设, H_0 表示 (i, j, l) 单元中不存在目标的假设。假设各分辨单元间相互独立,目标的 RCS 没有起伏,满足 Swerling 0 型假设, $A_{k,t}$ 为目标复幅度, $\mathbf{n}_k^{(i,j,l)}$ 为分辨单元 (i, j, l) 处的复高斯观测噪声,且 $\mathbf{n}_k^{(i,j,l)} = \mathbf{v}_{I,k}^{(i,j,l)} + i \mathbf{v}_{Q,k}^{(i,j,l)}$ 。 k 时刻目标 t 在 (i, j, l) 单元内的点扩散函数 $h_{k,t}^{(i,j,l)}$ 为

$$h_{k,t}^{(i,j,l)}(\mathbf{x}_{k,t}) = \exp \left\{ -\frac{(r_i - r_{k,t})^2}{2R} L_r - \frac{(d_j - d_{k,t})^2}{2D} L_d - \frac{(b_l - b_{k,t})^2}{2B} L_b \right\} \quad (3)$$

式中: R, D 和 B 表示与距离、多普勒和方位单元尺寸分辨率,分别根据带宽、积累时间和波束宽度决定; L_r, L_d 和 L_b 分别表示 3 个观测维度上的损耗系数; $r_{k,t}, d_{k,t}$ 和 $b_{k,t}$ 表示 k 时刻目标 t 所处的距离、多普勒和方位单元; r_i, d_j 和 b_l 表示 (i, j, l) 单元的距离、多普勒和方位信息。

依据量测模型,目标似然函数可表示为

$$p(\mathbf{z}_k | \mathbf{x}_{k,1}, \mathbf{x}_{k,2}, \dots, \mathbf{x}_{k,Num}) = \begin{cases} \prod_i \prod_j \prod_l p_1(\mathbf{z}_k^{(i,j,l)} | \mathbf{x}_{k,1}, \mathbf{x}_{k,2}, \dots, \mathbf{x}_{k,Num}; H_1) \\ \prod_i \prod_j \prod_l p_0(\mathbf{z}_k^{(i,j,l)} | H_0) \end{cases} \quad (4)$$

式中, p_0 表示没有目标时 (i, j, l) 单元处噪声的似

然函数, p_0 表示存在 Num 个目标时 (i, j, l) 单元目标加噪声的似然函数。

$$p_0(\mathbf{z}_k^{(i,j,l)} | \mathbf{H}_0) = N(\mathbf{z}_k^{(i,j,l)}; 0, \sigma^2) \quad (5)$$

$$p_1(\mathbf{z}_k^{(i,j,l)} | \mathbf{H}_1) = N(\mathbf{z}_k^{(i,j,l)}; \sum_{t=1}^{N_k} h_{k,t}^{i,j,l}(\mathbf{x}_{k,t}), \sigma^2) \quad (6)$$

由此得到似然比函数 L_k 的计算如下:

$$L_k = \frac{\prod_i \prod_j \prod_l p_1(\mathbf{z}_k^{(i,j,l)} | \mathbf{x}_{k,1}, \mathbf{x}_{k,2}, \dots, \mathbf{x}_{k,N_k}; \mathbf{H}_1)}{\prod_i \prod_j \prod_l p_0(\mathbf{z}_k^{(i,j,l)}; \mathbf{H}_0)} \quad (7)$$

2 改进的雷达 PSO-PHD-TBD 算法

改进之后的 PSO-PHD-TBD 算法主要借助于多目标粒子群优化算法以及基于密度聚类的 DB-SCAN 算法相结合提高对目标的位置估计精度。2.1 节着重描述多目标粒子群优化算法, 2.2 节强调对粒子进行基于密度聚类, 2.3 节展示 PSO-PHD-TBD 的具体实施步骤, 并在 3.2 节中给出了具体的算法复杂度的分析。

2.1 粒子群优化算法

粒子群优化算法(Particle Swarm Optimization, PSO)通过粒子个体通过适应度目标函数的函数值信息进行粒子优选, 完成对最优条件的搜索^[15]。算法中每个粒子 i 具有位置和搜索速度, 代表最优结果的可能取值。算法首先定义适应度目标函数, 通过迭代寻找最优解。迭代操作按照式(8)、式(9)更新每个粒子的运动信息, 使得每个粒子移动, 经过对粒子的个体最优解 p_i 筛选, 在搜索全局极值 g_i 的同时实现对集群分布的优化^[16]。

$$v_i = w v_i + c_1 R_1 \cdot (p_i - x_i) + c_2 R_2 \cdot (g_i - x_i) \quad (8)$$

$$x_{i+1} = x_i + r v_i \quad (9)$$

式中, R_1 和 R_2 在区间 $(0, 1)$ 内随机取值, w 为惯性系数, c_1 和 c_2 为正实数, 代表粒子向个体最优解和全局最优解移动的权重, x_i 和 x_{i+1} 为粒子状态, v_i 为搜索速度, r 为更新因子。

在多目标的检测前跟踪过程中, 由于存在多个适应度目标函数之间相互冲突, 一个目标函数的最优解往往并不能满足剩余目标函数最优解, 因此每一个目标的最优解只能陷入局部最优解。而多目标粒子群优化(Multi-Object PSO,

MOPSO)方法, 借助 NSGA-II 算法实现利用多个适应度目标函数筛选粒子, 能够将粒子引导、移动以求取多目标 Pareto 最优解集^[17-18]。作为遗传算法上的改进^[19], 算法关键步骤在以下 3 个过程:

1) 精英选择策略。为了避免盲目的更新迭代而采用的一种方法, 将更新前后的粒子集群同时存储进行优先选择。

2) 快速非支配排序。将粒子群中所有粒子的解进行比较, 得出粒子目标函数值之间的支配关系, 对种群分层, 从而指引搜索向 Pareto 最优解集方向进行。

3) 计算拥挤距离。计算粒子的拥挤距离是为了能够将处于相同非支配层的粒子进行选择性排序。对同一非支配层 L 中所有 n 个粒子的拥挤距离 dis_i 初始化。

$$dis_i = 0, i = 1, 2, \dots, n \quad (10)$$

对同层的个体按照第 m 个目标函数值升序排列: 对于排序边缘上的粒子, 令 $dis_0 = dis_n = D$ (D 为一较大乘数); 对排序中间的粒子 i , 求取拥挤距离 dis_i 。

$$dis_i = \sum_m W_m dis_{i,m} \quad (11)$$

$$dis_{i,m} = dis_{i,m} + (dis_{i+1,m} - dis_{i-1,m}) / (f_{\max,m} - f_{\min,m}) \quad (12)$$

式中 $dis_{i+1,m}$, $dis_{i-1,m}$ 为粒子 i 的相邻粒子对第 m 个目标函数的函数值, $f_{\max,m}$, $f_{\min,m}$ 分别为层中粒子对第 m 个目标函数的最大值和最小值。基于所有的适应度目标函数, 都需要循环上述步骤, 每一个目标函数拥有与之相对应的函数权重 W_m , 对所有的 $W_m dis_{i,m}$ 求和得到粒子 i 的拥挤距离 dis_i 。

为了避免陷入局部最优解的问题, 再加入变异机制增加粒子的多样性。粒子分为三部分, 一为选择不变异, 二为统一增加变异量, 三为随机添加变异量。

2.2 基于密度的数据聚类方法

粒子群优化方法使粒子都向后验概率密度较大的区域进行移动, 这样使得基于密度进行聚类的方法得到应用。基于密度的聚类算法其实是基于距离的聚类的类型(这一点和通常使用的 K-means 聚类方法类似)。只要邻近区域的粒子密度超出了阈值 Th_{\min} , 就可以继续对粒子聚类。DB-SCAN 是其中具有代表性的一种, 该方法根据密度阈值 Th_{\min} 控制聚类的增长, 其主要目的是通过

过滤低密度区域来发现稠密样本点聚类。

DBSCAN 方法将聚类定义为高密度相连点的最大集合，并能发现任意形状的聚类^[20]。为了实现粒子聚类，算法描述需要输入一个如数目为 N 的粒子群，一个最小半径 E ，密度阈值 Th_{\min} 。对于尚未被聚类的粒子，算法主要统计该粒子周围半径 E 范围内的粒子数量，如果小于 Th_{\min} ，则该点为噪声点；如果抽出的粒子其最小半径 E 范围内的粒子数目超出阈值 Th_{\min} ，则该点成为一个新聚类的核心点，将所有从该点密度可达的点加入到当前聚类中，如果该点密度可达节点中有已经生成聚类的核心点，则将两个聚类合并形成一个聚类，新聚类的核心点为原来合并的核心点的集合。

2.3 PSO-PHD-TBD 算法实施步骤

借助于粒子滤波(也称为序贯蒙特卡洛^[21])的实现形式，PSO-PHD-TBD 的具体实施步骤如下：

1) 初始化

根据多目标初始概率密度 $p_0(\mathbf{X}_0)$ 进行粒子采样，假设初始目标数为 N_0 ，采样粒子数为 N ，粒子的状态集合为 $\mathbf{x}_0^{(i)} \sim p_0(\mathbf{X}_0)$ ，且赋予粒子权重为

$$\omega_0^{(i)} = \frac{N_0}{N_0 \times N} = \frac{1}{N} \quad (13)$$

2) 预测

假设在 $k-1$ 时刻有 L_{k-1} 个粒子，则根据建议密度 $q_k(\cdot | \mathbf{x}_{k-1}^{(i)}, \mathbf{Y}_k)$ 采样存活目标的粒子^[22]：

$$\mathbf{x}_{k|k-1}^{(i)} \sim q_k(\cdot | \mathbf{x}_{k-1}^{(i)}, \mathbf{Y}_k), i=1, 2, \dots, L_{k-1} \quad (14)$$

并根据下式计算存活粒子的权重：

$$\omega_{k|k-1}^{(i)} = \frac{\omega_{k-1}^{(i)} f_{k|k-1}(\mathbf{x}_{k|k-1}^{(i)} | \mathbf{x}_{k-1}^{(i)}) p_s}{q_k(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{Y}_k)} \quad (15)$$

假设 k 时刻新生目标的采样粒子数为 J_k ，则根据建议密度 $p_k(\cdot | \mathbf{Y}_k)$ 采样新生目标的粒子：

$$\mathbf{x}_{k|k-1}^{(i)} \sim p_k(\cdot | \mathbf{Y}_k), i=L_{k-1}+1, \dots, L_{k-1}+J_k \quad (16)$$

并根据式(17)计算新生粒子的权重：

$$\omega_{k|k-1}^{(i)} = \frac{\gamma_k(\mathbf{x}_k^{(i)})}{J_k p_k(\mathbf{x}_k^{(i)} | \mathbf{Y}_k)} \quad (17)$$

式中， γ_k 为新生粒子的概率假设密度函数。

3) PSO 优化

在粒子的预测之后，将最新的观测值引入优化采样过程，根据获得的观测定义优化所需的适

应度目标函数：

$$fitness_m^{(j)} = \exp \left[-\frac{(\mathbf{x}^{(j)} - \mathbf{Z}_m)^2}{2c \cdot \sigma_n^2} \right] \quad (18)$$

$$fitness^{(j)} = \sum_m w_m fitness_m^{(j)} \quad (19)$$

式中， $fitness_m^{(j)}$ 为第 j 个粒子对第 m 个观测值的适应度目标函数值， $fitness^{(j)}$ 为第 j 个粒子适应度目标函数值， w_m 为第 m 个函数值的权重，通常设为 $1/m$ ， σ_n^2 为观测噪声协方差， c 为修正系数， $\mathbf{x}^{(j)}$ 和 \mathbf{Z}_m 分别代表粒子 j 和观测 m 的状态向量。

为了避免预测概率密度与似然函数的重叠区域较小的问题，在此设置粒子群优化算法，结合量测信息，由量测驱动粒子集通过式(8)、式(9)不断更新迭代向高似然比区域移动，提高每一个粒子的利用效率，使粒子不断地向高似然状态靠近^[13]。具体的实施步骤如下：

① 经过对父代种群粒子进行式(8)、式(9)的运算更新得到子代种群，对子代种群中的粒子进行变异操作，同时父代粒子的权重也传递给子代对应的粒子；

② 将两个种群合并，进行非支配排序，计算整个粒子集之间的拥挤距离；

③ 选择生成新的父代种群粒子，对粒子权重重新进行归一化处理，继续进行下一轮的优化迭代，直到适应度函数值达到阈值 Th_{pso} 。

4) 更新

对于 k 时刻已经过优化处理的所有粒子 $i=1, 2, \dots, L_{k-1}+J_k$ ，根据式(20)更新其权重：

$$\omega_k^{(i)} = \omega_{k|k-1}^{(i)} \times \frac{\prod_{l \in T_i(x_{k|k-1}^{(i)})} \prod_{j \in T_j(x_{k|k-1}^{(i)})} \prod_{l \in T_l(x_{k|k-1}^{(i)})} L(z_k^{(i,j,l)} | \mathbf{x}_{k|k-1}^{(i)})}{\lambda_k + \rho_k(y_{j_0}^{(i_0, j_0, l_0)})} \quad (20)$$

式中， λ_k 为杂波归一化系数， $L(z_k^{(i,j,l)} | \mathbf{x}_{k|k-1}^{(i)})$ 为观测的似然比函数^[23]。

$$L_k(z_k^{(i,j,l)} | \mathbf{x}_k^{(i)}) = \frac{1}{2\sigma^2} \exp \left\{ \frac{(z_k^{(i,j,l)} + (\mu_k^{(i)})^2)}{2\sigma^2} \right\} \times I_0 \left[\frac{\sqrt{z_k^{(i,j,l)}}}{\sigma} \right] \quad (21)$$

$$\mu_k^{(i)} = A_k h_k^{(i,j,l)}(\mathbf{x}_k^{(i)}) \quad (22)$$

$$g_k(z_k^{(i,j,l)}) = \frac{1}{2\sigma^2} \exp \left\{ \frac{z_k^{(i,j,l)}}{2\sigma^2} \right\} \quad (23)$$

σ^2 为观测噪声协方差，而权重表达式分母的另一项，

$$\rho_k(y_k^{(i_0, j_0, l_0)}) = \sum_{x_{k|k-1}^{(i)} \in P^{(i_0, j_0, l_0)}} \prod_{i \in T_i(x_{k|k-1}^{(i)})} \prod_{j \in T_j(x_{k|k-1}^{(i)})} \prod_{l \in T_l(x_{k|k-1}^{(i)})} L(z_k^{(i, j, l)} | x_{k|k-1}^{(i)}) \omega_{k|k-1}^{(i)} \quad (24)$$

式中,

$$\begin{aligned} P^{(i_0, j_0, l_0)} &= \{x_{k|k-1}^{(i)} : p \in \{1, 2, \dots, L_{k-1} + J_k\} \\ i_0 &= D_i(x_{k|k-1}^{(i)}), j_0 = D_j(x_{k|k-1}^{(i)}) \\ l_0 &= D_l(x_{k|k-1}^{(i)}) \end{aligned} \quad (25)$$

式中, $D_i(x_{k|k-1}^{(i)})$, $D_j(x_{k|k-1}^{(i)})$ 和 $D_l(x_{k|k-1}^{(i)})$ 分别表示第 i 个预测粒子所在的单元, 因而, 式(20)理解为与第 i 个预测粒子在同一个分辨单元中的所有粒子的集合。

5) 数目估计、重采样以及状态提取

根据粒子权重之和估计目标数目

$$\hat{N}_k = \text{round}\left(\sum_{i=1}^{L_{k-1}+J_k} \omega_k^{(i)}\right) \quad (26)$$

为了避免粒子权重退化, $\{x_k^{(i)}, \omega_k^{(i)}\}_{i=1}^{L_{k-1}+J_k}$ 经过重采样重新筛选大小为 L_k 的粒子集, 然后对所有粒子权重进行归一化得到新的粒子集 $\{x_k^{(i)}, 1/N\}_{i=1}^{L_k}$ 。根据估计出的目标数目, 以 DBSCAN 聚类结合最小半径 E 和密度阈值 Th_{\min} , 提取总数为 \hat{N}_k 的粒子群密度聚类和聚类中心的状态。

3 算法仿真

3.1 仿真条件设置

本节将给出多目标 TBD 的应用实例, 仿真中假定目标运动满足匀速模型。扫描周期 $T=1$ s, 目标运动近似为线性运动, 运动方程同式(1)。假设雷达的测量区域设置为 $[0, 2000]$ m \times $[0, 2000]$ m, 雷达位于原点位置, 距离单元分辨率 $R=20$ m, 多普勒单元分辨率 $D=1$ m/s, 方位单元分辨率 $B=1^\circ$ 。为便于算法性能对比, 一共产生 40 帧仿真数据(文中将一次扫描数据设置为一帧数据, 由于扫描周期为 1 s, 数据信息一共历时 40 s), 经过 100 次蒙特卡洛实验取均值。

仿真设置在 3 种不同信噪比条件下(分别为 9, 7 和 5 dB), 雷达的观测区域存在 6 个目标, 目标初始运动状态如表 1 所示。假定目标的 RCS 没有起伏, 满足 Swerling 0 型假设; 目标存活概率 $P_s=0.98$, 新生概率 $P_b=0.02$; 过程噪声协方差

为 0.001; 目标强度噪声协方差为 0.01; 粒子数 $L=500$; $\text{SNR}=10\lg(P/2\sigma^2)$, 观测噪声协方差为 1, 则可依据信噪比以及观测噪声协方差 σ^2 来得到目标功率。目标强度设定 $I=20$, 粒子的强度服从介于[15, 25]之间的均匀分布。

表 1 目标初始运动状态

序号	出现帧	消失帧	初始状态/ [m, m/s, m, m/s, -]
1	12	31	[250, 40, 1500, -15, I]
2	16	34	[250, 55, 1500, 2.5, I]
3	5	37	[250, 30, 1500, -25, I]
4	17	40	[1750, -67.5, 500, 10, I]
5	12	29	[1750, -65, 500, 22.5, I]
6	15	32	[1750, -60, 500, -17.5, I]

每个目标分别设置 1000 个粒子, 设置高斯混合模型从中采样得出 500 个新生粒子, 高斯混合模型一共包含 3 种高斯分布 $x_{(i)} \sim \mathcal{N}(x; m_{(i)}, P)$, $i=1, 2, 3$ 相组合, 具体参数分别为 $m_{(1)}=[250 \text{ m}, 0 \text{ m/s}, 1500 \text{ m}, 0 \text{ m/s}, I]$, $m_{(2)}=[1000 \text{ m}, 0 \text{ m/s}, 1000 \text{ m}, 0 \text{ m/s}, I]$, $m_{(3)}=[1500 \text{ m}, 0 \text{ m/s}, 250 \text{ m}, 0 \text{ m/s}, I]$, $P=\text{diag}([20 \text{ m } 20 \text{ m/s } 20 \text{ m } 20 \text{ m/s } 1])^2$, 3 种目标的权重一致。多目标粒子群优化过程中, 在一个时刻 k 内迭代次数 $gen=10$, 目标函数阈值 $Th_{\text{pso}}=0.7$, 达到迭代次数后以适应度函数阈值为优化结束的最终条件。DBSCAN 聚类时设置参数最小半径 $E=5$ m 和密度阈值 $Th_{\min}=10$ 。

整个仿真场景不考虑新目标衍生。目标真实运动状态如图 1 所示, 图中三角形表示目标起始位置, 正方形表示消失位置。

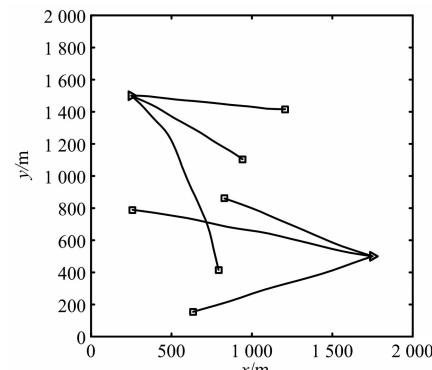


图 1 目标的真实轨迹

图 2 表示 9 dB 信噪比条件下, 监视区域在第 25 帧时已转换为笛卡尔坐标系的回波能量信息, 6 个目标都悉数出现在观测区域, 完全淹没在噪声

之中。

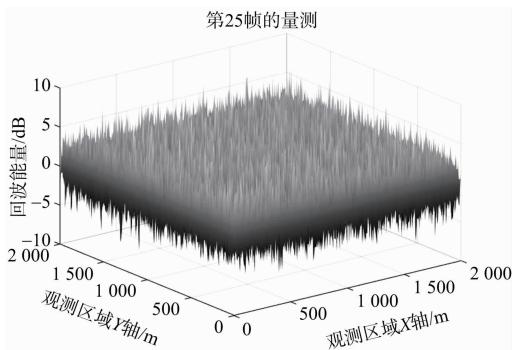


图 2 第 25 帧的观测信息

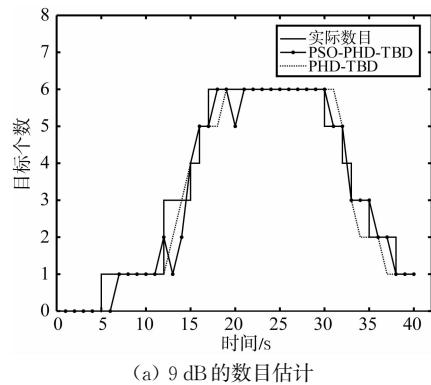
3.2 仿真结果分析

本文将所提出的 PSO-PHD-TBD 算法和常规 PHD-TBD 算法对同一仿真场景在信噪比进行性能分析。

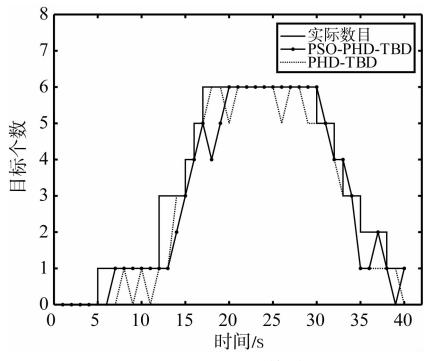
1) 对目标的数目估计情况

经过 100 次蒙特卡洛的仿真实验, 得到平均每个时刻的估计数目如图 3 所示。

两种算法在随着信噪比的降低, 两算法的估计性能都出现了相应的下降。相较之下, PSO-PHD-TBD 的性能更加稳定。图 4 列举出不同信噪比条件下基于 100 次蒙特卡洛仿真计算而来的数目



(a) 9 dB 的数目估计



(b) 7 dB 的数目估计

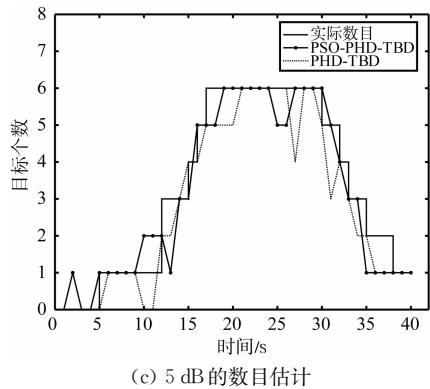
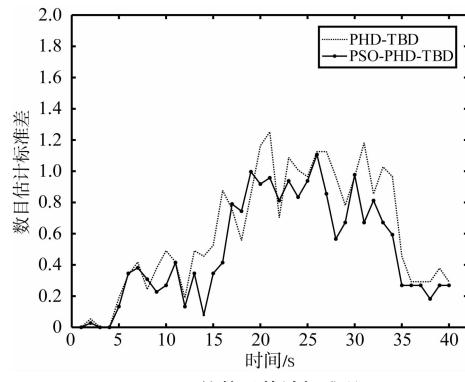


图 3 不同信噪比下算法对目标数目的估计

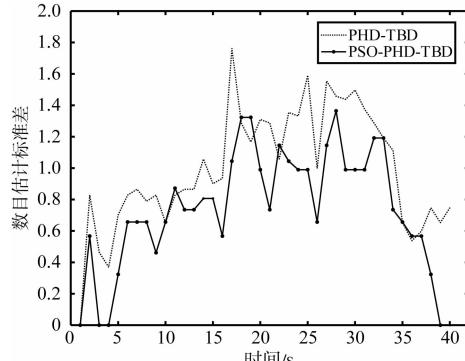
估计标准差, 表 2 展示了 40 帧数据目标数目估计标准差的均值, 统计值越小代表目标数目估计越准确。根据图 4 和表 2 可以看出在数目估计精度上 PSO-PHD-TBD 算法相比于 PHD-TBD 算法也有较为明显的提高。

表 2 两种算法目标数目估计标准差均值

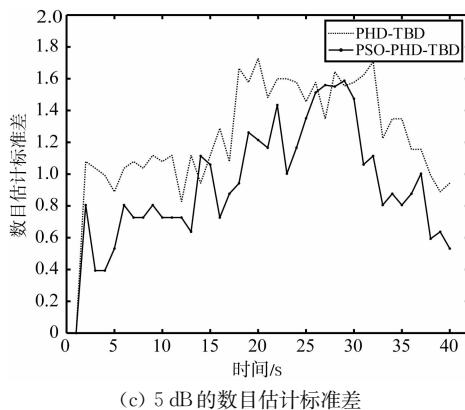
算法	SNR=9 dB	SNR=7 dB	SNR=5 dB
PHD-TBD	0.59	1.00	1.25
PSO-PHD-TBD	0.47	0.74	0.93



(a) 9 dB 的数目估计标准差



(b) 7 dB 的数目估计标准差



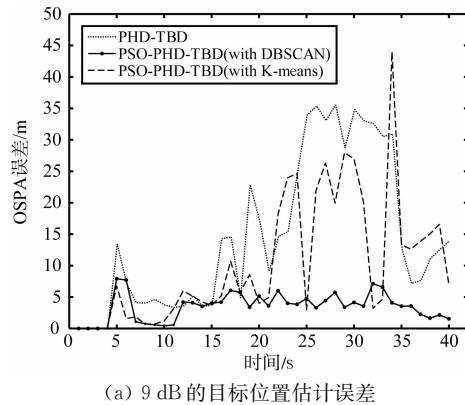
(c) 5 dB 的数目估计标准差

图4 不同信噪比下算法对目标数目估计标准差

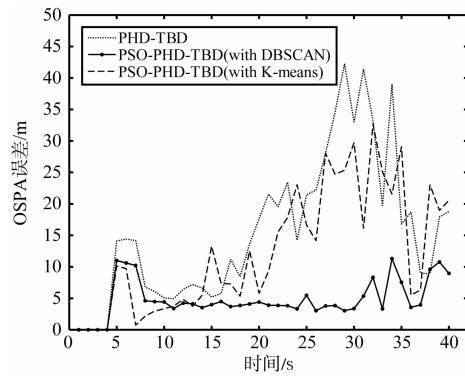
2) 对目标位置精度的估计情况

本文按照OSPA距离^[24]作为误差评判标准,设置OSPA距离参数截断距离 $c=50\text{ m}$, $p=2$ 。为了更好地进行对比说明粒子群优化与DBSCAN方法相结合的优势,另外添加了结合粒子群优化但进行常规K-means聚类的PHD-TBD算法添加对照,按照相同的仿真场景,得出的结果如图5所示。具体3种算法在不同信噪比下的OSPA误差的均值如表3所示。

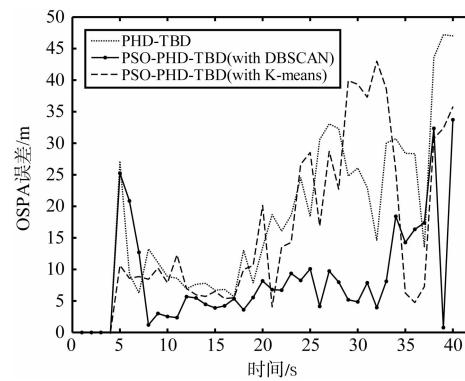
综合来看,新提出的PSO-PHD-TBD算法主要在目标位置估计精度上较PHD-TBD算法有了明显进步,随着信噪比的降低,精度上优势更加明显。



(a) 9 dB 的目标位置估计误差



(b) 7 dB 的目标位置估计误差



(c) 5 dB 的目标位置估计误差

图5 不同信噪比下3种算法的误差比较

表3 不同信噪比下OSPA误差均值

算法	SNR = 9 dB	SNR = 7 dB	SNR = 5 dB
PHD-TBD	14.68	15.79	17.75
PSO-PHD-TBD (with K-means)	9.43	11.55	15.60
PSO-PHD-TBD (with DBSCAN)	3.47	4.88	8.52

3) 算法实现复杂度分析

本文所提出的PSO-PHD-TBD的粒子滤波实现方式,借助了多目标粒子群优化,DBSCAN算法共同实现。DBSCAN算法的时间复杂度是 $O(n^2)$,相比于K-means聚类的时间复杂度 $O(n)$ 更加复杂,另外基于NSGA-II的MOPSO算法的时间复杂度为 $O(mn^2)$,其中 m 为目标函数的个数, n 为粒子数目,通过理论分析PSO-PHD-TBD算法运行时间确实更长,最为理想的情况下生存粒子维持现有的分布,仅有新生粒子随着粒子群优化而改变分布,会使得优化所用的时间最短。在Intel(R) Core(TM) i5-4590 3.30 GHz CPU,16 GB(DDR3 1600 MHz)内存,Win7 64位旗舰版计算平台下运行不同信噪比条件下仿真的平均时长如表4所示。

表4 不同信噪比下算法运行时长

算法	SNR = 9 dB	SNR = 7 dB	SNR = 5 dB
PHD-TBD	12.49	12.76	12.85
PSO-PHD-TBD (with K-means)	20.45	22.97	25.44
PSO-PHD-TBD (with DBSCAN)	22.19	25.73	28.26

在信噪比降低的情况下,优化步骤会受到一定的影响,从而PSO-PHD-TBD的运算时间会随之增加,反观PHD-TBD算法因为不存在优化步骤,因此在时间上并没有随信噪比的变化而能明显改变;因为DBSCAN的算法复杂度高于K-

means 聚类,因此同样经过粒子群优化而聚类不同的算法运算效率也不同,具体而言本文提出的粒子群优化与 DBSCAN 算法相结合的用时更长。虽然运算成本不可避免地增加,但是很明显的一点是本文提出的 PSO-PHD-TBD 的算法性能要明显地优于 PHD-TBD。在运行时间尚能容忍的情况下,利用 DBSCAN 聚类的 PSO-PHD-TBD 算法依旧是更好的选择。

4 结束语

经过仿真对比发现,结合 DBSCAN 聚类的 PSO-PHD-TBD 算法通过粒子群优化算法结合量测优化粒子分布,再将基于密度的聚类算法运用到经过优化的粒子滤波当中可以实现较为良好的聚类效果,能够满足检测目标发现其位置的要求,更是能在目标数目准确估计的情况下将估计误差加以降低。但是 DBSCAN 算法对两个初始参数邻域半径和邻域最小点数还需要根据仿真过程调试,以达到最佳聚类效果。同时粒子群优化算法复杂度较高,在计算中确实牺牲了一部分计算效率,在今后的工作中则需要尽可能地解决粒子数和运算时间之间的矛盾,并希望能够历史信息自适应选择粒子集群优化,避免低效率的优化。

参考文献:

- [1] 陈小龙,关键,黄勇,等.雷达低可观测目标精细化处理及应用[J].科技导报,2017,35(20):19-27.
- [2] 陈小龙,关键,何友,等.高分辨稀疏表示及其在雷达成像中的应用[J].雷达学报,2017,6(3):239-251.
- [3] DENG X, PI Y, MORELANDE M, et al. Track-Before-Detect Procedures for Low Pulse Repetition Frequency Surveillance Radars[J]. IET Radar, Sonar & Navigation, 2011,5(1):65-73.
- [4] MOYER L R, SPAK J, LAMANNA P. A Multi-Dimensional Hough Transform-Based Track-Before-Detect Technique for Detecting Weak Targets in Strong Clutter Backgrounds[J]. IEEE Trans on Aerospace and Electronic Systems, 2011,47(4):3062-3068.
- [5] ZHANG Xuwang, SUN Jinping, ZHANG Yuxi, et al. H-PMHT Track-Before-Detect Processing with DP-Based Track Initiation and Termination[J]. IET Signal Processing, 2016,10(9):1118-1125.
- [6] 吴孙勇,薛秋条,朱圣棋,等.杂波环境下基于粒子滤波的微弱扩展目标检测前跟踪算法[J].雷达学报,2017,6(3):252-258.
- [7] 杨云高,倪威,闫浩,等.基于多模型后验概率的机动目标跟踪方法[J].雷达科学与技术,2018,16(3):322-326.
- [8] MAHLER R P S. Multitarget Bayes Filtering via First-Order Multitarget Moment[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.
- [9] VO B T, VO B N, CANTONI A. Analytic Implementations of the Cardinalized Probability Hypothesis Density Filter[J]. IEEE Trans on Signal Processing, 2007,55(7):3553-3567.
- [10] 李翠芸,曹潇男,廖良雄,等.高斯粒子 PHD 滤波的多个弱小目标 TBD 算法[J].系统工程与电子技术,2015,37(4):740-745.
- [11] 曹潇男.基于随机有限集理论的检测前跟踪方法研究[D].西安:西安电子科技大学,2014.
- [12] 朱红鹏,黄勇,修建娟,等.基于 GM-PHD 平滑器的检测前跟踪技术[J].雷达科学与技术,2016,14(6):648-653.
- [13] 王尔申,庞涛,曲萍萍,等.基于混沌的改进粒子群优化粒子滤波算法[J].北京航空航天大学学报,2016,42(5):885-890.
- [14] BOERS Y, DRIESSEN J N. Multitarget Particle Filter Track Before Detect Application[J]. IEE Proceedings: Radar, Sonar and Navigation, 2004, 151(6):351-357.
- [15] SRINIVASA RAO P C, JANA P K, BANKA H. A Particle Swarm Optimization Based Energy Efficient Cluster Head Selection Algorithm for Wireless Sensor Networks [J]. Wireless Networks, 2017, 23(7): 2005-2020.
- [16] 汲清波,耿丽群,任超.高斯粒子群优化粒子滤波的检测前跟踪算法[J].计算机工程与应用,2014,50(17):205-209.
- [17] 王东风,孟丽.粒子群优化算法的性能分析和参数选择[J].自动化学报,2016,42(10):1552-1561.
- [18] 王皓,欧阳海滨,高立群.一种改进的全局粒子群优化算法[J].控制与决策,2016,31(7):1161-1168.
- [19] AFZALIRAD M, REZAEIAN J. A Realistic Variant of Bi-Objective Unrelated Parallel Machine Scheduling Problem: NSGA-II and MOACO Approaches [J]. Applied Soft Computing, 2017,50(1):109-123.

(下转第 279 页)