

# 控制与决策

Control and Decision

## 基于交互式CPHD的多传感器多机动目标跟踪

蔡如华, 樊向婷, 吴孙勇, 王力, 伍雯雯

引用本文:

蔡如华, 樊向婷, 吴孙勇, 等. 基于交互式CPHD的多传感器多机动目标跟踪[J]. 控制与决策, 2022, 37(1): 47–57.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0983>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于转换量测容积卡尔曼滤波器带多普勒量测的目标跟踪算法

Converted measurement cubature Kalman filter for Doppler-assisted target tracking

控制与决策. 2021, 36(6): 1425–1434 <https://doi.org/10.13195/j.kzyjc.2019.1070>

### 含混合储能的互联电力系统传感器容错负荷频率控制

Sensor fault-tolerant load frequency control for multi-area interconnected power system with hybrid energy storage system

控制与决策. 2021, 36(5): 1069–1077 <https://doi.org/10.13195/j.kzyjc.2019.1432>

### 抗遮挡与尺度自适应的改进KCF跟踪算法

Improved KCF tracking algorithm based on anti-occlusion and scale transformation

控制与决策. 2021, 36(2): 457–462 <https://doi.org/10.13195/j.kzyjc.2019.0394>

### 基于稀疏度阶数优化的杂波密度估计算法

A clutter density estimation algorithm by optimized sparsity order

控制与决策. 2020, 35(12): 2923–2930 <https://doi.org/10.13195/j.kzyjc.2019.0429>

### 基于操作风险的双模式传感器管理方法

A dual-mode sensor management method based on operational risk

控制与决策. 2020, 35(12): 2993–2998 <https://doi.org/10.13195/j.kzyjc.2018.1541>

# 基于交互式CPHD的多传感器多机动目标跟踪

蔡如华<sup>1</sup>, 樊向婷<sup>1</sup>, 吴孙勇<sup>1,2†</sup>, 王力<sup>1</sup>, 伍雯雯<sup>1</sup>

- (1. 桂林电子科技大学 数学与计算科学学院, 广西 桂林 541004;
2. 桂林电子科技大学 广西精密导航技术与应用实验室, 广西 桂林 541004)

**摘要:** 针对多传感器高速多机动目标的跟踪问题, 提出一种多传感器交互式贪婪势概率假设密度 (MS-IMM-Greedy-CPHD) 滤波器. 该滤波器在预测阶段, 通过交互式多模 (IMM) 算法对势概率假设密度 (CPHD) 滤波中目标的状态、势分布和运动模型同时进行预测; 在滤波的更新阶段, 利用贪婪 (greedy) 量测划分机制选取多传感器量测子集和拟分区, 并通过拟分区量测子集对不同模型下 CPHD 预测的目标状态和势分布以及模型进行交互式更新. 仿真结果表明, 所提出 MS-IMM-Greedy-CPHD 滤波能够对高机动多目标进行稳定有效的跟踪, 相较于多传感器势概率假设密度 (MS-CPHD) 滤波, 跟踪结果的 OSPA 误差更小且势估计更加准确.

**关键词:** 交互式多模型; 机动目标; 多传感器; 势概率假设密度滤波; 贪婪量测划分机制

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0983

开放科学(资源服务)标识码(OSID):



**引用格式:** 蔡如华, 樊向婷, 吴孙勇, 等. 基于交互式 CPHD 的多传感器多机动目标跟踪 [J]. 控制与决策, 2022, 37(1): 47-57.

## Multi-sensor and multi-maneuver target tracking based on interactive CPHD

CAI Ru-hua<sup>1</sup>, FAN Xiang-ting<sup>1</sup>, WU Sun-yong<sup>1,2†</sup>, WANG Li<sup>1</sup>, WU Wen-wen<sup>1</sup>

- (1. School of Mathematics and Computing Science, Guilin University of Electronic Technology, Guilin 541004, China;
2. Guangxi Key Laboratory of Precision Navigation Technology and Application, Guilin University of Electronic Technology, Guilin 541004, China)

**Abstract:** Aiming at the tracking problem of multi-sensor high-speed and multiple maneuvering targets, a multi-sensor interactive greedy cardinalized probability hypothesis density (MS-IMM-Greedy-CPHD) filter is proposed. In the prediction stage, the interacting multi-mode (IMM) algorithm is used to predict the state, potential distribution and motion model of the target in CPHD filtering; in the update stage of the filter, the greedy measurement partition strategy is used to select the multi-sensor measurement subsets and quasi-partition regions, and the quasi-partition measurement subset is used to predict the target state and potential distribution under different models which is updated interactively. Simulation results show that the proposed MS-IMM-Greedy-CPHD filter can track high maneuvering multi-target stably and effectively. Compared with the multi-sensor cardinalized probability hypothesis density (MS-CPHD) filter, the OSPA error of the proposed method is smaller and the cardinalized estimation is more accurate.

**Keywords:** interactive multiple model; maneuvering target; multi-sensor; cardinalized probability hypothesis density filter; greedy measurement division mechanism

## 0 引言

多目标跟踪通常指利用传感器量测对观测空间中目标的数量和状态作出正确、连续的估计<sup>[1]</sup>. 传统的多目标跟踪是将量测与目标相关联, 但是随着目标数目增加会发生组合爆炸的问题<sup>[2]</sup>. Mahler 在多目标跟踪理论的基础上引入有限集统计 (FISST), 提

出了随机有限集 (RFS)<sup>[3]</sup> 理论, 将多目标状态与量测建模为 RFS 的形式, 有效地解决了基于多假设跟踪 (MHT)<sup>[4]</sup> 和联合概率数据关联 (JPDA)<sup>[5]</sup> 在多目标跟踪过程中的组合爆炸问题. Mahler 在 RFS 理论框架下, 提出概率假设密度 (PHD) 滤波算法<sup>[6]</sup>, 降低了计算量并具有估计精度高、易于实现等优点. 随后, 文献

收稿日期: 2020-07-17; 修回日期: 2020-10-10.

基金项目: 国家自然科学基金项目 (11661024, 61861008); 广西自然科学基金项目 (2016GXNSFAA380073); 广西研究生教育创新计划项目 (2020YCX084).

责任编辑: 徐胜元.

<sup>†</sup>通讯作者. E-mail: wusunyong121991@163.com.

[7-8]给出了势概率假设密度(CPHD)滤波器.与PHD相比,CPHD克服了PHD的局限性,对目标强度函数和势分布函数进行联合估计,提高了滤波性能.然而,CPHD滤波在复杂场景下由于传感器性能的限制,导致单传感器已经不能满足目标跟踪的要求.文献[9]将单传感器FISST向多传感器FISST推广,并且实现了多传感器PHD(MS-PHD)滤波器.通过多传感器之间的相互协作,能有效地克服单传感器的局限性.

在多传感器场景中,每个传感器都能独立地对跟踪场景中的目标进行检测,但各传感器间的量测数据的关联性未知.为了将目标与量测进行有效关联,首先需要多个传感器的量测值进行划分.杨金龙等<sup>[10]</sup>提出距离划分法来获得所有划分的子集,但由于该方法需要预设关联阈值,阈值的选取会影响量测划分精确性.Qi等<sup>[11]</sup>提出一种基于 $K$ -均值聚类法的量测划分方法,该划分方法比距离划分更精确,但在效率上有所降低.为了减少计算复杂度并使得量测划分的结果更加精确,章涛等<sup>[12]</sup>提出了一种近邻传播量测聚类划分算法.随后,国外学者利用贪婪量测划分机制<sup>[13-14]</sup>对量测进行划分,通过选取量测子集及拟分区操作能够保持优越的后续跟踪性能,同时在拟分区操作过程中对量测进行筛选,利用最优量测子集对目标进行更新,从而使得跟踪性能得到显著提高.文献[15]在迭代PHD滤波(IC-CPHD)<sup>[16]</sup>的基础上进行改进,提出了势修正多传感器PHD(CPM-PHD)滤波器,该滤波器稳定性好,但跟踪误差大.

然而,目标在实际运动过程中会发生机动变化,无法准确预知目标运动状态,单一的模型不能很好地描述一个复杂的系统,导致滤波性能下降.为了克服单一模型对多目标跟踪的不足,文献[17]提出了转向率自适应的交互式机动目标跟踪算法.文献[18]提出了IMM-CPHD主被动雷达跟踪算法<sup>[18]</sup>,该算法针对单传感器交互式多目标跟踪有良好的效果,但由于传感器检测范围的限制,无法跟踪目标.当目标运动速度过快时,利用传统的贪婪量测划分机制对量测进行划分后,导致对高速机动目标进行检测与跟踪时无法实时地跟踪目标.为了更好地跟踪复杂场景下的多传感器多机动目标,本文利用交互式多模(IMM)<sup>[19]</sup>贪婪(greedy)量测划分机制对多传感器高速机动目标进行跟踪.

本文的主要工作和创新如下:1)针对多传感器高速多机动目标在单一模型条件下的模型失配导致目标误跟和失跟的问题,提出一种MS-IMM-Greedy-CPHD滤波,此滤波在预测阶段采用IMM算法对模

型参数进行交互式预测,以解决多传感器高速运动多目标跟踪效果差的问题.2)针对多传感器场景下的量测重复问题,在更新阶段运用贪婪量测划分机制对目标的量测子集进行挑选并找到最优路径,按照最优路径所包含的量测子集对目标进行交互式更新,以解决多传感器场景下同一量测被重复使用导致计算量过大和跟踪不准确的问题.3)通过序贯蒙特卡罗<sup>[20]</sup>(SMC)方法实现所提出的MS-IMM-Greedy-CPHD滤波.

## 1 问题背景

### 1.1 多传感器多目标随机有限集

在多目标跟踪问题中,目标状态是一个随时间变化的离散随机变量,因此多目标的状态模型可以表示为随机有限集的形式.设 $k$ 时刻的目标状态集 $X_k = \{x_{k,1}, x_{k,2}, \dots, x_{k,M}\}$ .其中: $x_{k,M}$ 为 $k$ 时刻的目标状态, $M$ 为 $k$ 时刻的目标个数. $X_k$ 可用随机有限集表示为

$$X_k = \left( \bigcup_{x \in X_{k-1}} S_{k|k-1}(x_{k-1}) \right) \cup \left( \bigcup_{x \in X_{k-1}} B_{k|k-1}(x_{k-1}) \right) \cup \Gamma_k. \quad (1)$$

其中: $S_{k|k-1}(x_{k-1})$ 为 $k-1$ 时刻存在且在 $k$ 时刻同样存在的目标随机有限集; $B_{k|k-1}(x_{k-1})$ 为由 $x_{k-1}$ 衍生出的目标随机有限集; $\Gamma_k$ 为 $k$ 时刻出现的目标随机有限集.

类似地,量测也是一个随时间变化的离散随机变量.若 $x_k$ 为 $k$ 时刻的目标状态,则 $k$ 时刻第 $i$ 个传感器对目标进行检测的目标量测集可用随机有限集表示为

$$z_k = \left( \bigcup_{x_k \in X_k} \Theta_k^{s_i}(x_k) \right) \cup K_k. \quad (2)$$

其中: $\Theta_k^{s_i}(x_k)$ 为第 $i$ 个传感器 $s_i$ 的目标状态 $x_k$ 所产生量测值的随机有限集; $K_k$ 为由杂波、误差和虚警等非目标因素产生的量测随机有限集.

### 1.2 CPHD滤波算法

在多目标跟踪中,CPHD滤波算法在PHD滤波算法的基础上放宽了条件,且增加了对目标势分布的概率密度函数的计算.CPHD滤波的预测和更新过程<sup>[7-8]</sup>如下:

1) 预测阶段.

CPHD滤波在 $k$ 时刻的预测方程如下:

$$p_{k|k-1}(n) = \sum_{j=0}^n p_{\Gamma,k}(n-j) \prod_{k|k-1} [v_{k-1}, p_{k-1}](j), \quad (3)$$

$$v_{k|k-1}(x) = \int p_{S,k}(x_{k-1})f_{k|k-1}(x_k|x_{k-1})v_{k-1}(x_{k-1})dx_{k-1} + b(x_k), \quad (4)$$

其中

$$\prod_{k|k-1} [v, p](j) = \sum_{l=j}^{\infty} C_j^l \frac{\langle p_{s,k}, v \rangle^j \langle 1 - p_{s,k}, v \rangle^{l-j}}{\langle 1, v \rangle^l} p(l); \quad (5)$$

$v_{k|k-1}(x)$  为多目标状态 PHD 函数;  $p_{k|k-1}(n)$  为多目标状态的势分布函数;  $b(x_k)$  为  $k$  时刻新生目标的随机有限集  $\Gamma_k$  的 PHD 函数;  $p_s(x_{k-1})$  为状态  $x_{k-1}$  在  $k$  时刻的存活概率;  $f(x_k|x_{k-1})$  为目标的转移概率密度;  $p_{\Gamma,k}(\cdot)$  为  $k$  时刻的新生目标势分布; 系数  $C_j^l = \frac{l!}{j!(l-j)!}$ ,  $P_j^n = \frac{n!}{(n-j)!}$ .

2) 更新阶段.

CPHD 滤波在  $k$  时刻的更新方程如下:

$$p_k(n) = \frac{\gamma_k^0[v_{k|k-1}, Z_k](n)p_{k|k-1}(n)}{\langle \gamma_k^0[v_{k|k-1}, Z_k], p_{k|k-1} \rangle}, \quad (6)$$

$$v_k(x) = \frac{\langle \gamma_k^1[v_{k|k-1}, Z_k], p_{k|k-1} \rangle}{\langle \gamma_k^0[v_{k|k-1}, Z_k] \rangle} [1 - p_{D,k}(x)]v_{k|k-1}(x) + \sum_{z \in Z_k} \frac{\langle \gamma_k^1[v_{k|k-1}, Z_k, \{z\}], p_{k|k-1} \rangle}{\langle \gamma_k^0[v_{k|k-1}, Z_k], p_{k|k-1} \rangle} \psi_{k,z}(x)v_{k|k-1}(x). \quad (7)$$

其中

$$\psi_{k,z}(x) = \frac{\langle 1, K_k \rangle}{K_k(z)} g_k(z|x)p_{D,k}(x), \quad (8)$$

$$\gamma_k^u[v, Z](n) = \sum_{j=0}^{\min(|Z|, n)} (|Z| - j)p_{K,k}(|Z| - j)P_{j+u}^n \times \frac{\langle 1 - p_{D,k}, v \rangle^{n-(j+u)}}{\langle 1, v \rangle^n} e_j(E_k(v, Z)), \quad (9)$$

$$E_k(v, Z) = \{ \langle v, \psi_{k,z} \rangle : z \in Z \}; \quad (10)$$

$e_j(z)$  为第  $j$  个量测子集的初等对称函数, 其定义为  $e_j(Z) = \sum_{S \subseteq Z, |S|=j} \left( \prod_{\partial \in S} \partial \right)$ ,  $e_0(Z) = 1$ ;  $Z_k$  为  $k$  时刻的量测集;  $g(\cdot|x)$  为状态  $x$  在  $k$  时刻的单目标似然函数;  $p_{D,k}$  为  $k$  时刻的状态的检测概率;  $K_k$  为  $k$  时刻当前状态的杂波强度;  $p_{K,k}(\cdot)$  为  $k$  时刻的杂波的势分布.

## 2 MS-IMM-Greedy-CPHD 多目标跟踪

对高速机动运动的目标采用单一模型进行跟踪时会因为目标速度过快导致目标出现误跟、漏跟的情况, 本文采用交互式多模算法 (IMM) 对高速运动的目标进行机动跟踪, 解决了单一模型下的模型失配问

题. 为了解决多传感器量测重复的问题, 本文在更新阶段采用贪婪量测划分机制对量测进行量测子集的划分与路径的选取后, 再对 PHD 分量进行交互式更新.

### 2.1 MS-IMM-Greedy-CPHD 预测

在  $k$  时刻, 利用交互式多模算法 (IMM) 进行目标状态估计, 设有  $m$  个模型滤波器均可能成为下一时刻的运动模型, 利用不同的模型对目标后验进行交互式预测. 当  $m = 3$  时, 交互式多模型算法的结构如图 1 所示.




图 1 交互式多模型算法结构

图 1 中  $x_{k-1|k-1}^{(i)}$  ( $i = 1, 2, 3$ ) 为同一个目标在  $k-1$  时刻经过不同模型更新后的目标状态, 通过不同的转移概率  $\eta_{ij}$  ( $i, j = 1, 2, 3$ ) 经过交互式预测得到  $\bar{x}_{k-1|k-1}^{(i)}$  ( $i = 1, 2, 3$ ), 在预测之后通过量测利用不同的模型  $M_i$  ( $i = 1, 2, 3$ ) 对目标的状态进行更新并计算模型权重  $w_{k,i}$ , 最后通过权重加权和  $\bar{w}_k$  得到  $k$  时刻的状态  $x_{k|k}$ .

设目标可能的运动模型参数集为  $\Lambda = \{\tau_i | i = 1, 2, \dots, m\}$ , 目标从模型  $i$  转移到模型  $j$  的转移概率为  $\eta(i, j)$ , 简记为  $\eta_{ij}$ , 其中  $i, j = 1, 2, \dots, m$ .  $m$  个模型之间的转移概率矩阵为

$$\eta = \begin{bmatrix} \eta_{11} & \eta_{12} & \dots & \eta_{1m} \\ \eta_{21} & \eta_{22} & \dots & \eta_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \eta_{m1} & \eta_{m2} & \dots & \eta_{mm} \end{bmatrix}. \quad (11)$$

预测步骤包括运动目标模型的预测和目标后验的预测, 设  $k-1$  时刻目标的势分布函数为  $p_{k-1|k-1}(x_{k-1}|\tau_{k-1})$ , 强度函数为  $v_{k-1|k-1}(\cdot|\tau_k = i, Z_{1:k-1}^{1:s})$ , 存活目标从模型  $i$  到模型  $j$  的交互式预测

$$\bar{v}_{k|k-1}(\cdot|\tau_k = j, Z_{1:k-1}^{1:s}) = \sum_{i=1}^m v_{k-1|k-1}(\cdot|\tau_k = i, Z_{1:k-1}^{1:s})\eta_{ij}, \quad (12)$$

则  $k$  时刻的目标后验强度目标势分布的交互预测

$$v_{k|k-1}(x_k|\tau_k = j, Z_{1:k-1}) = \int p_{s,k|k-1}(x_{k-1})f_{k|k-1}(x_k|x_{k-1}, \tau_k = j) \times$$

$$\begin{aligned}
& \bar{v}_{k|k-1}(x_{k-1}|\tau_k = j, Z_{1:k-1})dx_{k-1} + \\
& \int b_{k|k-1}(x_k|x_{k-1}, \tau_k = j) \times \\
& \bar{v}_{k|k-1}(x_{k-1}|\tau_k = j, Z_{1:k-1})dx_{k-1}, \quad (13) \\
& p_{k|k-1}(n_k|\tau_k) = \\
& \sum_{j=0}^n p_s((n_k - j)|\tau_k) \left[ \sum_{l=j}^{\infty} C_l^j p_{s,k|k-1}^j(x_{k-1}) \times \right. \\
& \left. (1 - p_{s,k|k-1}(x_{k-1}))^{l-j} p_{k-1|k-1}(l|\tau_{k-1} = v) \right]. \quad (14)
\end{aligned}$$

## 2.2 MS-IMM-Greedy-CPHD更新

MS-IMM-Greedy-CPHD更新阶段包括量测子集划分与拟分区操作,具体将在本节分别介绍.

### 2.2.1 贪婪(Greedy)量测子集的划分

设通过交互式预测得到  $M$  个状态分量  $X_k = \bigcup_{i=1}^M x_{k,i}$ , 针对每个预测分量选取最优量测子集  $W_{1:s} = (W_1, \dots, W_s)$ ,  $W_i$  表示第  $i$  个传感器局部量测子集, 其中  $|W_i| \leq 1$ . 设  $k$  时刻的所有传感器产生的量测集  $Z_k^{1:s} = \{z_{k,1}^1, z_{k,2}^2, \dots, z_{k,m_s}^s\}$ , 记为  $Z_k^{1:s} = \{z_{k,m_i}^j\}_{j=1}^s$ , 其中  $m_i$  代表的是第  $i$  个传感器检测到的量测个数. 利用贪婪量测划分机制<sup>[14-15]</sup>对第  $i$  个预测 PHD 分量进行高得分量测子集  $W_{1:s}$  的选取, 具体步骤如下.

step 1: 分别计算所有传感器量测  $Z_k^{1:s}$  相对于目标状态  $x_{k,i}$  在模型  $\tau_o$  下的伪似然函数, 其中模型  $\tau_o$  表示第  $o$  个模型. 第  $s$  个传感器的第  $j$  个量测  $z_{k,j}^s$  对第  $i$  个分量的伪似然函数计算如下:

$$\begin{aligned}
& \bar{h}_{k,s}^{(i,j)}(z_{k,j}^s|x_{k,i}, \tau_o) = P_D^s h(z_{k,j}^s|x_{k,i}, \tau_o), \\
& i = 1, 2, \dots, M_k^s, j = 1, 2, \dots, m_s, o = 1, 2, \dots, m. \quad (15)
\end{aligned}$$

其中未检测到目标情况下的伪似然函数为

$$\bar{h}_{k,s}^{\emptyset}(\emptyset|\cdot, \tau_o) = (1 - P_D^s), o = 1, 2, \dots, m.$$

step 2: 计算所有伪似然函数在模型  $\tau_o$  中的代价, 代价越小, 表示量测值对目标状态  $x_{k,i}$  的贡献度越大. 代价函数计算如下:

$$\begin{aligned}
& \varpi_{k,s}^{c_s} = -\log(\bar{h}_{k,s}^{c_s}), c_s = \emptyset \text{ or } (i, j); \\
& i = 1, 2, \dots, M_k^s, j = 1, 2, \dots, m_s. \quad (16)
\end{aligned}$$

其中  $c_s$  为第  $s$  个传感器  $k$  时刻产生的第  $i$  个 PHD 分量对应于第  $j$  个量测值的代价函数的指标.

step 3: 对于第  $i$  个 PHD 分量进行量测子集的挑选, 初始量测子集为  $W_0 = \emptyset$ , 按照传感器 1 到传感器  $s$  的顺序, 每次至多保留  $L$  个贡献度最大的量测子集. 设到第  $j$  个传感器的选取的  $L$  个量测子集为  $W_{1:j}^1, \dots, W_{1:j}^L$ , 将第  $j+1$  个传感器的  $m_{j+1}$  个量测分

别选取到第  $n$  个子集  $W_{1:j}^n$ , 其中  $n = 1, 2, \dots, L$ , 得到新的  $m_{j+1}$  个量测子集并计算其代价  $\phi_{W_{1:j+1}^n}[x]$ . 依次对  $L$  个量测子集进行上述操作后选择贡献度最大的前  $L$  个量测子集进行下一个传感器量测子集的选取, 直到对第  $s$  个传感器的量测子集选取完成后, 最终可得到  $L$  个最优量测子集  $W_{1:s}^1, \dots, W_{1:s}^L$ .

step 4: 对  $k$  时刻所有  $M$  个目标进行 step 1~step 3, 则可得到  $M \times L$  个量测划分子集. 记为  $\{W_{1:s}^{k,1}, W_{1:s}^{k,2}, \dots, W_{1:s}^{k,M \times L}\}$ .

step 5: 由于得到的  $M \times L$  个量测划分子集中有可能出现相同的量测子集, 对于重复量测子集保留一个得到  $L'$  个量测划分子集, 记为  $\{W_{1:s}^{k,1}, W_{1:s}^{k,2}, \dots, W_{1:s}^{k,L'}\}$ . 未被划分的所有其他量测值组成子集

$$W_{1:s}^{k,L'+1} = Z_k / \{W_{1:s}^{k,1} \cup W_{1:s}^{k,2} \cup \dots \cup W_{1:s}^{k,L'}\}.$$

为方便, 重记所有得到的量测子集为

$$\{W_{1:s}^{k,1}, W_{1:s}^{k,2}, \dots, W_{1:s}^{k,L'}, W_{1:s}^{k,L'+1}\} = \{W_{1:s}^{k,l}\}_{l=1}^L,$$

其中  $L = L' + 1$ .

对于任意一个量测子集  $W_{1:s}^j$ , 在模型  $\tau_o$  的条件下对单目标  $x$  的似然函数和代价计算如下:

$$\begin{aligned}
f(W_{1:s}^j|x, \tau_o) &= \prod_{(i,l) \in T_{W_{1:s}^j}} \frac{p_{i,D}(x|\tau_o) h_i(z_i^l|x, \tau_o)}{c_i(z_i^l|\tau_o)} \times \\
& \prod_{(i,l) \notin T_{W_{1:s}^j}} (1 - p_{i,D}(x|\tau_o)), \quad (17)
\end{aligned}$$

$$\phi_{W_{1:s}^j}[u] = \int u(x) p_{k+1|k}^{(j)}(x|\tau_o) f(W_{1:s}^j|x, \tau_o) dx. \quad (18)$$

### 2.2.2 贪婪量测划分机制的路径选取和 CPHD 更新

由于同一个目标在每一个传感器至多只产生一个量测值, 每个量测值至多只能对应一个目标, 故不能用相同的量测更新不同的目标. 因此, 需要从得到的  $M \times L$  个量测划分子集中分别对每个 PHD 分量选取量测子集作为一个分区<sup>[13]</sup>, 且分区中任意两个子集含有的所有非空元素都应该是互斥的, 即  $\forall i, j \in \{1, 2, \dots, M \times L\}$ , 均有  $W_{1:s}^{k,i} \cap W_{1:s}^{k,j} = \emptyset$ . 令  $\Omega$  表示  $k$  时刻所有的量测子集  $W_{1:s}^{k,j}$  的集合,  $\Omega$  中不相交子集  $W_1, W_2, \dots, W_M$  和  $V$  组成一个分区  $\mathcal{P}$ , 其中  $V = Z_k^{1:s} \setminus (\bigcup_{i=1}^M W_i)$ , 集合  $V$  是由所有传感器的杂波量测组成的集合.  $Z_k^{1:s}$  的一个分区  $\mathcal{P}$  的构造如下:

$$\mathcal{P} = \{W_1, W_2, \dots, W_{|\mathcal{P}|-1}, V\}, \quad (19)$$

其中  $|\mathcal{P}|$  定义为分区  $\mathcal{P}$  的数目.

令  $\ell$  表示在模型  $\tau_o$  的预测 PHD 分量目标没有被传感器检测到的概率密度函数, 有

$$\ell = \int v_{k|k-1}(x|\tau_o) \prod_{j=1}^s (1 - p_{D,k}(x|\tau_o)) dx. \quad (20)$$

杂波势分布和预测势分布的 $v$ 阶导数为

$$C_j^{(v)}(k) = \frac{d^v C_j}{dk^v}(k), M^{(v)}(k) = \frac{d^v M}{dk^v}(k).$$

对于分区 $\mathcal{P}$ 的杂波势分布计算如下:

$$K_{\mathcal{P}} = \prod_{j=1}^s C_j^{(m_j - |\mathcal{P}|_j)}(0). \quad (21)$$

其中: 设 $|\mathcal{P}|_j$ 是由第 $j$ 个传感器检测到目标的量测数目, 即 $|\mathcal{P}|_j = \sum_{i=1}^{|\mathcal{P}|-1} |W_{i,j}|$ ; 在传感器 $j$ 检测到的量测中被归为杂波量测的个数为 $m_j - |\mathcal{P}|_j$ ,  $m_j$ 表示第 $j$ 个传感器检测到的所有量测数目. 对于模型 $\tau_o$ 下状态 $x$ 的量测子集 $W \in \Omega$ , 有

$$d_W = \frac{1}{\prod_{(i,l) \in T_W} c_i(z_i^l | \tau_o)} \int v(x | \tau_o) \times \prod_{(i,l) \in T_W} p_{i,D}(x | \tau_o) h_i(z_i^l | x, \tau_o) \times \prod_{j:(j,*) \notin T_W} (1 - p_{i,D}(x | \tau_o)) dx, \quad (22)$$

$$\rho_W(x | \tau_o) = \frac{\prod_{(i,l) \in T_W} p_{i,D}(x | \tau_o) h_i(z_i^l | x, \tau_o) \times \prod_{j:(j,*) \notin T_W} (1 - p_{i,D}(x | \tau_o))}{\int v(x) \prod_{(i,l) \in T_W} p_{i,D}(x | \tau_o) h_i(z_i^l | x, \tau_o) \times \prod_{j:(j,*) \notin T_W} (1 - p_{i,D}(x | \tau_o)) dx}. \quad (23)$$

其中:  $d_W$ 为目标生成量测子集 $W$ 的似然函数与杂波生成量测子集 $W$ 似然函数之比,  $\rho_W$ 为量测子集 $W$ 的归一化伪似然函数,  $T_W = \{(i, l) : z_i^l \in W\}$ .

杂波量测子集与目标量测子集的路径划分系数如下:

$$\alpha_0 = \frac{\sum_{P \in \mathcal{P}} \left( \kappa_P M^{(|P|)}(\ell) \prod_{W \in \mathcal{P}} d_W \right)}{\sum_{P \in \mathcal{P}} \left( \kappa_P M^{(|P|-1)}(\ell) \prod_{W \in \mathcal{P}} d_W \right)}, \quad (24)$$

$$\alpha_P = \frac{\kappa_P M^{(|P|-1)}(\ell) \prod_{W \in \mathcal{P}} d_W}{\sum_{Q \in \mathcal{P}} \left( \kappa_Q M^{(|Q|-1)}(\ell) \prod_{W \in Q} d_W \right)}. \quad (25)$$

式(24)和(25)是用来对拟分区 $\mathcal{P}$ 进行评分的系数.

接下来利用分区 $\mathcal{P} = (W_{1:s}^0, \dots, W_{1:s}^M)$ 下的量测子集进行目标后验强度更新和势分布更新, 目标在 $k$ 时刻模型 $\tau_o$ 下CPHD滤波的更新方程如下:

$$\frac{v_{k|k}(x | \tau_o)}{v_{k|k-1}(x | \tau_o)} = \alpha_0 \sum_{j=1}^s (1 - p_{i,D}(x | \tau_o)) +$$

$$\sum_{P \in \mathcal{P}} \alpha_P \left( \sum_{W \in \mathcal{P}} \rho_W(x | \tau_o) \right), \quad (26)$$

$$\frac{p_{k|k}(n)}{p_{k|k-1}(n)} = \frac{\sum_{\substack{P \in \mathcal{P} \\ |P| \leq n+1}} \left( K_P \frac{n!}{(n - |P| + 1)!} \ell^{n - |P| + 1} \prod_{W \in \mathcal{P}} d_W \right)}{\sum_{P \in \mathcal{P}} \left( K_P M^{(|P|-1)}(\ell) \prod_{W \in \mathcal{P}} d_W \right)}. \quad (27)$$

其中 $\alpha_0, \alpha_P, \rho_W, d_W, K_P, \ell$ 分别由式(24)、(25)、(23)、(22)、(21)、(20)得到.

目标状态后验强度交互式更新如下:

$$v_{k|k}(x) = \sum_{o=1}^m v_{k|k}(x | \tau_o) w_{\tau_o}. \quad (28)$$

其中 $w_{\tau_o}$ 为第 $o$ 个模型的模型权重, 其更新公式为

$$w_{\tau_o} = \frac{\rho_w(x | \tau_o)}{\sum_{o=1}^m \rho_w(x | \tau_o)}. \quad (29)$$

### 3 MS-IMM-Greedy-CPHD 多目标跟踪方法的实现

MS-IMM-Greedy-CPHD滤波器采用粒子滤波算法实现<sup>[20]</sup>, 即用一组带权重粒子集合表示后验概率密度函数. 在本文算法中, 利用不同的模型对目标进行CPHD交互式预测, 对不同运动模型的CPHD滤波器并行处理信息<sup>[21]</sup>. 设 $k-1$ 时刻的目标后验强度信息为 $v_{k-1|k-1}(x_{k-1} | \tau_{k-1}, Z_{1:k-1}^{1:s})$ , 用粒子集表示为 $\{w_{k|k-1}^\theta, x_{k|k-1}^\theta, \tau_{k|k-1}^\theta\}_{\theta=1}^{L_{k-1}}$ , 即

$$\nu_{k|k-1}(x_{k-1} | \tau_{k|k-1}, Z_{1:k-1}^{1:s}) = \sum_{\theta=1}^{L_{k-1}} w_{k|k-1}^\theta \delta(x_{k|k-1} - x_{k|k-1}^\theta, \tau_{k|k-1} - \tau_{k|k-1}^\theta). \quad (30)$$

其中 $\delta(\cdot)$ 是Dirac delta函数, 表示为: 1)  $\delta(x - a) = 0, x \neq a$ ; 2)  $\int_{-\infty}^{+\infty} \delta(x - a) dx = 1$ .  $w_{k|k-1}^\theta$ 为粒子权重, 对 $w_{k|k-1}^\theta$ 求和即可得到 $k-1$ 时刻出现的目标数目.

MS-IMM-Greedy-CPHD算法的粒子滤波实现步骤如下:

#### 1) MS-IMM-Greedy-CPHD预测.

设 $k-1$ 时刻目标势分布函数为 $p_{k-1|k-1}(n_{k-1} | \tau_{k-1})$ , 模型交互预测 $\bar{v}_{k|k-1}(\cdot | \tau_{k|k-1}, Z_{1:k-1}^{1:s})$ 的模型存活样本点 $\{\tau_{k|k-1}^\theta\}_{\theta=1}^{L_{k-1}}$ 由建议密度为 $\pi_k(\cdot | \tau_{k-1})$ 的重要采样产生. 新生目标相应的模型样本点 $\{\tau_{k|k-1}^\theta\}_{\theta=L_{k-1}+1}^{L_{k-1}+J_k}$ 由建议密度 $\vartheta_k(\cdot)$ 产生, 则有

$$\tau_{k|k-1}^\theta \sim \begin{cases} \pi_k(\cdot|\tau_{k-1}), \theta = 1, 2, \dots, L_{k-1}; \\ \vartheta_k(\cdot), \theta = L_{k-1} + 1, \dots, L_{k-1} + J_k. \end{cases} \quad (31)$$

模型的交互式预测后验加权估计为

$$\bar{v}_{k|k-1}(\cdot|\tau_{k-1}, Z_{1:k-1}^{1:s}) = \sum_{\theta=1}^{L_{k-1}+J_k} \bar{w}_{k|k-1}^\theta \delta(\tau_{k-1} - \tau_{k-1}^\theta). \quad (32)$$

其中

$$\bar{w}_{k|k-1}^\theta = \begin{cases} \frac{\eta_{k|k-1}(\tau_{k|k-1}^\theta|\tau_{k-1}^\theta)}{\pi_k(\tau_{k|k-1}^\theta|\tau_{k-1}^\theta)} w_{k-1}^\theta, \theta = 1, 2, \dots, L_{k-1}; \\ \frac{\zeta_k(\tau_{k|k-1}^\theta)}{\vartheta_k(\tau_{k|k-1}^\theta)} \frac{1}{J_k}, \theta = L_{k-1} + 1, \dots, L_{k-1} + J_k. \end{cases} \quad (33)$$

$\zeta_k(\cdot)$ 为 $k$ 时刻新生目标的模型分布概率函数。

目标运动状态的预测  $v_{k|k-1}(x_k|\tau_k, Z_{1:k-1}^{1:s})$ , 存活状态样本点  $\{x_{k|k-1}^\theta\}_{\theta=1}^{L_{k-1}}$  是由建议密度  $q_k(\cdot|x_{k-1}, \tau_{k|k-1}, Z_k^{1:s})$  产生, 新生目标相应的状态样本点  $\{x_{k|k-1}^\theta\}_{\theta=L_{k-1}+1}^{L_{k-1}+J_k}$  由另一个建议密度  $\sigma(\cdot|\tau_{k|k-1}, Z_k^{1:s})$  产生, 则有

$$x_{k|k-1}^\theta \sim \begin{cases} q_k(\cdot|x_{k-1}, \tau_{k|k-1}, Z_k^{1:s}), \theta = 1, 2, \dots, L_{k-1}; \\ \sigma_k(\cdot|\tau_{k|k-1}, Z_k^{1:s}), \theta = L_{k-1} + 1, \dots, L_{k-1} + J_k. \end{cases} \quad (34)$$

目标运动状态的预测  $v_{k|k-1}(x_k|\tau_k, Z_{1:k-1}^{1:s})$ , 后验加权估计为

$$\nu_{k|k-1}(x_k|\tau_k, Z_{1:k-1}^{1:s}) = \sum_{\theta=1}^{L_{k-1}+J_k} w_{k|k-1}^\theta \delta(x_{k|k-1} - x_{k|k-1}^\theta, \tau_{k|k-1} - \tau_{k|k-1}^\theta). \quad (35)$$

其中

$$w_{k|k-1}^\theta = \begin{cases} \frac{\{p_{k|k-1}(x_{k|k-1}^\theta)f_{k|k-1}(x_{k|k-1}^\theta|x_{k-1|k-1}^\theta, \tau_{k|k-1}^\theta) + b_{k|k-1}(x_{k|k-1}^\theta|x_{k-1|k-1}^\theta, \tau_{k|k-1}^\theta)\}}{q_k(x_{k|k-1}^\theta|x_{k-1|k-1}^\theta, \tau_{k|k-1}^\theta, Z_k^{1:s})\bar{w}_k^\theta}, & \theta = 1, 2, \dots, L_{k-1}; \\ \frac{\xi(x_{k|k-1}^\theta|\tau_{k|k-1}^\theta)}{\sigma_k(x_{k|k-1}^\theta|\tau_{k|k-1}^\theta, Z_k^{1:s})}, & \theta = L_{k-1} + 1, \dots, L_{k-1} + J_k. \end{cases} \quad (36)$$

$\xi_k(\cdot)$ 为 $k$ 时刻新生目标的运动状态分布概率函数。

2) MS-IMM-Greedy-CPHD更新。

给定 $k$ 时刻所有传感器量测集  $Z_k^s = \{Z_k^s\}_{s=1}^S$ , 按照2.2.2节的方式进行量测划分, 可得到划分后的 $L$ 个量测子集  $\{W_{1:S}^{k,l}\}_{l=1}^L$ . 对于MS-IMM-Greedy-CPHD的更新问题, 设单个量测子集中  $Z_k^i$  的个数为 $M$ , 粒子的IMM模型更新为

$$x_{n,k|k-1}^{(i)} = \sum_{c=1}^m \sum_{j=1}^M F_{k,j}^{(c)}(x_{n,k-1|k-1}^{(j)}) \tau_{k,c}^{(i)}. \quad (37)$$

其中:  $F_{k,j}^{(c)}$ 为 $k$ 时刻模型 $c$ 的状态转移矩阵,  $\tau_{k,c}^{(i)}$ 为 $k-1$ 时刻的模型 $c$ 的匹配概率. 给定 $k$ 时刻的量测子集中的量测值为  $Z_k^{1:s}$ , 模型匹配概率  $\tau_{k,c}^{(i)}$  的一步预测更新公式为

$$\tau_{k,c}^{(i)} = (p_{k-1}^i)^T \times \left\{ \eta(:, j) \cdot \begin{bmatrix} \sum_{s=1}^S g(F_k^{(1)}(x_{n,k-1|k-1}^{(i)}|Z_k^s)) \\ \vdots \\ \sum_{s=1}^S g(F_k^{(j)}(x_{n,k-1|k-1}^{(i)}|Z_k^s)) \end{bmatrix} \right\}. \quad (38)$$

其中:  $g(\cdot|Z_k^s) = \sum_{c_s=1}^{M_s} g(\cdot|z_{s,c_s}^s)$ ,  $g(\cdot|z_{s,c_s}^s)$ 为单目标似然函数;  $\eta$ 为模型转移概率矩阵. 粒子权重的更新公式为

$$\hat{w}_k^\eta = \left[ (1 - p_D(x_{k|k-1}^\theta)) + \sum_{i=1}^{N_k} p_D(x_{k|k-1}^\theta) f_{k|k}(z_k^i|x_{k|k-1}^\theta, \tau_{k|k-1}^\theta) / \left( \lambda_k c_k(z_k^i) + \sum_{\eta=1}^{J_{k-1}+J_k} p_D(x_{k|k-1}^\theta) f_{k|k}(z_k^i|x_{k|k-1}^\theta, \tau_{k|k-1}^\theta) w_{k|k-1}^\theta \right) \right] \times w_{k|k-1}^\theta. \quad (39)$$

对粒子集合  $\{w_k^\theta/d_{k|k-1}, x_{k|k-1}^\theta, \tau_{k|k-1}^\theta\}_{\theta=1}^{J_{k-1}+J_{k|k-1}}$  进行重采样得到集合  $\{w_k^\theta/d_k, x_k^\theta, \tau_k^\theta\}_{\theta=1}^{J_k}$ , 使重采样之后的总权重保持为 $d_k$ , 重采样之后的粒子集合为  $\{w_k^\theta, x_k^\theta, \tau_k^\theta\}_{\theta=1}^{J_k}$ . 则 $k$ 时刻MS-IMM-Greedy-CPHD后验估计更新为

$$v_{k|k}(x_k|\tau_k, Z_{1:k}^{1:s}) = \sum_{\theta=1}^{J_k} w_k^\theta \delta(x_k - x_k^\theta, \tau_k - \tau_k^\theta), \quad (40)$$

$$p_{k|k}(n_k|\tau_k) = \frac{\Psi_k^0[v_{k|k-1}(x_k|\tau_k, Z_{1:k-1}^{1:s}), Z_k^{1:s}](n_k) p_{k|k-1}(n_k|\tau_k)}{\langle \Psi_k^0[v_{k|k-1}(x_k|\tau_k, Z_{1:k-1}^{1:s}), Z_k^{1:s}](n_k) p_{k|k-1}(n_k|\tau_k) \rangle}. \quad (41)$$

其中

$$\Psi_k^j[v_{k|k-1}(x_k|\tau_k, Z_{1:k-1}^{1:s}), Z_k^{1:s}](n_k) = \min(n_k, |Z_k^{1:s}|) \sum_{j=0}^{\min(n_k, |Z_k^{1:s}|)} (|Z_k^{1:s}| - j)! p_k((|Z_k^{1:s}| - j)|\tau_k) P_{j+i}^{n_k} D_{j+i}^{n_k} \quad (42)$$

$$D_{j+i}^{n_k} = \frac{(1 - p_D(x_k))^{n_k - (j+i)}}{\langle 1, v_{k|k-1}(x_k|\tau_k, Z_{1:k-1}^{1:s}) \rangle^{j+i}} \times e_j(\Xi_k(v_{k|k-1}(x_k|\tau_k, Z_{1:k-1}^{1:s}), Z_{1:k}^{1:s})). \quad (43)$$

通常每一个PHD成分在更新后需要进行重采样避免粒子退化的问题,在得到式(40)和(41)后还需要进行剪枝,保留存在强度较大的PHD成分来近似多机动目标RFS在 $k$ 时刻的后验估计。 $k$ 时刻目标的势估计可通过求取 $v_{k|k}(x_k|\tau_k, Z_{1:k}^{1:s})$ 的最大值获得,即

$$m_k = \arg \max(p_{k|k}(n_k|\tau_k = i), i = 1, 2, \dots, m). \quad (44)$$

粒子滤波实现算法流程如算法1所示。

**算法1** MS-IMM-Greedy-CPHD算法。

输入:  $\{w_{k-1|k-1}^\theta, x_{k-1|k-1}^\theta, \tau_{k-1|k-1}^\theta\}_{\theta=1}^{L_{k-1}}$ 。

预测步骤:

step 1: 模型混合。

step 1.1: 模型存活样本点的预测状态和新生样本点的预测状态为

$$\tau_{k|k-1}^\theta \pi(\cdot|\tau_{k-1}), \theta = 1, 2, \dots, L_{k-1};$$

$$\tau_{k|k-1}^\theta \vartheta_k(\cdot), \theta = L_{k-1} + 1, \dots, L_{k-1} + J_k.$$

step 1.2: 预测模型权重且进行模型混合  $\bar{w}_{k|k-1}^\theta$ ,  $\theta = 1, 2, \dots, L_{k-1} + J_k$ , 根据式(33)求得;再根据式(32)进行模型概率混合。

step 2: 计算存活粒子的预测状态和构造新生加权粒子集

$$x_{k|k-1}^\theta q(\cdot|x_{k-1}, \tau_{k|k-1}, Z_k^{1:s}), \theta = 1, 2, \dots, L_{k-1};$$

$$x_{k|k-1}^\theta \sigma(\cdot|\tau_{k|k-1}, Z_k^{1:s}), \theta = L_{k-1} + 1, \dots, L_{k-1} + J_k.$$

step 3: 预测粒子权重由式(36)求得。

更新步骤:

step 4: 量测划分与最优路径的选取。

step 4.1: 按照式(15)计算每个PHD分量的伪似然函数  $\bar{h}_{k,s}^i(z_{k,j}^s|x_{k,i}, \tau_o)$ , 并利用式(16)计算每个PHD分量的代价  $\varpi_{k,s}^{c_s}$ ;按照式(17)和(18)求每个量测子集的得分,找出得分最高的量测子集。

step 4.2: 按照式(24)和(25)对每一个分区进行计算,根据分区的计算结果进行状态的更新。

step 5: 粒子的IMM模型更新。按照式(37)进行IMM模型更新。

step 6: 粒子权重的更新。按照式(39)进行粒子权重的更新,将更新后的粒子进行重采样得到粒子集  $\{w_k^\theta, x_k^\theta, \tau_k^\theta\}_{\theta=1}^{J_k}$ , 按照式(40)和(41)对MS-IMM-Greedy-CPHD进行后验估计的更新,利用式(44)对 $k$ 时刻的目标进行势估计。

输出:  $(n_k, \{w_k^\theta, x_k^\theta, \tau_k^\theta\}_{\theta=1}^{J_k})$ 。

$k = k + 1$ , 重复step 1至step 6, 若 $k > K$ , 则结束,  $K$ 为观测时间长度。

## 4 数值实验

本章就所提出的MS-IMM-Greedy-CPHD滤波方法进行仿真,并与文献[14]中的多传感器贪婪势平衡概率假设密度(MS-Greedy-CPHD)滤波方法、迭代CPHD(IC-CPHD)滤波方法和文献[13]中的多传感器贪婪截断势平衡概率假设密度(MS-Greedy-TCPHD)滤波方法,在不同检测概率与杂波率下进行性能对比。此外,为了使仿真结果更具有说服力,本章还实现了多传感器交互式贪婪截断势平衡概率假设密度(MS-IMM-Greedy-TCPHD)滤波方法、单传感器交互式贪婪势平衡概率假设密度(SS-IMM-Greedy-CPHD)滤波方法及单传感器贪婪势平衡概率假设密度(SS-Greedy-CPHD)滤波方法,并与本文算法进行性能对比。本文采用最优子模式分配(OSPA)<sup>[22]</sup>距离作为误差度量,OSPA采用的两个参数是基数惩罚因子 $c = 100$ 和阶 $p = 1$ 。

### 4.1 仿真设置

假设目标的状态向量为 $X = [x, y, \dot{x}, \dot{y}]^T$ 。其中: $x$ 和 $y$ 表示目标的坐标, $\dot{x}$ 和 $\dot{y}$ 代表的是目标的速度。5个机动目标的运动情况如表1所示。实验中共有5个机动目标随机在 $[-2000 \text{ m}, 1500 \text{ m}] \times [0 \text{ m}, 1400 \text{ m}]$ 范围内出现。

表1 目标信息

目标	目标初始位置(m)及速度(m/s)	存活时间/s
1	[0 - 5.8857; 800 + 1.4102; 18; - 18]	5 → 70
2	[0 - 7.3806; 800 + 6.7993; - 18; 18]	15 → 95
3	[0; 800 + 1.4102; 18; - 18]	20 → 86
4	[0; 800 + 6.7993; - 18; 18]	30 → 90
5	[0 + 7.3806; 800 + 6.7993; 18; - 18]	40 → 100

图2为所有目标的真实运动轨迹,所有目标的存活概率都设置为 $p_D = 0.99$ 。

目标的状态集合为 $X_k = \{x_k^i, i = 1, 2, \dots, n_k\}$ , 第 $s$ 个传感器在 $k$ 时刻产生的量测集为 $Z_k^s = \{z_{k,c_s}^s\}_{c_s=1}^{M_k^s}$ ,  $M_k^s$ 为第 $s$ 个传感器在 $k$ 时刻产生的量测总数,则 $s$ 个传感器在 $k$ 时刻产生的所有量测可表示为 $Z_k = \{Z_k^s\}_{s=1}^S$ 。

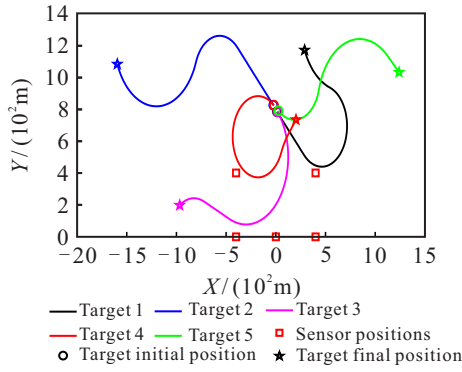


图2 目标真实运动轨迹

$$x_k = F_k x_{k-1} + v_k, \quad (45)$$

其中  $F_k$  为  $k$  时刻状态转移矩阵. 注意: 不同模型的状态转移矩阵不同. 实验中共设置 3 个状态预测模型, 模型初始概率假设相同, 都为  $1/3$ . 匀速直线 (CV) 运动模型为

$$x_k = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} x_{k-1} + v_k. \quad (46)$$

协同右转 ( $\varepsilon = -0.06 \text{ rad/s}$ ) 运动模型和协同左转 ( $\varepsilon = 0.1 \text{ rad/s}$ ) 运动模型为

$$x_k = \begin{bmatrix} 1 & 0 & \frac{\sin(\varepsilon T)}{\varepsilon} & -\frac{1 - \cos(\varepsilon T)}{\varepsilon} \\ 0 & 1 & \frac{1 - \cos(\varepsilon T)}{\varepsilon} & \frac{\sin(\varepsilon T)}{\varepsilon} \\ 0 & 0 & \cos(\varepsilon T) & -\sin(\varepsilon T) \\ 0 & 0 & \sin(\varepsilon T) & \cos(\varepsilon T) \end{bmatrix} x_{k-1} + v_k. \quad (47)$$

在模型概率预测中, 假设模型间转移是随机的且各个模型间相互转移的概率相同, 实验中初始模型转移概率矩阵设置为

$$H = \begin{bmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix}. \quad (48)$$

过程噪声  $v_k$  是服从均值为 0、协方差为  $Q$  的高斯白噪声, 与模型相互独立, 其中协方差矩阵为

$$Q = \sigma^2 \begin{bmatrix} \frac{T^3}{3} & 0 & \frac{T^2}{2} & 0 \\ 0 & \frac{T^3}{3} & 0 & \frac{T^2}{2} \\ \frac{T^2}{2} & 0 & T & 0 \\ 0 & \frac{T^2}{2} & 0 & T \end{bmatrix}. \quad (49)$$

其中  $\sigma^2 = 1 \text{ m}^2 \cdot \text{s}^{-2}$ ,  $T = 1 \text{ s}$ .

实验中共设置  $S = 5$  个传感器, 位置分别为  $[0, 0]$ ,  $[-400, 400]$ ,  $[400, 400]$ ,  $[-400, 0]$  和  $[400, 0]$ , 量纲为  $\text{m}$ . 传感器量测模型为

$$z_k^i = \begin{bmatrix} \arctan \frac{y_k^i - d_y^s}{x_k^i - d_x^s} \\ \frac{2f_c (x_k^i - d_x^s)v_{x,k}^i + (y_k^i - d_y^s)v_{y,k}^i}{c \sqrt{(x_k^i - d_x^s)^2 + (y_k^i - d_y^s)^2}} \end{bmatrix} + w_k^i. \quad (50)$$

其中:  $(d_x^s, d_y^s)$  为第  $s$  个传感器位置,  $f_c = 300 \text{ Hz}$  为接收信号载波频率;  $c = 1450 \text{ m/s}$  为光速. 所有参数服从水下场景.  $w_k^i$  服从协方差为  $\text{diag}([1 \text{ rad}^2, 0.49 \text{ Hz}^2])$  的高斯白噪声. 均值和协方差分别为

$$m^{(1)} = [0 \text{ m}, 800 \text{ m}, 0 \text{ m/s}, 0 \text{ m/s}]. \quad (51)$$

$$P^{(1)} = \text{diag}([50 \text{ m}^2, 50 \text{ m}^2, 30 \text{ m}^2/\text{s}^2, 30 \text{ m}^2/\text{s}^2]). \quad (52)$$

## 4.2 仿真实验

为了验证 MS-IMM-Greedy-CPHD 滤波器的有效性, 在传感器检测概率  $P_D = 0.5$ , 杂波数  $\lambda = 4$  时的场景下, 通过不同的滤波器进行多机动目标跟踪结果和性能对比如图 3~图 5 所示.




图3 MS-IMM-Greedy-CPHD 滤波目标跟踪




图4 MS-Greedy-CPHD 滤波目标跟踪

图 3 和图 4 分别为 MS-IMM-Greedy-CPHD 滤波器和 MS-Greedy-CPHD 滤波器<sup>[13]</sup> 对多机动目标的跟踪效果图. 由图 4 可知, 单模型下 MS-Greedy-CPHD 滤波会因为机动目标状态估计中的模型失配问题逐渐丢失目标. 通过图 3 和图 4 的对比可以看出, 本文所

提出滤波器能够解决单模型条件下的模型失配问题.

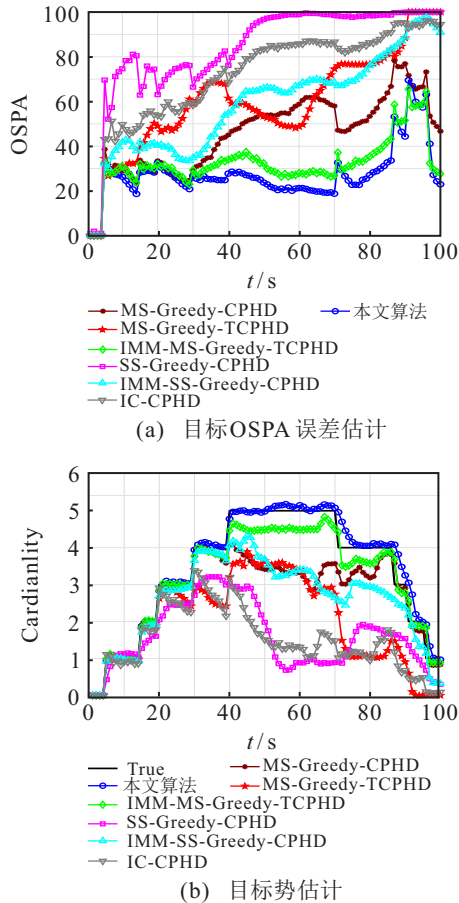


图5 不同滤波的OSPA误差估计和势估计

图5是不同滤波器对多机动目标进行100次蒙特卡洛实验的势估计与OSPA误差估计统计图. 由图5(a)对MS-Greedy-CPHD滤波与IC-CPHD滤波进行对比可以看出: MS-Greedy-CPHD滤波的OSPA误差更小, 说明了贪婪量测划分机制在多传感器条件下是有效的; 相较于单模型下MS-Greedy-CPHD滤波, 本文所提出滤波器则能够有效解决单模型下因模型失配造成的OSPA误差过大的问题. 由表1可知, 不同的目标是在不同的时刻出现和消失, 这是OSPA出现峰值的原因. 由图5(b)不同滤波的势估计对比可以看出: 本文算法的势估计几乎能够与真实的目标个数重合, 相较于其他方法对多机动目标的跟踪更有效. 综上可知, 本文所提出算法的稳定性与有效性得到了提升. OSPA误差较其他算法较小, 势估计更加准确. 不同滤波方法的单次蒙特卡洛运行平均时间如表2所示.

由表2可知: IC-CPHD滤波器的运行时间最短, 但由图5可知该算法的OSPA误差大, 势估计不准确; MS-Greedy-CPHD滤波通过贪婪量测划分机制进行最优量测挑选, 能减小OSPA误差且势估计与IC-CPHD滤波器相比更准确, 但是计算时间相对较

表2 单次蒙特卡洛平均运行时间

方法	时间/s
IC-CPHD	34.725 8
MS-Greedy-CPHD	124.176 8
MS-Greedy-TCPHD	59.561 2
MS-IMM-Greedy-CPHD	202.848 1
MS-IMM-Greedy-TCPHD	145.049 7

长; 而本文算法在MS-Greedy-CPHD滤波基础上针对机动目标进行交互式计算, 时间上略有增加, 但能进一步提高跟踪性能, 且算法的有效性与稳定性得到了较大的提高. 在此基础上, 对本文所提出算法进行截断操作时能降低计算时间, 但由图5可知在滤波过程中进行了截断操作会导致跟踪性能下降.

图6是在传感器检测概率 $P_D = 0.5$ 的不同检测概率下的MS-IMM-Greedy-CPHD滤波对多机动目标进行100次蒙特卡洛实验的势估计与OSPA误差估计. 由图6可知, 本文所提出滤波器在不同检测概率下都能够有效地实现对多机动目标的势估计, 当目标新生和死亡时, 在目标出现和消失的时刻所提滤波器都会出现OSPA距离误差峰值.

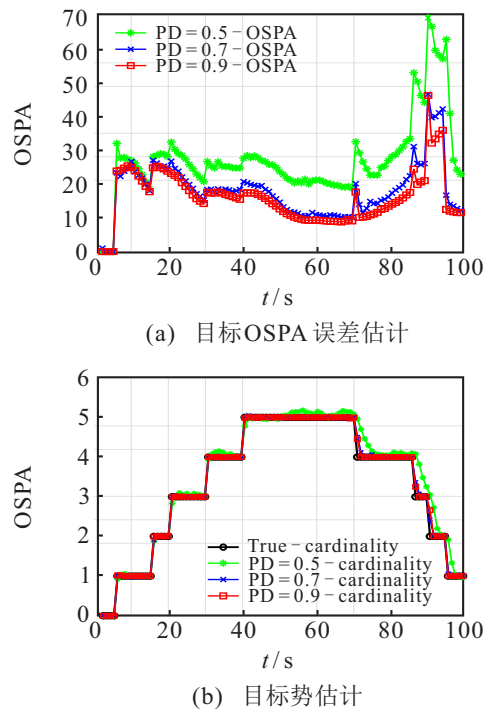


图6 不同检测概率下OSPA误差估计和势估计

为了进一步验证算法性能, 对不同检测概率下的100次蒙特卡洛实验进行时间平均OSPA (TOSPA) 误差统计和跟踪收敛成功概率 (probability of convergence, PROC) 实验. 其中PROC定义为: 算法的OSPA均不大于阈值 $T_s$ 的实验次数在所进行的实验总数中的百分比, 即

$$\text{PROC} = \frac{1}{\text{MK}} \sum_{m=1}^{\text{MK}} S_m \times 100\% \quad (53)$$

其中: MK 为实验总数;  $S_m = \begin{cases} 1, & \text{OSPA} < T_s; \\ 0, & \text{otherwise.} \end{cases}$

不同检测概率下 100 次蒙特卡洛实验的 TOSPA 和 PROC 统计结果如图 7 所示。

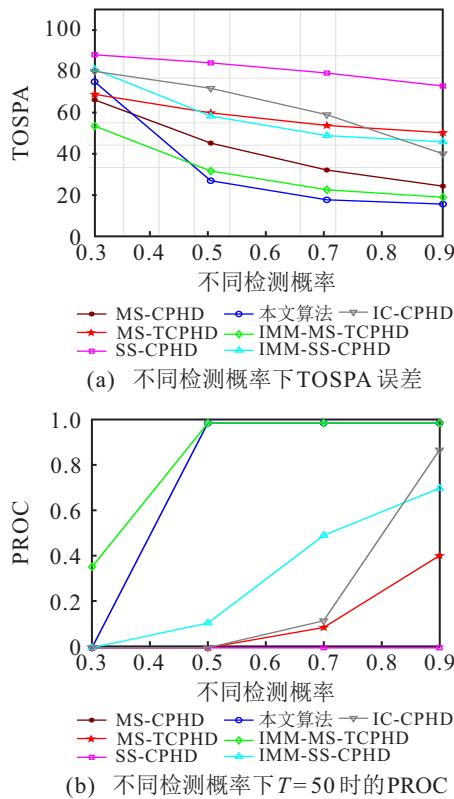


图 7 TOSPA 和 PROC 随检测概率变化

图 7(a) 为不同检测概率下不同的滤波对多机动目标进行 100 次蒙特卡洛实验的 TOSPA 误差估计图。可以看出, 本文算法在检测概率达到 0.5 时 TOSPA 误差趋于平缓, 保持在 20~30 左右, 相对于其他算法 OSPA 误差较小。图 7(b) 为不同检测概率下不同的滤波对多机动目标进行 100 次蒙特卡洛实验的 PROC。针对不同滤波器而言, 检测概率越高, 各算法的跟踪收敛成功概率越高, 本文所提出算法在检测概率为 0.5 时跟踪收敛成功率已达到 1, 相对于其他方法跟踪收敛成功概率更大。由图 7 可知, 所提出算法在稳定性与收敛性能方面都优于其他对比算法, 能有效进行多目标跟踪。

## 5 结论

针对多传感器高速多机动目标的情况, 提出一种 MS-IMM-Greedy-CPHD 滤波器, 采用交互式多模 (IMM) 算法对 CPHD 滤波中目标的状态、势分布和运动模型同时进行预测, 利用贪婪量测划分机制在更新

阶段对量测进行量测子集的划分与路径的选取后得到最优的路径, 利用最优路径中的量测对目标采用交互式更新对目标状态、势分布和运动模型进行更新, 从而解决多传感器低检测概率下高速多机动目标跟踪问题。仿真实验验证了在低检测概率的条件下, 所提出滤波器对多机动目标的势分布和状态进行稳定有效的跟踪, 且相较于传统 MS-CPHD 滤波器, 该滤波器解决了高速多机动目标由速度过高导致目标跟踪不上的问题。MS-IMM-Greedy-CPHD 滤波器跟踪的 OSPA 误差更小以及势估计更加准确, 极大地提高了多传感器多机动目标算法的运算效率。将所提出算法扩展到多伯努利滤波中以及对滤波进行前向后向平滑是未来需要考虑的工作。

## 参考文献 (References)

- [1] Blackman S S. Multiple hypothesis tracking for multiple target tracking[J]. IEEE Aerospace and Electronic Systems Magazine, 2004, 19(1): 5-18.
- [2] Hoffmann C, Dang T. Cheap joint probabilistic data association filters in an interacting multiple model design[J]. Robotics and Autonomous Systems, 2009, 57(3): 268-278.
- [3] Mahler R P S. Statistical multisource-multitarget information fusion[M]. Boston: House, Inc., 2007: 483-655.
- [4] Xiong J, Li F M, Liu J. Fusion of different height pyroelectric infrared sensors for person identification[J]. IEEE Sensors Journal, 2016, 16(2): 436-446.
- [5] Chang K C, Bar-Shalom Y. Joint probabilistic data association for multitarget tracking with possibly unresolved measurements and maneuvers[J]. IEEE Transactions on Automatic Control, 1984, 29(7): 585-594.
- [6] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091-4104.
- [7] Mahler R, El-Fallah A. CPHD and PHD filters for unknown backgrounds, part III: Tractable multitarget filtering in dynamic clutter[J]. Proceedings of SPIE-The International Society for Optical Engineering, 2010, 7698: 1-12.
- [8] Vo B T, Vo B N, Cantoni A. Analytic implementations of the cardinalized probability hypothesis density filter[J]. IEEE Transactions on Signal Processing, 2007, 55(7): 3553-3567.
- [9] Delande E, Duflos E, Vanheeghe P, et al. Multi-sensor PHD: Construction and implementation by space partitioning[C]. 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).

- Prague, 2011: 3632-3635.
- [10] 杨金龙, 刘风梅, 王冬, 等. 基于近邻传播聚类的多扩展目标量测集划分算法[J]. 雷达学报, 2015, 4(4): 82-89.  
(Yang J L, Liu F M, Wang D, et al. Multi-target measurement set partition algorithm based on nearest neighbor propagation clustering[J]. Journal of Radars, 2015, 4(4): 82-89.)
- [11] Qi H, Li J, Di X, et al. Improved  $K$ -means clustering algorithm and its applications[J]. Recent Patents on Engineering, 2019, 13(4): 403-409.
- [12] 章涛, 吴仁彪. 近邻传播观测聚类的多扩展目标跟踪算法[J]. 控制与决策, 2016, 31(4): 764-768.  
(Zhang T, Wu R B. Multi-extended target tracking algorithm based on nearest neighbor propagation observation clustering[J]. Control and Decision, 2016, 31(4): 764-768.)
- [13] Saucan A A, Coates M, Rabbat M. A multi-sensor multi-bernoulli filter[J]. IEEE Transactions on Signal Processing, 2017, 65(20): 5495-5509.
- [14] Nannuru S, Blouin S, Coates M, et al. Multisensor CPHD filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2016, 52(4): 1834-1854.
- [15] Liu L, Ji H, Fan Z. A cardinality modified product multi-sensor PHD[J]. Information Fusion, 2016, 31: 87-99.
- [16] Nagappa S, Kadar I, Clark D E. On the ordering of the sensors in the iterated-corrector probability hypothesis density (PHD) filter[J]. Proceedings of SPIE-The International Society for Optical Engineering, 2011, 8050: 1-8.
- [17] Tian Y, Jiang H, Ding Q X, et al. Turn rate estimation based adaptive IMM algorithm for maneuvering target tracking[J]. Advanced Materials Research, 2012, 1518: 5609-5614.
- [18] 李刚, 熊思宇, 陈峰, 等. 基于IMM-CPHD的主被动雷达多目标跟踪方法[C]. OSEC首届兵器工程大会论文集. 重庆, 2017: 848-854.  
(Li G, Xiong S Y, Chen F, et al. Active and passive radar multi-target tracking method based on IMM-CPHD[C]. Proceedings of OSEC 1st Ordnance Engineering Conference. Chongqing: Ordnance Equipment Engineering Journal, 2017: 848-854.)
- [19] Li X R, Jilkov V P. Survey of maneuvering target tracking, Part Va: Multiple-model methods[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(4): 1255-1321.
- [20] 秦岭, 黄心汉. 自适应目标新生强度的SMC-PHD/CPHD滤波[J]. 控制与决策, 2016, 31(8): 1461-1467.  
(Qin L, Huang X H. SMC-PHD/CPHD filter with adaptive target freshness intensity[J]. Control and Decision, 2016, 31(8): 1461-1467.)
- [21] Mahler R, Hall D, Llinas J. Random set theory for target tracking and identification[M]. Boca Raton: Data Fusion Hand Book, 2001: 14.
- [22] 刘伟峰, 文成林. 基于OSPA距离的航迹关联方法[J]. 航空学报, 2012, 33(6): 1083-1092.  
(Liu W F, Wen C L. Track correlation method based on OSPA distance[J]. Acta Aeronautica Sinica, 2012, 33(6): 1083-1092.)

### 作者简介

蔡如华(1971—), 男, 副教授, 从事小波分析、信号处理等研究, E-mail: ruhuac@guet.edu.cn;

樊向婷(1994—), 女, 硕士生, 从事多传感器信息融合、信号处理的研究, E-mail: 1948985528@qq.com;

吴孙勇(1981—), 男, 教授, 博士, 从事多目标检测与跟踪、阵列信号处理等研究, E-mail: wusunyong121991@163.com;

王力(1995—), 男, 硕士生, 从事多传感器信息融合、信号处理的研究, E-mail: 1581960594@qq.com;

伍雯雯(1999—), 女, 本科生, 从事信息与计算科学的研究, E-mail: 710367492@qq.com.

(责任编辑: 孙艺红)