

基于多目标 MS-OSPA 下界的 分散式传感器选择

连峰^{1,2}, 张修立¹, 魏博¹, 侯利明¹, 韩崇昭¹, 王伟^{2,3}

(1. 西安交通大学电子与信息工程学院, 陕西西安 710049; 2. 陕西省组合与智能导航重点实验室, 陕西西安 710068;
3. 中国电子科技集团公司第二十研究所, 陕西西安 710068)

摘要: 本文提出了一种分散式大规模多目标跟踪网络的传感器选择优化算法. 该方法以多目标状态集和估计集间的均方最优子模式分配误差下界作为优化目标函数, 根据加权 Kullback-Leibler 平均 (Kullback-Leibler average, KLA) 准则对局部多目标密度进行融合, 最终采用坐标下降法来折中计算代价和跟踪精度. 仿真实验在不同信噪比场景下验证了本方法的有效性.

关键词: 传感器选择; 多目标跟踪; 标签随机有限集; 分散式传感器网络

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2019)10-2158-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.10.018

Decentralized Sensor Selection Based on Multi-Target MS-OSPA Lower Bound

LIAN Feng^{1,2}, ZHANG Xiu-li¹, WEI Bo¹, HOU Li-ming¹, HAN Chong-zhao¹, WANG Wei^{2,3}

(1. School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an, Shaanxi 710049, China;

2. Shaanxi Key Laboratory of Integrated and Intelligent Navigation, Xi'an, Shaanxi 710068, China;

3. The 20th Research Institute of China Electronics Technology Corporation, Xi'an, Shaanxi 710068, China)

Abstract: A sensor selection optimization algorithm is proposed for decentralized large-scale multi-target tracking network. In this method, the lower bound of mean square optimal sub-pattern assignment error between multi-target state set and its estimation is taken as optimized objective function while the rule of weighted Kullback-Leibler average (KLA) is used to fuse local multi-target densities. The coordinate descent method is proposed to compromise the computation cost and tracking accuracy. Simulations verify the effectiveness of our method under different signal-to-noise ratio scenarios.

Key words: sensor selection; multi-target tracking; labeled random finite set; decentralized sensor network

1 引言

近几年, 如何利用随机有限集 (Random finite set, RFS)^[1] 在多目标跟踪 (Multi-target tracking, MTT) 的同时对一个或几个可移动传感器进行位置控制^[2-5] 成为一个新的研究热点. 本文提出了一种针对分散式大规模 MTT 网络的传感器选择优化算法. 该算法采用加权 Kullback-Leibler 平均 (Kullback-Leibler average, KLA) 准则^[6] 对局部多目标密度进行融合. 算法的传感器选择步以多目标状态集和估计集间的均方最优子模式分配 (Mean square optimal sub-pattern assignment, MS-OS-

PA)^[7] 误差下界作为优化目标函数. 由于传感器选择优化步的计算量随传感器个数呈组合爆炸式增长. 因此本文建议采用坐标下降^[8] 法来折中计算代价和跟踪精度. 最终仿真结果表明, 当该网络中的传感器存在观测性能差异时, 本方法的跟踪精度在不同 SNR 场景下均明显优于以 Cauchy-Schwarz (CS) 散度^[4]、Poisson 近似 CS 散度以及势和状态的后验期望误差 (Posterior expected error of cardinality and state, PEECS)^[5] 作为优化目标函数的传感器选择算法. 并且相比遗传算法, 坐标下降法能显著缩短传感器选择的计算时间, 尽管它的跟踪精度略有损失.

2 数学基础

2.1 标签 RFS 和 Mδ-GLMB

为便于区分,用斜体表示未加标签的量(例如将传统的状态矢量、测量矢量和相应集合记为 x, z, X 和 Z)而粗正体表示带标签的量(例如将标签状态矢量和其集合记为 $\mathbf{x} = (x, \ell)$ 和 \mathbf{X} , 其中 ℓ 为离散标签量). 记 $\ell(\mathbf{X})$ 、 $|\mathbf{X}|$ 和 $\mathbb{X} \times \mathbb{L}$ 分别表示 \mathbf{X} 的标签集、势和所在空间, 其中 \mathbb{X} 和 \mathbb{L} 分别为状态矢量空间和离散标签空间. 令 $\delta_Y(X)$ 、 $1_Y(X)$ 和 p^X 分别表示广义 Kronecker 函数、包含指示函数和多目标指数函数,

$$\delta_Y(X) = \begin{cases} 1, & \text{if } X = Y \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

$$1_Y(X) = \begin{cases} 1, & \text{if } X \subseteq Y \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

$$p^X = \begin{cases} \prod_{x \in X} p(x), & X \neq \emptyset \\ 1, & X = \emptyset \end{cases} \quad (3)$$

通常将 $1_Y(\{x\})$ 简写为 $1_Y(x)$.

对于 \mathbf{X} 的任意实数值函数 $b(\mathbf{X})$, 它的集合积分定义为

$$\int b(\mathbf{X}) \delta \mathbf{X} = \sum_{n=0}^{\infty} \frac{1}{n!} \sum_{\ell_{1:n} \in L_n} \int_{X_n} b(\mathbf{X}_n) dx_{1:n} \quad (4)$$

上式中 $x_{1:n} = x_1, \dots, x_n$ 和 $\ell_{1:n} = \ell_1, \dots, \ell_n$, $\mathbf{X}_n = \{x_{1:n}\}$ 表示 n 元素集, X_n 和 L_n 分别为 X_n 和 $\ell_{1:n}$ 所在空间.

若 \mathbf{X} 为一个 Mδ-GLMB RFS, 其密度满足^[6,9]

$$\pi(\mathbf{X}) = \Delta(\mathbf{X}) \sum_{I \in \mathcal{T}(\mathbb{L})} \delta_I(\mathcal{L}(\mathbf{X})) \omega_I p_I^{\mathbf{X}} \quad (5)$$

上式中 $\Delta(\mathbf{X}) = \delta_{|\mathbf{X}|}(|\mathcal{L}(\mathbf{X})|)$ 表示标签区别指示器, $I \in \mathcal{T}(\mathbb{L})$ 表示航迹标签集, $\mathcal{T}(\mathbb{L})$ 表示 \mathbb{L} 内的有限个子集构成的集合, 权重 ω_I 表示 I 的概率, $p_I(\mathbf{x})$ 表示 I 中 \mathbf{x} 的密度. Mδ-GLMB 密度可简记为 $\pi = \{(\omega_I, p_I)\}_{I \in \mathcal{T}(\mathbb{L})}$. 它的势分布为

$$P(|\mathbf{X}| = n) = \sum_{I \in \mathcal{T}(\mathbb{L})} \omega_I \quad (6)$$

上式中 $\mathcal{T}_n(\mathbb{L})$ 表示由 \mathbb{L} 内的有限个 n 元素子集构成的集合.

3 问题描述

将当前时刻的多目标状态集建模为标签 RFS. 单目标状态 $\mathbf{x} = (x, \ell) \in \mathbf{X}$ 的存活概率和转移密度分别为 $p_s(x, \ell)$ 和 $f(x, \ell | x', \ell') \delta_{\ell'}(\ell)$. 多目标状态集的转移密度记为 $f(\mathbf{X} | \mathbf{X}')$. 此处 $\mathbf{x}' = (x', \ell')$ 和 \mathbf{X}' 分别表示前一刻的状态和状态集.

采用图 1 所示的分散式传感器网络对目标观测. 该网络由传感器节点 (Sensor node, SN) 和局部融合中心 (Local fusion center, LFC) 组成. 每个 SN 获得测量并与上级 LFC 通讯. 每个 LFC 负责接收下属 SN 的测量. 数据处理与存储、与相连 LFC 通讯以及对下属 SN 进行管理.

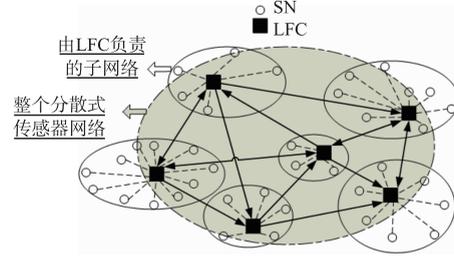


图1 分散式传感器网络示意图
(○和■分别表示SN和LFC, 带箭头实线表示LFC间的有向连接, 虚线表示LFC和其所负责的SN的连接)

该网络结构可用拓扑图 $G = \{N, C, A\}$ 描述, 其中 C 为 LFC 索引集; $A \subseteq C \times C$ 为 LFC 的有向连接集. 若第 $j \in C$ 个 LFC 可收到第 $i \in C$ 个 LFC 的数据, 则 $(i, j) \in A$. 令 $C^j = \{i \in C: (i, j) \in A\}$ 表示第 $j \in C$ 个 LFC 能够收到数据的相连 LFC 集 (包括它本身). N 为 SN 索引集, N^j 为受控于第 j 个 LFC 的 SN 集.

对于单个 SN $s \in N$, 它可能收到杂波和目标测量或发生漏检, 可将其测量集 Z^s 建模为空间 Z^s 上的 RFS. 记它的单个测量矢量为 $z^s \in Z^s$, 杂波为泊松 RFS, 其强度为

$$\kappa^s(z^s) = \lambda^s f_\kappa^s(z^s) \quad (7)$$

其中 λ^s 和 $f_\kappa^s(z^s)$ 分别为杂波率和杂波空间密度.

给定多目标状态集 \mathbf{X} , 可得多目标似然函数为

$$g^s(Z^s | \mathbf{X}) = e^{-\lambda^s [\kappa^s]^{Z^s}} \sum_{\theta^s \in \Theta^s(\mathbf{X})} [\psi_{Z^s}^s(\cdot; \theta^s)]^{\mathbf{X}} \quad (8)$$

其中

$$\psi_{Z^s}^s(\mathbf{x}; \theta^s) = \begin{cases} \frac{p_D^s(\mathbf{x}) g^s(z_{\theta^s}^s | \mathbf{x})}{\kappa^s(z_{\theta^s}^s)}, & \text{if } \theta^s > 0 \\ 1 - p_D^s(\mathbf{x}), & \text{if } \theta^s = 0 \end{cases} \quad (9)$$

上两式中 $p_D^s(\mathbf{x})$ 和 $g^s(z^s | \mathbf{x})$ 分别为单目标检测概率和似然函数, Θ^s 表示由关联映射 $\theta^s: I \rightarrow \{0, 1, \dots, |Z^s|\}$ 构成的集合, $I \subseteq \ell(\mathbf{X})$ 为航迹标签集. $\theta^s > 0$ 或 $\theta^s = 0$ 表示第 s 个 SN 的航迹 $\ell \in I$ 产生了第 $\theta^s \in \{1, \dots, |Z^s|\}$ 个测量 $z_{\theta^s}^s \in Z^s$ 或被漏检.

对于第 $j \in C$ 个 LFC, 由于受条件限制每次只能开启 N^j 内的部分 SN 采集目标测量. 算法 1 给出了 Bayes 框架下该 LFC 的执行步骤.

算法 1 第 $j \in C$ 个 LFC 的 SN 选择及 MTT 执行流程

1. 预测: 根据上一时刻融合后的密度 $\bar{\pi}^j(\mathbf{X}')$ 计算当前预测密度为 $\pi^j(\mathbf{X}) = \int f(\mathbf{X} | \mathbf{X}') \bar{\pi}^j(\mathbf{X}') \delta \mathbf{X}'$.

2. SN 选择: 从 SN 集 N^j 中选择子集 $S^j \subseteq N^j$ 并获得测量集 Z^{S^j} , 其中 Z^{S^j} 表示由 SN 子集 S^j 收到的累积测量.

3. 更新: 计算当前后验密度为 $\pi^j(\mathbf{X} | Z^{S^j}) = \frac{\prod_{s \in S^j} g^s(Z^s | \mathbf{X}) \pi^j(\mathbf{X})}{\int \prod_{s \in S^j} g^s(Z^s | \mathbf{X}) \pi^j(\mathbf{X}) \delta \mathbf{X}}$, 并将其传递给与之相连的 LFC.

4. 融合:收到 LFC 集 C^j 的后验密度后利用加权 KLA 准则计算融合密

度为 $\bar{\pi}^j(X) = \frac{\prod_{i \in C^j} [\pi^i(X|Z^S)]^{v^i}}{\prod_{i \in C^j} [\pi^i(X|Z^S)]^{v^i} \delta X}$, 其中 $v^i (i \in C^j)$ 为预先设定

的归一化权重.

5. 状态提取:从 $\bar{\pi}^j(X)$ 提取当前时刻的状态估计集 \hat{X}_n^j 作为输出. 转第 1 步.

给定第 $j \in C$ 个 LFC 和其下属的 SN 集 N^j , 传感器选择是指在一定约束条件下通过选择合适的 SN 子集 $S^j \subseteq N^j$ 使得目标函数达到最优, 即:

$$\begin{aligned} [S^j]^* &= \operatorname{argmin}_{S^j \subseteq N^j} / \max \vartheta^j(S^j; \pi_+^j) \\ \text{s. t. } &\begin{cases} \gamma_i^j(S^j; \pi_+^j) \geq 0 & i = 1, \dots, l \\ \nu_k^j(S^j; \pi_+^j) = 0 & k = 1, \dots, m \end{cases} \end{aligned} \quad (10)$$

式中 $\vartheta^j(S^j; \pi_+^j)$, $\gamma_i^j(S^j; \pi_+^j) \geq 0$ 和 $\nu_k^j(S^j; \pi_+^j) = 0$ 分别表示给定 $\pi_+^j(X)$ 时关于 S^j 的优化目标函数、不等式约束和等式约束.

本文可将式(10)中的目标函数 $\vartheta^j(S^j; \pi_+^j)$ 、不等式约束 $\gamma_i^j(S^j; \pi_+^j)$ 和等式约束 $\nu_k^j(S^j; \pi_+^j)$ 分别建模如下:

1) 目标函数建模:若第 $j \in C$ 个 LFC 的 SN 开启集为 S^j , 其多目标 Bayes 估计的 2 阶 MS-OSPA 误差 $[\sigma_{S^j}^j]^2$ 为

$$\begin{aligned} [\sigma_{S^j}^j]^2 &= E[d_c^2(X, \hat{X}^j)] \\ &= \int_{\mathbb{Z}^{S^j}} \int_{\mathbb{X} \times \mathbb{L}} f(X, Z^{S^j}) d_c^2(X, \hat{X}^j) |\delta X \delta Z^{S^j}| \\ &= \int_{\mathbb{Z}^{S^j}} \int_{\mathbb{X} \times \mathbb{L}} \prod_{s \in S^j} g^s(Z^s | X) \pi_+^j(X) d_c^2(X, \hat{X}^j) \delta X \delta Z^{S^j} \end{aligned} \quad (11)$$

上式中 \mathbb{Z}^{S^j} 为 SN 集 S^j 的联合测量空间, $f(X, Z^{S^j})$ 表示 (X, Z^{S^j}) 的联合密度, $d_c(X, \hat{X}^j)$ 表示 X 和 \hat{X}^j 的 2 阶 OSPA 误差距离.

我们将式(10)中的优化目标函数选为多目标状态估计的 2 阶 MS-OSPA 下界, 即

$$\vartheta^j(S^j; \pi_+^j) = [\sigma_{S^j}^j]^2, j \in C \quad (12)$$

2) 等式和不等式约束建模:记 u^s 为第 s 个 SN 的位置矢量.

等式约束 1:假设第 j 个 LFC 每次只能开启 K^j 个 SN, 即

$$\nu_1^j(S^j; \pi_+^j) = K^j - |S^j| = 0, j \in C \quad (13)$$

等式约束 2:记第 s 个 SN 的 FoV 为区域 \mathcal{A} 内以它所处位置 u^s 为中心 ρ^s 为半径的圆形区域 $\mathcal{A}^s(\rho^s) = \{p^s \in \mathcal{A}: \|p^s - u^s\| \leq \rho^s\}$, $\mathcal{A}^s \subseteq \mathcal{A}$. 为了保证每个 LFC 所选择的 SN 集的 FoV 能够对区域 \mathcal{A} 全覆盖, 要求

$$\nu_2^j(S^j; \pi_+^j) = \mathcal{A} - \bigcup_{s \in S^j} \mathcal{A}^s(\rho^s) = 0, j \in C \quad (14)$$

不等式约束 1:令所选择的 SN 两两之间距离需大

于门限 D^j , 即

$$\gamma_i^j(S^j; \pi_+^j) = \min_{s, s' \in S^j} \|u^s - u^{s'}\| - D^j \geq 0, j \in C \quad (15)$$

最终可得本文传感器选择优化的具体形式为

$$\begin{aligned} [S^j]^* &= \operatorname{argmin}_{S^j \subseteq N^j} [\sigma_{S^j}^j]^2 \\ \text{s. t. } &\begin{cases} K^j - |S^j| = 0 \\ \mathcal{A} - \bigcup_{s \in S^j} \mathcal{A}^s(\rho^s) = 0 \\ \min_{s, s' \in S^j} \|u^s - u^{s'}\| - D^j \geq 0 \end{cases}, j \in C \end{aligned} \quad (16)$$

4 MS-OSPA 下界及次优算法

4.1 MS-OSPA 下界

在 4.1 和 4.2 节中暂时将 LFC 的索引上标 'j' 省略. 例如 $[\sigma_{S^j}^j]^2$ 可简记为 $\sigma_{S^j}^2$.

为了得到 $\sigma_{S^j}^2$, 需要给定如下 2 点假设:

A1:多目标 Bayes 递推为一个边缘 δ -广义标签多伯努利 (Marginalized δ -generalized labeled multi-Bernoulli, M δ -GLMB) 滤波器^[9].

A2:最大后验 (Maximum a posterior, MAP) 和无偏估计准则.

给定 SN 集 S , MAP 检测准则判定 $|X| = \hat{n}$ ($\hat{n} = 0, 1, \dots, \infty$) 当且仅当 $Z^S \subseteq \mathbb{Z}_n^S$,

$$\mathbb{Z}_n^S = \left\{ Z^S \subseteq \mathbb{Z}^S : \hat{n} = \operatorname{argmax}_n (P(|X| = n | Z^S)) \right\} \quad (17)$$

其中 $\mathbb{Z}_n^S = \mathbb{Z}_n^{s_1} \times \dots \times \mathbb{Z}_n^{s_{|S|}}$ 表示目标个数估计为 \hat{n} 时 SN 集 S 的联合测量子空间, $\mathbb{Z}_0^S, \mathbb{Z}_1^S, \dots, \mathbb{Z}_\infty^S$ 为 \mathbb{Z}^S 的划分.

根据假设 A1、式(6)和 M δ -GLMB 的更新步可得

$$P(|X| = n | Z^S) = \sum_{l \in \mathcal{V}_n(\mathbb{L})} \omega_l(Z^S) \quad (18)$$

其中

$$\begin{aligned} \omega_l(Z^S) &= \frac{\omega_{l,+} \langle p_{l,+}(\cdot, \ell), \prod_{s \in S} \psi_{Z^s}^s(\cdot, \ell; \theta^s) \rangle^l}{\sum_{\theta^s \in \Theta^s} \sum_{J \in \mathcal{V}(\mathbb{L})} \sum_{\theta^s \in \Theta^s} \omega_{J,+} \langle p_{J,+}(\cdot, \ell), \prod_{s \in S} \psi_{Z^s}^s(\cdot, \ell; \theta^s) \rangle^J} \end{aligned} \quad (19)$$

表示给定测量集 Z^S 时标签集为 l 的后验概率, $\theta^s \in \Theta^s$ 表示 $\theta^{s_1} \in \Theta^{s_1}, \dots, \theta^{s_{|S|}} \in \Theta^{s_{|S|}}$!

令 $q(X_n, Z_{n,m}^S)$ 表示空间 $(\mathbb{X} \times \mathbb{L})_n \times \mathbb{Z}_{n,m}^S$ 上的联合密度, 根据 Bayes 公式可得

$$q(X_n, Z_{n,m}^S) = \frac{1}{\Omega_{n,m^s}} \prod_{s \in S} g^s(Z_{n,m}^s | X_n) \pi_+(X_n) \quad (20)$$

其中 Ω_{n,m^s} 为归一化因子,

$$\Omega_{n,m^s} = \sum_{\ell_{1:n} \in \mathbb{L}_n} \int_{\mathbb{Z}_{n,m}^S} \prod_{s \in S} g^s(Z_{n,m}^s | X_n) \pi_+(X_n) dx_{1:n} dz_{1:n}^S \quad (21)$$

上式中 $\int_{\mathbf{z}_n^s} \cdot d\mathbf{z}_{1:m^s}^s = \int_{\mathbf{z}_{n-1}^s} \cdots \int_{\mathbf{z}_n^s} \cdot d\mathbf{z}_{1:m^s}^s \cdots d\mathbf{z}_{1:m^s}^s \cdots$

令 $\varpi_{\hat{n},n,m^s}$ 为 $q(\mathbf{X}_n, Z_m^s)$ 在空间 $(\mathbb{X} \times \mathbb{L})_n \times \mathbb{Z}_{\hat{n},m^s}^s$ 上的积分,根据式(20)可得

$$\begin{aligned} \varpi_{\hat{n},n,m^s} &= \sum_{\ell_{1:n} \in \mathcal{L}_n} \int_{\mathbf{z}_{1:n}^s} \int_{\mathbf{X}_n} q(\mathbf{X}_n, Z_m^s) d\mathbf{x}_{1:n} d\mathbf{z}_{1:m^s}^s \\ &= \frac{1}{\Omega_{n,m^s}} \sum_{\ell_{1:n} \in \mathcal{L}_n} \int_{\mathbf{z}_{1:n}^s} \int_{\mathbf{X}_n} \prod_{s \in S} g^s(Z_m^s | \mathbf{X}_n) \pi_+(\mathbf{X}_n) d\mathbf{x}_{1:n} d\mathbf{z}_{1:m^s}^s \end{aligned} \quad (22)$$

将假设 A1 和式(8)带入式(21)和(22)并根据文献[10]的引理 12,最终可得 Ω_{n,m^s} 和 $\varpi_{\hat{n},n,m^s}$ 为

$$\Omega_{n,m^s} = n! e^{-\sum_{s \in S} \lambda^s} \prod_{s \in S} [\lambda^s]^{m^s} \quad (23)$$

$$\begin{aligned} &\cdot \sum_{l \in \mathcal{T}(\mathbb{L})} \omega_{l,+} \sum_{\theta^s \in \Theta_l^s} \langle p_{l,+}(\cdot, \ell), \prod_{s \in S} \xi^s(\cdot, \ell; \theta^s) \rangle^l \\ \varpi_{\hat{n},n,m^s} &= \frac{n! e^{-\sum_{s \in S} \lambda^s}}{\Omega_{n,m^s}} \left(\prod_{s \in S} [\alpha_n^s \lambda^s]^{m^s} \right) \end{aligned} \quad (24)$$

$$\cdot \sum_{l \in \mathcal{T}(\mathbb{L})} \omega_{l,+} \sum_{\theta^s \in \Theta_l^s} \langle p_{l,+}(\cdot, \ell), \prod_{s \in S} \varphi_n^s(\cdot, \ell; \theta^s) \rangle^l$$

其中,

$$\zeta^s(\mathbf{x}; \theta^s) = \begin{cases} \frac{p_D^s(\mathbf{x})}{\lambda^s}, & \text{if } \theta_\ell^s > 0 \\ 1 - p_D^s(\mathbf{x}), & \text{if } \theta_\ell^s = 0 \end{cases} \quad (25)$$

$$\varphi_n^s(\mathbf{x}; \theta^s) = \begin{cases} \frac{\beta_n^s p_D^s(\mathbf{x})}{\alpha_n^s \lambda^s}, & \text{if } \theta_\ell^s > 0 \\ 1 - p_D^s(\mathbf{x}), & \text{if } \theta_\ell^s = 0 \end{cases} \quad (26)$$

$$\alpha_n^s = \int_{\mathbf{z}_{n-1}^s} f_\kappa^s(\mathbf{z}^s) d\mathbf{z}^s \quad (27)$$

$$\beta_n^s = \int_{\mathbf{z}_{n-1}^s} g^s(\mathbf{z}^s | \mathbf{x}) d\mathbf{z}^s \quad (28)$$

既然 $q(\mathbf{X}_n, Z_m^s)$ 关于 $\mathbf{x}_{1:n}$ 排序不变,那么它对于 $\mathbf{x}_{1:n}$ 中任意变量的边缘密度均相同,记为

$$q_n(\mathbf{x}, Z_m^s) = \int_{\mathbf{X}_{n-1}} q(\{\mathbf{x}, \mathbf{x}_{2:n}\}, Z_m^s) d\mathbf{x}_{2:n} \quad (29)$$

将式(20)带入式(29),再根据假设 A1 和恒等式 $\delta_n(\{l, \ell_{2:n}\}) = \delta_{n-1}(\{l, \ell_{2:n}\}) (1 - 1_{|\ell_{2:n}|}(\ell))$, $q_n(\mathbf{x}, Z_m^s)$ 可写为式(30),假设 SN 子集 $Y \subseteq S$ 收到了目标 \mathbf{x} 的观测,将式(8)带入式(30)并化简后可得式(31),式(31)中 $S - Y$ 表示子集 Y 在全集 S 中的补集.

$$\begin{aligned} q_n(\mathbf{x}, Z_m^s) &= \frac{1}{\Omega_{n,m^s} \prod_{\ell_{2:n} \in \mathcal{L}_{n-1}} \delta_{n-1}(\{l, \ell_{2:n}\})} \\ &(1 - 1_{|\ell_{2:n}|}(\ell)) \sum_{l \in \mathcal{T}(\mathbb{L})} \omega_{l,+} \delta_l(\{l, \ell_{2:n}\}) \\ &\cdot \int_{\mathbf{X}_{n-1}} \prod_{s \in S} g^s(Z_m^s | \{\mathbf{x}, \mathbf{x}_{2:n}\}) p_{l,+}(\mathbf{x}) \prod_{i=2}^n p_{l,+}(\mathbf{x}_i) d\mathbf{x}_{2:n} \end{aligned} \quad (30)$$

$$\begin{aligned} q_n(\mathbf{x}, Z_m^s) &= \frac{1}{\Omega_{n,m^s}} e^{-\sum_{s \in S} \lambda^s} \prod_{s \in S} [\kappa^s]^{Z^s} \\ &\sum_{l \in \mathcal{T}(\mathbb{L})} 1_l(\ell) \omega_{l,+} p_{l,+}(\mathbf{x}) \sum_{\theta^s \in \Theta_{l,+}^s} \sum_{Y \subseteq S} \sum_{z^s \in Z_{n-1}^s} \prod_{s \in Y} p_D^s(\mathbf{x}) g^s(\mathbf{z}^s | \mathbf{x}) \\ &\cdot \prod_{s' \in (S-Y)} (1 - p_D^{s'}(\mathbf{x})) \langle p_{l,+}(\cdot, \ell), \\ &\prod_{s \in Y} \psi_{Z_{n-1}^s}^s(\cdot, \ell; \theta^s) \cdot \prod_{s' \in (S-Y)} \psi_{Z_{n-1}^{s'}}^{s'}(\cdot, \ell; \theta^{s'}) \rangle^{l-|\ell|} \end{aligned} \quad (31)$$

定理 1 给定假设 A1、A2 以及 SN 集 S ,式(11)所示的 MS-OSPA 的下界为式(32). 式(32)中 $\varepsilon_{\hat{n},n} = \min(\hat{n}, n) / \max(\hat{n}, n)$, $J_{\hat{n},n,m^s}$ 为给定 $(|\hat{\mathbf{X}}| = \hat{n}, |\mathbf{X}| = n, |Z^s| = m^s)$ 时的 $L \times L$ 维 FIM;

$$\begin{aligned} \sigma_S^2 &= \sum_{m^s=0}^{\infty} \sum_{n=0}^{\infty} \sum_{\hat{n}=0, n+\hat{n}>0}^{\infty} \frac{\Omega_{n,m^s} \varpi_{\hat{n},n,m^s}}{m^s! n!} \\ &\left[\varepsilon_{\hat{n},n} \min\left(c^2, \frac{1}{\varpi_{\hat{n},n,m^s}} \sum_{l=1}^L [J_{\hat{n},n,m^s}^{-1}]^{l,l}\right) + (1 - \varepsilon_{\hat{n},n}) c^2 \right] \end{aligned} \quad (32)$$

$$\begin{aligned} [J_{\hat{n},n,m^s}]^{i,j} &= -\frac{1}{\varpi_{\hat{n},n,m^s}^2} \int_{\mathbf{z}_{n-1}^s} \int_{\mathbf{X}_1} q_n(\mathbf{x}, Z_m^s) \\ &\frac{\partial^2 \log q_n(\mathbf{x}, Z_m^s)}{\partial x^i \partial x^j} d\mathbf{x} d\mathbf{z}_{1:m^s}^s \quad i, j = 1, \dots, L \end{aligned} \quad (33)$$

$q_n(\mathbf{x}, Z_m^s)$ 为式(31)的无标签版,即

$$q_n(\mathbf{x}, Z_m^s) = \sum_{\ell \in \mathcal{L}_1} q_n(\mathbf{x}, \ell, Z_m^s) \quad (34)$$

说明 1:目标和测量的最大个数通常可由先验知识设定.

说明 2:由式(24)和(33)可知 $\varpi_{\hat{n},n,m^s}$ 和 $J_{\hat{n},n,m^s}$ 的计算公式中包含测量子空间 $\mathbb{Z}_{\hat{n},m^s}^s$ 上的积分且没有解析表达式,故需要利用数值积分法先对 $\mathbb{Z}_{\hat{n},m^s}^s$ 内的点进行采样再计算获得.

4.2 基于坐标下降的次优化算法

如式(10)和(16)所示,传感器选择实际上是一个有约束的组合优化问题.若采用穷尽搜索法求其最优解则需要对目标函数进行 $C_{|N|}^{|S|} = \frac{|N|!}{|S|! (|N| - |S|)!}$ 次重复计算.针对此问题,本文建议采用坐标下降法^[8]来寻找式(16)的次优解.

对每个 SN 设定一个二进制的标识量 $\tau^s \in \{0, 1\}$, $s = 1, \dots, |N|$. $\tau^s = 1$ 表示该 SN 被选中,即 $s \in S$;反之, $\tau^s = 0$ 表示该 SN 未被选中,即 $s \notin S$. 令矢量 $\boldsymbol{\tau} = [\tau^1, \dots, \tau^{|N|}]$ 表示该 LFC 所有 SN 的标识量. 集合 S 显然可由 $\boldsymbol{\tau}$ 完全确定. 通过用 $\boldsymbol{\tau}$ 代替集合 S 构造如下的增广目标函数可将式(16)松弛为无约束优化问题,

$$F(\boldsymbol{\tau}, r) = \underline{\sigma}_{\boldsymbol{\tau}}^2 + r \sum_{i=1}^I \gamma_i^{-1}(\boldsymbol{\tau}) + \frac{1}{\sqrt{r}} \sum_{j=1}^m \nu_j^2(\boldsymbol{\tau}) \quad (35)$$

负责观测的分散式传感器网络由 $|C| = 8$ 个 LFC 构成, 记为 LFC1 ~ LFC8. 它们位置矢量(单位为 km)依次为 $[10, 40]^T$, $[25, 40]^T$, $[40, 40]^T$, $[40, 25]^T$, $[40, 10]^T$, $[25, 10]^T$, $[10, 10]^T$, $[10, 25]^T$. 每个 LFC 负责 $|N^j| = 50$ 个 SN ($j = 1, \dots, 8$), 总计 $|N| = 400$ 个 SN. 每个 LFC 可与其相距 25km 内的其它 LFC 相互通信. 最终, LFC 的有向连接集 A 和 SN 位置如图 2 所示:

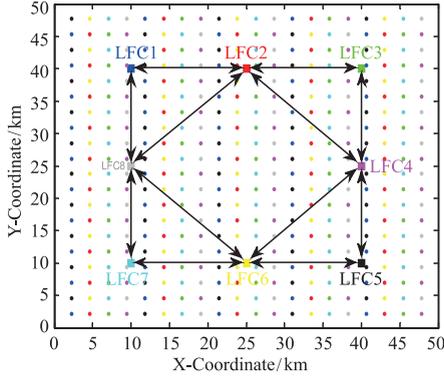


图2 分散式传感器网络LFC和SN位置分布图。■表示LFC, ●表示SN, 不同的颜色分别对应于不同的LFC和其所负责的SN. 有向箭头表示LFC间的通讯连接. 每个SN相距为2.4km

SN 的单目标似然函数为如下高斯形式

$$g^s(z^s | x, \ell) = N(z^s; h^s(x), R^s(x)) \quad s = 1, \dots, 400 \quad (45)$$

上式中 $h^s(x)$ 和 $R^s(x)$ 分别为观测函数和观测噪声协方差矩阵, 两者均依赖于目标运动状态 x .

杂波为区域 \mathcal{A} 内均匀分布的泊松 RFS. 本例先令每个 SN 的杂波率为 $\lambda^s = \lambda = 20$, 检测概率为 $p_d^s(x) = p_d = 0.95, s = 1, \dots, 400$.

该网络由不同类型的 SN 组成. 令 LFC1 和 LFC5 的每个 SN 可获得目标距离和角度测量, 其 $h^s(x)$ 为

$$h^s(x) = \left[\|x - u^s\|, \arctan \frac{p_y - u_y^s}{p_x - u_x^s} \right]^T, s \in N^1 \text{ 或 } s \in N^5 \quad (46)$$

其中 $u^s = [u_x^s, u_y^s]^T$ 为第 s 个 SN 的位置, $\|x - u^s\| = \sqrt{(p_x - u_x^s)^2 + (p_y - u_y^s)^2}$ 为该 SN 与目标的距离, $R^s(x)$ 为式(47).

$$R^s(x) = \begin{cases} \text{diag}(\left([0.2 + 0.05 \|x - u^s\| \text{ km}\right]^2, \left([0.02 + 0.001 \|x - u^s\| \text{ rad}\right]^2)) & s \in N^1 \\ \text{diag}(\left([0.4 + 0.04 \|x - u^s\| \text{ km}\right]^2, \left(0.04 + 0.0005 \|x - u^s\| \text{ rad}\right)^2) & s \in N^5 \end{cases} \quad (47)$$

LFC2 和 LFC6 的每个 SN 只能获得目标距离测量, 其 $h^s(x)$ 和 $R^s(x)$ 为

$$h^s(x) = \|x - u^s\|, s \in N^2 \text{ 或 } s \in N^6 \quad (48)$$

$$R^s(x) = \begin{cases} \left([0.1 + 0.02 \|x - u^s\| \text{ km}\right]^2 & s \in N^2 \\ \left([0.2 + 0.01 \|x - u^s\| \text{ km}\right]^2 & s \in N^6 \end{cases} \quad (49)$$

LFC3 和 LFC7 的每个 SN 只能获得目标角度测量, 其 $h^s(x)$ 和 $R^s(x)$ 为

$$h^s(x) = \arctan \frac{p_y - u_y^s}{p_x - u_x^s}, s \in N^3 \text{ 或 } s \in N^7 \quad (50)$$

$$R^s(x) = \begin{cases} \left([0.01 + 0.001 \|x - u^s\| \text{ rad}\right]^2 & s \in N^3 \\ \left([0.02 + 0.0005 \|x - u^s\| \text{ rad}\right]^2 & s \in N^7 \end{cases} \quad (51)$$

LFC4 和 LFC8 的每个 SN 可获得目标距离和多普勒测量, 其 $h^s(x)$ 和 $R^s(x)$ 为式(52)和式(53)

$$h^s(x) = \left[\|x - u^s\|, \frac{(p_x - u_x^s)\dot{p}_x + (p_y - u_y^s)\dot{p}_y}{\|x - u^s\|} \right]^T, s \in N^4 \text{ 或 } s \in N^8 \quad (52)$$

$$R^s(x) = \begin{cases} \text{diag}(\left([0.2 + 0.05 \|x - u^s\| \text{ km}\right]^2, \left([0.02 + 0.001 \|x - u^s\| \text{ km/s}\right]^2)) & s \in N^4 \\ \text{diag}(\left([0.4 + 0.04 \|x - u^s\| \text{ km}\right]^2, \left([0.04 + 0.0005 \|x - u^s\| \text{ km/s}\right]^2)) & s \in N^8 \end{cases} \quad (53)$$

每个 LFC 选定的最优 SN 集由式(16)得到. 在本例中, 对于式(13)所示的个数约束, 令若 $j = 1, 4, 5, 8$, 则 $K^j = 5$; 否则 $K^j = 8$. 对于式(14)所示的观测范围约束, 令若 $j = 1, 4, 5, 8$, 则该 LFC 的 SN 观测半径为 $\rho^s = 30\text{km}$; 否则 $\rho^s = 20\text{km}$. 对于式(15)所示的干扰约束, 令门限 $D^j = 5\text{km}, j = 1, \dots, 8$.

采用粒子滤波器执行本算法并用 MATLAB R2018a 编程实现. 平均用 500 个粒子近似每个 M δ -GLMB RFS 的航迹密度 $p_t(\cdot, \ell)$. 本例中设每帧最大目标数为 25, 每个 SN 每帧最大测量数为 200, OSPA 截断距离 $c = 1000\text{m}$. 我们进行了 500 次 MC 仿真, 每次仿真均为 $T = 25$ 帧共计 250s, 其中目标航迹(包括出生和终止时刻)、杂波和目标测量均按照前述模型独立产生.

首先展示单次仿真中的 MS-OSPA 下界 + 坐标下降法的传感器选择效果. 图 3 为该次仿真中目标运动轨迹.

图 4(a) ~ 4(f) 依次展示了 MS-OSPA 下界 + 坐标下降法在第 1、5、10、15、20 和 25 帧时的传感器选择效果. 可以看出, 随着时间的推移, 各个 LFC 所选择的 SN 会随着多目标运动而进行自适应的改变. 具体来说, 为了使得 MS-OSPA 下界最小, 它们均能够始终保持每个时刻所选择的 SN 大部分位于较为接近存活目标的区域.

下面在相同测试平台下将其与其它 5 种传感器选择算法进行比较:

方法 1: 即上述 MS-OSPA 下界 + 坐标下降法.

方法 2: MS-OSPA 下界 + 遗传算法. 在遗传算法中,

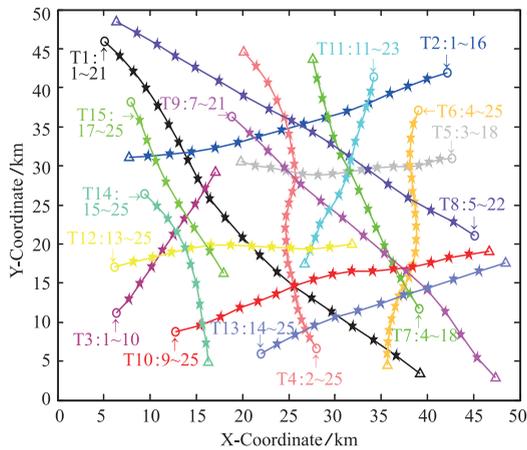


图3 单次仿真中目标运动轨迹。
○、△和★分别表示目标的起点、终点和其余时刻所处位置，
实线表示运动轨迹，不同颜色对应于不同目标

设种群规模为 50, 交叉率为 0.9, 变异率为 0.001, 精英率为 0.04, 每帧迭代次数最多 500 次.

- 方法 3: CS 散度 + 遗传算法.
- 方法 4: 随机选择法.
- 方法 5: Poisson 近似 CS 散度 + 遗传算法.
- 方法 6: PEECS^[5] + 遗传算法.

图 5 展示了 6 种方法经 500 次 MC 平均后得到的多目标位置估计的 OSPA 误差随时间变化曲线. 此处的 OSPA 误差选为所有 LFC 的平均值.

从图 5 可以看出, 采用 6 种方法多目标位置估计的平均 OSPA 误差均随时间下降, 其中基于 CS 散度和 PEECS 的三种方法 OSPA 误差相接近, 它们明显小于随机选择法的 OSPA 误差; 基于 MS-OSPA 下界的两种方法 OSPA 误差相接近, 它们又明显小于其它方法的 OSPA 误差. 这说明相比随机选择法, 其余 5 种算法均能通过传感器的选择优化来不同程度地提高最终的 MTT 精度. 显然, 基于 MS-OSPA 下界的传感器选择算法的提高幅度优于基于 CS 散度和 PEECS 的传感器选择算法. 造成这一结果的原因有如下 3 点.

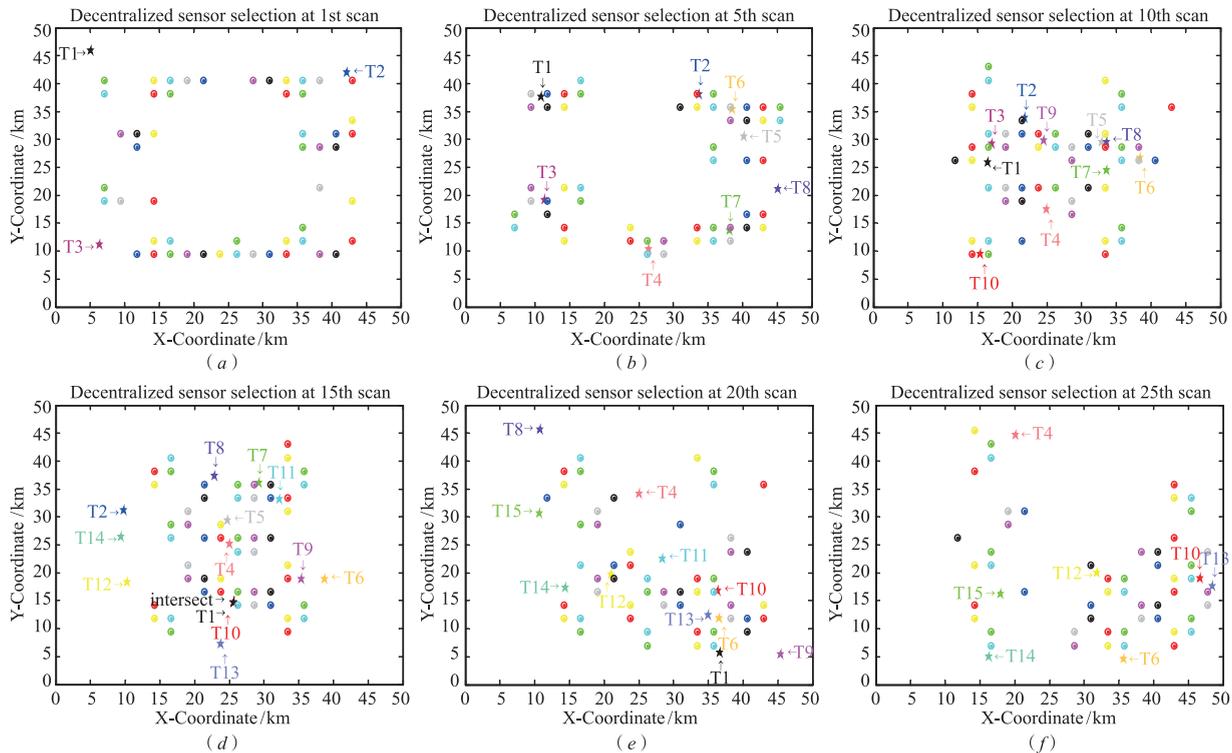


图4 MS-OSPA下界+坐标下降法的传感器选择效果。(a)第1帧;(b)第5帧;(c)第10帧;(d)第15帧;(e)第20帧;(f)第25帧。
★和○分别表示当前时刻的目标和所选择的SN, 不同颜色对应于不同目标以及不同LFC所负责的SN

- 1) MS-OSPA 下界具有更加明确的物理含义, 它反映了通过传感器选择所能达到的最优 MTT 精度.
- 2) 在 KLA 融合步, MS-OSPA 下界法的融合权重可通过式(41)设定; 而 CS 散度法、Poisson 近似 CS 散度法以及 PEECS 法的融合权重没有任何设定依据, 只能按惯例将其设为相同^[7]. 本例中由于不同 LFC 的 SN 测量精度存在较大差异, 导致它们的跟踪精度显然有好有

坏. 若不区分地将权重均设为相同, 显然会造成融合效率的下降.

- 3) 在传感器选择优化步, 坐标下降法可能陷入局部极值, 而遗传算法能够凭借自身的随机性在一定程度上跳出局部极值, 增加了收敛到全局最优点的可能性. 故坐标下降法的 MTT 精度略逊于遗传算法.

我们采用平均每帧所耗费的 CPU 时间来比较上述

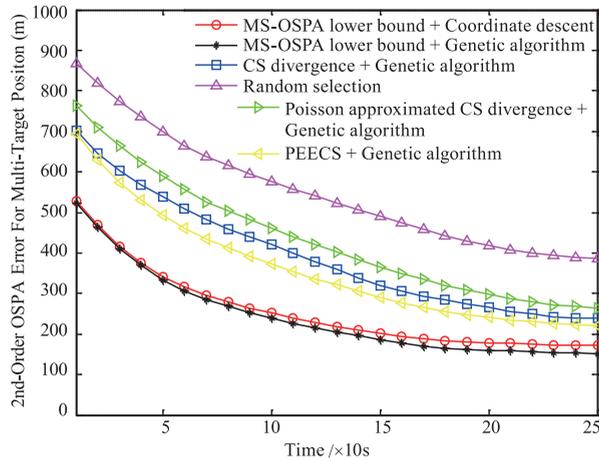


图5 多目标位置估计的平均OSPA误差,其中截断距离 $c=1000\text{m}$

算法在传感器选择步的计算代价。MS-OSPA 下界 + 坐标下降法、MS-OSPA 下界 + 遗传算法、CS 散度 + 遗传算法、Poisson 近似 CS 散度 + 遗传算法和 PEECS + 遗传算法的平均每帧 CPU 耗时分别为 0.62s、6.18s、5.69s、4.63s 和 5.05s。随机选择法由于没有优化步,自然不存在该部分的耗时。由此可见,尽管坐标下降法相比遗传算法跟踪精度略有下降,但是它能够显著缩短传感器选择优化步的计算时间。

6 结论

针对分散式大规模 MTT 网络的传感器选择问题,本文提出了一种以 MS-OSPA 下界为代价函数的传感器选择优化算法。仿真结果表明对于由不同观测性能传感器组成的大规模分散式网络,本方法的 MTT 跟踪精度明显优于以 CS 散度、Poisson 近似 CS 散度和 PEECS 作为优化目标函数的传感器选择算法。

参考文献

- [1] MAHLER R P S. Advances in Statistical Multisource Multitarget Information Fusion[M]. US: Artech House, 2014.
- [2] RISTIC B, VO B N. Sensor control for multi-object state-space estimation using random finite sets[J]. Automatica, 2010, 46(11): 1812–1818.
- [3] GOSTAR A K, HOSEINNEZHAD R, et al. Multi-bernoulli sensor control via minimization of expected estimation errors[J]. IEEE Transactions on Aerospace and Electronic Systems, 2015, 51(3): 1762–1773.

- [4] JIANG M, YI W, KONG L. Multi-sensor control for multi-target tracking using Cauchy-Schwarz divergence [A]. 2016 19th International Conference on Information Fusion (FUSION) [C]. Heidelberg, Germany: IEEE, 2016. 2059–2066.
- [5] WANG X, HOSEINNEZHAD R, GOSTAR A K, et al. Multi-sensor control for multi object Bayes filters[J]. Signal Processing, 2018, 142: 260–270.
- [6] FANTACCI C, VO B N, VO B T, et al. Consensus labeled random finite set filtering for distributed multi-object tracking[J]. arXiv preprint, 2015, arXiv: 1501.01579.
- [7] SCHUHMACHER D, VO B T, VO B N. A consistent metric for performance evaluation of multi-object filters[J]. IEEE Transactions on Signal Processing, 2008, 56(8): 3447–3457.
- [8] WRIGHT S J. Coordinate descent algorithms[J]. Mathematical Programming, 2015, 151(1): 3–34.
- [9] FANTACCI C, PAPI F. Scalable multisensor multitarget tracking using the marginalized-GLMB density[J]. IEEE Signal Processing Letters, 2016, 23(6): 863–867.
- [10] VO B T, VO B N. Labeled random finite sets and multi-object conjugate priors[J]. IEEE Transactions on Signal Processing, 2013, 61(13): 3460–3475.

作者简介



连 峰 (通信作者) 男, 1981 年 9 月出生, 陕西宝鸡人, 西安交通大学电子与信息工程学院综合自动化研究所教授。主要研究方向为目标跟踪、信息融合与传感器管理。
E-mail: lianfeng1981@xjtu.edu.cn



张修立 男, 1992 年 7 月出生, 湖北天门人, 西安交通大学电子与信息工程学院硕士研究生, 研究方向为信息融合与传感器管理。