

多目标跟踪中多传感器分布式控制策略

陈 辉^{1†}, 邓东明¹, 韩崇昭²

(1. 兰州理工大学 电气工程与信息工程学院, 甘肃 兰州 730050;

2. 西安交通大学 电子与信息工程学院 综合自动化研究所, 陕西 西安 710049)

摘要: 分布式传感器网络技术在复杂的多目标跟踪系统中发挥了极其重要的作用. 本文针对多传感器多目标跟踪中的分布式传感器控制问题, 提出了基于信息论的多传感器控制策略. 首先, 本文利用随机有限集(RFS)建模, 给出了多传感器多伯努利滤波器, 并通过一组参数化的多伯努利过程来近似多传感器多伯努利密度. 进一步的, 通过多伯努利滤波器的序贯蒙特卡罗实现, 设计采样方案对多伯努利密度进行粒子采样, 用一组带有权值的粒子集近似多目标状态空间分布. 随后, 借助巴氏距离(Bhattacharyya distance)作为传感器控制的评价函数用于多个传感器的独立并行控制方案的决策制定. 作为另外一个重要内容, 本文提出了一种基于多目标战术重要性评估的多传感器控制策略. 该控制方案旨在评估多目标战术重要性的基础上对威胁度最大的目标进行优先跟踪. 最后, 仿真实验验证了所提算法的有效性.

关键词: 多目标跟踪; 多传感器控制; 分布式融合; 信息增益; 战术重要性评估

引用格式: 陈辉, 邓东明, 韩崇昭. 多目标跟踪中多传感器分布式控制策略. 控制理论与应用, 2019, 36(10): 1585 – 1598

DOI: 10.7641/CTA.2019.80715

Multi-sensor distributed control strategy for multi-target tracking

CHEN Hui^{1†}, DENG Dong-ming¹, HAN Chong-zhao²

(1. School of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou Gansu 730050, China;

2. Institute of Integrated Automation, School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an Shaanxi 710049, China)

Abstract: Distributed sensor network technology plays an extremely important role in complex multi-target tracking system. Aiming at distributed sensor control problem in multi-sensor multi-target tracking, this paper proposes some multi-sensor control strategies information-based. First, a multi-sensor multi-Bernoulli filter is presented by using random finite set (RFS), and a multi-sensor multi-Bernoulli density is approximated by a set of parameterized multi-Bernoulli process. Further, through the sequential Monte Carlo implementation of the multi-Bernoulli filter, the sampling scheme is designed to sample the multi-Bernoulli density, and then the multi-target state space distribution is approximated by a set of weighted particles. Subsequently, the Bhattacharyya distance, as the reward function, is used for the decision making of independent and parallel multi-sensor control. As another important part, this paper proposes a multi-sensor control strategy based on multi-target tactical significance assessment, where the goal is to evaluate multi-target tactical significance and then track preferentially the maximum threat target. Finally, the simulations verify the effectiveness of the proposed algorithms.

Key words: multi-target tracking; multi-sensor control; distributed fusion; information gain; tactical significance assessment

Citation: CHEN Hui, DENG Dongming, HAN Chongzhao. Multi-sensor distributed control strategy for multi-target tracking. *Control Theory & Applications*, 2019, 36(10): 1585 – 1598

1 引言

传感器网络在过去的十多年间受到了极大的关注, 这要归功于它在诸如移动传感器网络、车载网络、通信网络等领域的成功应用^[1-5]. 其中, 多目标跟踪是传感器网络最常见的应用之一, 包括军事背景中的战场

监视和敌方目标跟踪, 以及民用领域中的环境观测和交通监控等. 然而, 在许多实际应用中, 由于通信(带宽)和计算(例如数据存储)条件限制, 在目标跟踪过程的每个时间步骤中, 传感器网络仅允许有限的传感器采取相应的动作. 在这种情况下, 多传感器控制实际

收稿日期: 2018-09-09; 录用日期: 2019-01-21.

[†]通信作者. E-mail: huich78@hotmail.com.

本文责任编辑: 潘泉.

国家自然科学基金项目(61873116, 61763029), 国防基础科研项目(JCKY2018427C002), 甘肃省科技计划项目(18JR3RA137)资助.

Supported by the National Natural Science Foundation of China (61873116, 61763029), the National Defense Basic Research Project of China (JCKY2018427C002) and the Gansu Provincial Science and Technology Planning of China (18JR3RA137).

上是找到一个控制命令集合的最优子集,从而利用有限的计算和通信资源来最大化接收多目标信息^[6].一般而言,多传感器控制包含两个基础分量:多目标滤波过程与与之相结合的最佳方案决策过程.多目标滤波过程与多目标滤波器紧密相关.滤波器的性能通常会对整体方案的估计精度和鲁棒性产生重要影响.而最佳方案决策过程实际上是基于特定目标函数的优化过程.

近些年来,基于随机有限集(random finite set, RFS)^[7-8]的多目标跟踪方法备受关注,这要归功于点过程理论(point process theory)的拓展应用.该方法将多目标状态和多目标量测建模为有限集值.同时通过引入有限集统计(finite set statistics, FISST)理论^[7-8],将杂波环境下的多目标状态估计问题描述为贝叶斯滤波问题,从而避免了传统跟踪算法中较难处理的数据关联问题.为简化在多目标状态空间上直接求解多目标贝叶斯滤波器的复杂度,Mahler和Vo等提出了一系列最优近似多目标滤波器^[9-15],包括矩递推滤波器^[9-12]和多伯努利滤波器^[13-15].特别地,势均衡多目标多伯努利^[14](cardinality balanced multi-target multi-Bernoulli, CBMe-BMer)滤波器作为MeMBer的改进版本,在概念上不同于概率假设密度(probability hypothesis density, PHD)滤波器和势概率假设密度(cardinalized probability hypothesis density, CPHD)滤波器.它并没有“压缩”状态信息利用相关统计特性去近似多目标密度,而是通过传递一组相互独立且数量固定的伯努利参数来直接近似多目标密度.显然,CBMe-BMer这种天生优势将为多传感器控制问题中目标函数的求解提供极大的方便.

多传感器控制的另一个重要组成部分是最佳控制方案决策过程.而大多数方案的决策都是通过设计目标函数来进行传感器最优决策.通常,目标函数可以分为两类:基于信息驱动和基于任务驱动.基于信息驱动的目标函数通常以信息散度来作为目标依据,目的是使得基于传感器控制所获取的多目标信息增益最大化.基于信息驱动的传感器控制策略因其可以兼顾多个任务指标的竞争优化而广受关注.在近些年来,比较典型的基于信息驱动的信息散度通常有Cauchy-Schwarz距离^[16]、Kullback-Leibler距离^[17-18]以及更一般的Rényi距离^[19-21]等.此外,基于任务驱动的目标函数旨在某个单一准则下基于某个特殊任务对潜在的传感器方案进行决策,包括目标势估计方差^[22]、状态和势估计误差的后验期望(posterior expected error of cardinality and states, PEECS)^[23-24]、最优子模式分配(optimal sub-pattern assignment, OSPA)距离^[25]、目标势的后验期望(posterior expected number of targets, PENT)^[26]等.这类传感器控制策略通常在

某些特殊环境下能够发挥重要作用.

在实际应用中,多目标跟踪环境通常十分复杂,多目标跨区域运动范围较大,而且受限于传感器的性能,单传感器控制系统往往无法胜任对多目标跟踪估计的要求.此时,利用多传感器去拓展跟踪系统的监控区域,提升跟踪系统的灵活性、稳健性和容错性是非常有必要的.如前所述,多传感器控制的核心是在控制命令集合中找到一个最优子集.因此,多传感器控制本质上又是一个高维优化问题,这使得多传感器控制策略的求解异常复杂.在基于FISST的传感器控制的研究中,很多的研究成果针对的都是单传感器控制问题.近几年,一些学者也开始利用FISST去求解多传感器控制问题,并给出了一些基于任务驱动的多传感器控制方法^[27-28].本文基于信息驱动的方法,在部分可观测马尔科夫决策过程(partially observable Markov decision processes, POMDPs)^[27,29]理论框架下,基于多伯努利滤波器提出了相应的多传感器控制策略.该策略通过对多个传感器独立并行控制,有效化解了高维优化求解难题,在保证多目标估计精度的同时提高了计算效率.首先,本文利用多传感器多目标RFS建模,给出了多传感器多伯努利滤波器,并通过一组参数化的多伯努利过程来近似多传感器多伯努利密度.其次,通过多伯努利滤波器的序贯蒙特卡罗实现,设计采样方案对多伯努利密度进行粒子采样,其目的在于用一组带有权值的粒子集近似多目标状态空间分布.随后,借助巴氏距离(Bhattacharyya distance)^[30]作为传感器控制的评价函数用于多个传感器的独立并行控制方案的决策制定.作为另外一个重要内容,本文提出了一种基于多目标战术重要性评估的多传感器控制策略.该控制方案旨在评估多目标战术重要性的基础上对威胁度最大的目标进行优先跟踪.最后,仿真实验验证了所提算法的有效性.

2 问题描述

2.1 多传感器多目标随机有限集建模

多传感器多目标跟踪问题可以利用RFS进行建模.假定 k 时刻在目标状态空间 $\mathcal{X} \subseteq \mathbb{R}^{n_x}$ 中存在 $N_x(k)$ 个目标,状态分别 $\mathbf{x}_{1,k}, \dots, \mathbf{x}_{N_x(k),k}$,目标状态维数为 n_x .则 k 时刻多目标状态集合为 $X_k = \{\mathbf{x}_{1,k}, \dots, \mathbf{x}_{N_x(k),k}\} \in \mathcal{F}(\mathcal{X})$,其中 $\mathcal{F}(\mathcal{X})$ 表示状态空间 $\mathcal{X}$ 所有有限子集的集合.假设 $k-1$ 时刻目标 $\mathbf{x}_{k-1} \in X_{k-1}$ 以存活概率 $p_{S,k}(\mathbf{x}_{k-1})$ 继续存活在 k 时刻.若不考虑衍生目标,则此时多目标状态集 X_k 可建模为

$$X_k = \left[\bigcup_{\mathbf{x}_{k-1} \in X_{k-1}} S_{k|k-1}(\mathbf{x}_{k-1}) \right] \cup \Gamma_k, \quad (1)$$

其中: $S_{k|k-1}(\mathbf{x}_{k-1})$ 是从 $k-1$ 时刻到 k 时刻存活目标状态的RFS, Γ_k 为 k 时刻新生目标状态的RFS.

类似地, 假设 k 时刻传感器 i 接收到 $M_{z^i}(k)$ 个量测, 在量测空间 $\mathcal{Z} \subseteq \mathbb{R}^{n_z}$ 中取值分别为 $z_{1,k}^i, \dots, z_{M_{z^i}(k),k}^i$, n_z 为传感器量测维数. 则 k 时刻传感器 i 接收到的多目标量测集合为 $Z_k^i = \{z_{1,k}^i, \dots, z_{M_{z^i}(k),k}^i\} \in \mathcal{F}(\mathcal{Z})$, 其中 $\mathcal{F}(\mathcal{Z})$ 表示目标量测空间 $\mathcal{Z}$ 所有有限子集的集合. 假设 k 时刻目标 $\mathbf{x}_k \in X_k$ 以检测概率 $p_{D,k}^{(i)}(\mathbf{x}_k)$ 被传感器 i 检测, 则此时对应的量测也为RFS, 可表示为 $\Theta_k^i(\mathbf{x}_k)$. 若考虑杂波的影响, 则 k 时刻传感器 i 接收到的多目标量测集 Z_k^i 可建模为

$$Z_k^i = \left[\bigcup_{\mathbf{x}_k \in X_k} \Theta_k^i(\mathbf{x}_k) \right] \cup K_k^i, \quad (2)$$

其中 K_k^i 表示 k 时刻第 i 个传感器的杂波过程, 它是一个泊松RFS, 其强度函数为 $\kappa_k(\cdot)$.

假设共有 N 个传感器, 则 k 时刻多传感器多目标量测可描述为

$$Z_k = [Z_k^1 \ Z_k^2 \ \dots \ Z_k^N], \quad (3)$$

Z_k 包含了多传感器接收到的所有的特征信息, 例如量测噪声、传感器探测距离、杂波等.

2.2 多目标跟踪中的多传感器控制方法

多目标跟踪中基于信息论的多传感器控制通常是在部分可观测马尔科夫决策过程POMDP的理论框架下进行. POMDP是马尔科夫决策过程的推广形式, 其通常包括3个要素: 表征多目标状态信息的概率密度函数, 一个可允许控制的多传感器控制集合和目标函数. 具体来讲, FISST理论框架下的多目标状态信息可用 k 时刻多目标后验概率密度 $p_{k|k}(X_k|Z_{1:k})$ 来描述. 用 U_k^N 表示 k 时刻可允许的多传感器控制集合, 每一个多传感器控制矢量 $\nu = (\nu_1, \dots, \nu_N) \in U_k^N$ 决定下一时刻 N 个传感器的位置. 则多传感器控制问题在六维离散POMDP框架下可描述为

$$\Psi = \{\mathcal{X}, U^N, f(\cdot|\cdot), \mathcal{Z}, g(\cdot|\cdot, \nu), \mathcal{R}(\nu)\}, \quad (4)$$

其中: $f(\cdot|\cdot)$ 表示目标状态转移函数, $g(\cdot|\cdot, \nu)$ 是与控制 ν 相关的似然函数; $\mathcal{R}(\nu)$ 表示多传感器控制目标函数, 旨在找到一个最优控制 $u = (\nu_1^*, \dots, \nu_N^*)$, 使得 k 时刻最优控制矢量

$$u_k = \arg \min_{\nu \in U_k^N} / \max E [\mathcal{R}(\nu; p_{k|k}(X_k|Z_{1:k}), u_{0:k-1}); Z_{k+1}(\nu)]. \quad (5)$$

式(5)中的目标函数针对不同的控制优化目的可取最大化(例如选散度, 表明信息增益最大化), 亦可取最小化(例如目标状态估计的误差). 此外, 值得注意的是, $\mathcal{R}(\nu, p, Z)$ 通常由未来量测集 Z 决定. 一般可由量测方程计算得到. 但这种方法往往会给传感器的求解带来极大的计算负担. 比较常用且实际的做法是在不考虑杂波、噪声且检测概率 $p_{D,k} = 1$ 的情况下, 对每一个控制 ν 产生一个预测理想量测集(predicted ideal measurement set, PIMS)^[22-24], 进而用PIMS代替实际量测来进行传感器控制的求解.

3 多传感器多伯努利滤波器

多传感器多目标跟踪通常由多个单传感器多目标系统的后验分布融合而成. 即每个传感器独立运行多目标贝叶斯滤波器, 随后对所有后验分布进行分布式融合. 通常, 融合方法依赖于特定的滤波器, 与滤波器的实现方式密切相关. CBMeMBer作为一种常见的RFS滤波器, 在概念上完全不同于PHD和CPHD. 它并没有“压缩”状态信息, 进而用统计特性去近似多目标密度, 而是通过传递一组相互独立且数量固定的伯努利参数来直接近似多目标密度. 此外, 值得注意的是, CBMeMBer本质上是一个多目标贝叶斯滤波器. 对于这类滤波器的多传感器融合, Mahler已证明给出多传感器(单)伯努利器^[8], 并已论证了该滤波器是一种有效的融合方法. 基于此, 本章节进一步将该方法思想拓展到多伯努利滤波器, 并给出其具体的SMC实现形式.

3.1 SMC-CBMeMBer

1) 预测步.

假设 $k-1$ 时刻后验多目标多伯努利密度表示为 $\pi_{k-1} = \{(r_{k-1}^{(i)}, p_{k-1}^{(i)})\}_{i=1}^{M_{k-1}}$, $r_{k-1}^{(i)}$ 表示 $k-1$ 时刻第 i 个伯努利过程的存在概率, $p_{k-1}^{(i)}(\mathbf{x})$ 表示该伯努利过程的概率分布, M_{k-1} 为伯努利过程个数. $p_{k-1}^{(i)}(\mathbf{x})$ 一般有以下形式:

$$p_{k-1}^{(i)}(\mathbf{x}) = \sum_{j=1}^{L_{k-1}^{(i)}} w_{k-1}^{(i,j)} \delta_{\mathbf{x}_{k-1}^{(i,j)}}(\mathbf{x}), \quad (6)$$

其中: $L_{k-1}^{(i)}$ 表示该概率分布的粒子个数, $w_{k-1}^{(i,j)}$ 是其对应的粒子权值. 则 k 时刻预测多伯努利密度可表示为

$$\pi_{k|k-1} = \{(r_{P,k|k-1}^{(i)}, p_{P,k|k-1}^{(i)})\}_{i=1}^{M_{k-1}} \cup \{(r_{G,k}^{(i)}, p_{G,k}^{(i)})\}_{i=1}^{M_{G,k}}, \quad (7)$$

其中: $\{(r_{G,k}^{(i)}, p_{G,k}^{(i)})\}_{i=1}^{M_{G,k}}$ 表示 k 时刻新生多伯努利密度, $\{(r_{P,k|k-1}^{(i)}, p_{P,k|k-1}^{(i)})\}_{i=1}^{M_{k-1}}$ 为 k 时刻存活目标预测多伯努利密度. 若依据建议分布 $q_k^{(i)}(\cdot|\mathbf{x}_{k-1}, Z_k)$ 采样存活目标状态 $\mathbf{x}_{P,k|k-1}^{(i,j)}$, 则

$$r_{P,k|k-1}^{(i)} = r_{k-1}^{(i)} \sum_{j=1}^{L_{k-1}^{(i)}} w_{k-1}^{(i,j)} p_{S,k}(\mathbf{x}_{k-1}^{(i,j)}), \quad (8)$$

$$p_{P,k|k-1}^{(i)}(\mathbf{x}) = \sum_{j=1}^{L_{k-1}^{(i)}} \tilde{w}_{P,k|k-1}^{(i,j)} \delta_{\mathbf{x}_{P,k|k-1}^{(i,j)}}(\mathbf{x}), \quad (9)$$

其中:

$$\tilde{w}_{P,k|k-1}^{(i,j)} = \frac{w_{P,k|k-1}^{(i,j)}}{\sum_{j=1}^{L_{k-1}^{(i)}} w_{P,k|k-1}^{(i,j)}}, \quad (10)$$

$$w_{P,k|k-1}^{(i,j)} = \frac{w_{k-1}^{(i,j)} f_{k|k-1}(\mathbf{x}_{P,k|k-1}^{(i,j)}|\mathbf{x}_{k-1}^{(i,j)}) p_{S,k}(\mathbf{x}_{k-1}^{(i,j)})}{q_k^{(i)}(\mathbf{x}_{P,k|k-1}^{(i,j)}|\mathbf{x}_{k-1}^{(i,j)}, Z_k)}. \quad (11)$$

通过建议分布 $q_{\Gamma,k}^{(i)}(\mathbf{x}_k|Z_k)$ 采样得到新生目标状态粒子 $\mathbf{x}_{\Gamma,k}^{(i,j)} (j=1, \dots, L_{\Gamma,k}^{(i)})$, 则

$$p_{\Gamma,k}^{(i)} = \sum_{j=1}^{L_{\Gamma,k}^{(i)}} \tilde{w}_{\Gamma,k}^{(i,j)} \delta_{\mathbf{x}_{\Gamma,k}^{(i,j)}}(\mathbf{x}), \quad (12)$$

$$\tilde{w}_{\Gamma,k}^{(i,j)} = \frac{w_{\Gamma,k}^{(i,j)}}{\sum_{j=1}^{L_{\Gamma,k}^{(i)}} w_{\Gamma,k}^{(i,j)}}, \quad (13)$$

$$w_{\Gamma,k}^{(i,j)} = \frac{p_{\Gamma,k}^{(i)}(\mathbf{x}_{\Gamma,k}^{(i,j)})}{q_{\Gamma,k}^{(i)}(\mathbf{x}_{\Gamma,k}^{(i,j)}|Z_k)}. \quad (14)$$

2) 更新步.

令 k 时刻预测多伯努利密度 $\pi_{k|k-1}$ 为

$$\pi_{k|k-1} = \{(r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)})\}_{i=1}^{M_{k|k-1}}, \quad (15)$$

其中

$$p_{k|k-1}^{(i)} = \sum_{j=1}^{L_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} \delta_{\mathbf{x}_{k|k-1}^{(i,j)}}(\mathbf{x}), \quad (16)$$

则后验伯努利密度 $\pi_{k|k}$ 可表示为

$$\begin{aligned} \pi_{k|k} &\approx \\ &\{(r_{L,k}^{(i)}, p_{L,k}^{(i)})\}_{i=1}^{M_{k|k-1}} \cup \{(r_{U,k}(\mathbf{z}), p_{U,k}(\mathbf{x}; \mathbf{z}))\}_{\mathbf{z} \in Z_k}, \end{aligned} \quad (17)$$

其中继承航迹(漏检)部分的多伯努利参数 $\{(r_{L,k}^{(i)}, p_{L,k}^{(i)})\}_{i=1}^{M_{k|k-1}}$ 为

$$r_{L,k}^{(i)} = r_{k|k-1}^{(i)} \frac{1 - \rho_{L,k}^{(i)}}{1 - r_{k|k-1}^{(i)} \rho_{L,k}^{(i)}}, \quad (18)$$

$$p_{L,k}^{(i)}(\mathbf{x}) = \sum_{j=1}^{L_{k|k-1}^{(i)}} \tilde{w}_{L,k}^{(i,j)} \delta_{\mathbf{x}_{k|k-1}^{(i,j)}}(\mathbf{x}), \quad (19)$$

其中:

$$\rho_{L,k}^{(i)}(\mathbf{x}) = \sum_{j=1}^{L_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} p_{D,k}(\mathbf{x}_{k|k-1}^{(i,j)}), \quad (20)$$

$$\tilde{w}_{L,k}^{(i,j)} = \frac{w_{L,k}^{(i,j)}}{\sum_{j=1}^{L_{k|k-1}^{(i)}} w_{L,k}^{(i,j)}}, \quad (21)$$

$$w_{L,k}^{(i,j)} = w_{k|k-1}^{(i,j)} (1 - p_{D,k}(\mathbf{x}_{k|k-1}^{(i,j)})), \quad (22)$$

$p_{D,k}$ 是传感器的检测概率. 此外, 量测更新的多伯努利密度 $\{(r_{U,k}(\mathbf{z}), p_{U,k}(\mathbf{x}; \mathbf{z}))\}_{\mathbf{z} \in Z_k}$ 的参数为

$$\begin{aligned} r_{U,k}(\mathbf{z}) &= \frac{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} (1 - r_{k|k-1}^{(i)}) \rho_{U,k}^{(i)}(\mathbf{z})}{(1 - r_{k|k-1}^{(i)} \rho_{L,k}^{(i)}(\mathbf{x}))^2}}{\kappa_k(\mathbf{z}) + \sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \rho_{U,k}^{(i)}(\mathbf{z})}{1 - r_{k|k-1}^{(i)} \rho_{L,k}^{(i)}(\mathbf{x})}}, \\ \kappa_k(\mathbf{z}) &= \end{aligned} \quad (23)$$

$$p_{U,k}(\mathbf{x}; \mathbf{z}) =$$

$$\sum_{i=1}^{M_{k|k-1}} \sum_{j=1}^{L_{k|k-1}^{(i)}} \tilde{w}_{U,k}^{*(i,j)}(\mathbf{z}) \delta_{\mathbf{x}_{k|k-1}^{(i,j)}}(\mathbf{x}), \quad (24)$$

其中:

$$\rho_{U,k}^{(i)}(\mathbf{z}) = \sum_{j=1}^{L_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} \psi_{k,z}(\mathbf{x}_{k|k-1}^{(i,j)}), \quad (25)$$

$$\tilde{w}_{U,k}^{*(i,j)}(\mathbf{z}) = \frac{w_{U,k}^{*(i,j)}(\mathbf{z})}{\sum_{i=1}^{M_{k|k-1}} \sum_{j=1}^{L_{k|k-1}^{(i)}} w_{U,k}^{*(i,j)}(\mathbf{z})}, \quad (26)$$

$$w_{U,k}^{*(i,j)}(\mathbf{z}) = w_{k|k-1}^{(i,j)} \frac{r_{k|k-1}^{(i)}}{1 - r_{k|k-1}^{(i)}} \psi_{k,z}(\mathbf{x}_{k|k-1}^{(i,j)}), \quad (27)$$

$$\psi_{k,z}(\mathbf{x}_{k|k-1}^{(i,j)}) = g_k(\mathbf{z}|\mathbf{x}_{k|k-1}^{(i,j)}) p_{D,k}(\mathbf{x}_{k|k-1}^{(i,j)}), \quad (28)$$

其中 $g_k(\mathbf{z}|\mathbf{x})$ 为似然函数.

3.2 多传感器多伯努利密度的融合

为了便于清晰描述, 考虑3个传感器场景. 假设 k 时刻3个传感器接收到的量测集分别为 Z_k^1, Z_k^2, Z_k^3 . 则利用传感器1的量测集 Z_k^1 更新式(15)–(16), 可得

$$\pi_{k|k}^1 = \{(r_{1,k|k}^{(i)}, p_{1,k|k}^{(i)})\}_{i=1}^{M_{k|k}^1}, \quad (29)$$

$$p_{1,k|k}^{(i)} = \sum_{j=1}^{L_{1,k|k}^{(i)}} w_{1,k|k}^{(i,j)} \delta_{\mathbf{x}_{1,k|k}^{(i,j)}}(\mathbf{x}). \quad (30)$$

随后, 借鉴Mahler的多传感器更新策略^[8], 将 $\pi_{k|k}^1$ 和 $p_{1,k|k}^{(i)}$ 作为传感器2的输入, 则传感器2的后验分布有如下形式:

$$\begin{aligned} \pi_{k|k}^2 &\approx \\ &\{(r_{L,k}^{(i)}, p_{L,k}^{(i)})\}_{i=1}^{M_{k|k}^1} \cup \{(r_{U,k}(\mathbf{z}), p_{U,k}(\mathbf{x}; \mathbf{z}))\}_{\mathbf{z} \in Z_k^2}. \end{aligned} \quad (31)$$

进一步可表示为

$$\pi_{k|k}^2 = \{(r_{2,k|k}^{(i)}, p_{2,k|k}^{(i)})\}_{i=1}^{M_{k|k}^2}, \quad (32)$$

$$p_{2,k|k}^{(i)} = \sum_{j=1}^{L_{2,k|k}^{(i)}} w_{2,k|k}^{(i,j)} \delta_{\mathbf{x}_{2,k|k}^{(i,j)}}(\mathbf{x}). \quad (33)$$

类似地, 借鉴Mahler的多传感器更新策略, 将 $\pi_{k|k}^2$ 和 $p_{2,k|k}^{(i)}$ 作为传感器3的输入, 则传感器3的后验分布有如下形式:

$$\begin{aligned} \pi_{k|k}^3 &\approx \\ &\{(r_{L,k}^{(i)}, p_{L,k}^{(i)})\}_{i=1}^{M_{k|k}^2} \cup \{(r_{U,k}(\mathbf{z}), p_{U,k}(\mathbf{x}; \mathbf{z}))\}_{\mathbf{z} \in Z_k^3}. \end{aligned} \quad (34)$$

同样也有如下形式:

$$\pi_{k|k}^3 = \{(r_{3,k|k}^{(i)}, p_{3,k|k}^{(i)})\}_{i=1}^{M_{k|k}^3}, \quad (35)$$

$$p_{3,k|k}^{(i)} = \sum_{j=1}^{L_{3,k|k}^{(i)}} w_{3,k|k}^{(i,j)} \delta_{\mathbf{x}_{3,k|k}^{(i,j)}}(\mathbf{x}), \quad (36)$$

则最终的多传感器融合后验分布为

$$\pi_{k|k} = \pi_{k|k}^3. \quad (37)$$

4 基于多目标信息增益的多传感器控制

4.1 分布式多传感器控制

多目标跟踪中多传感器控制的核心是根据一定的优化准则, 选择传感器的工作状态或运行参数, 进而控制量测过程以达到优化多目标跟踪性能的目的. 对于一个多传感器所构成的网络, 通常每个时刻有多个传感器参与部署, 因此可允许的控制动作通常会随传感器个数呈指数级增加. 例如, 对于一个 N 维传感器

控制空间 U , 若 U_i 表示第 i 个传感器控制空间, 则 $U = U_1 \times U_2 \times \cdots \times U_N$, 此时其计算复杂度为 $O(|U_1| \times |U_2| \times \cdots \times |U_N|)$. 显然, 多传感器控制问题本质上是一个高维优化问题. 尽管这类问题的解决仍然是在 POMDP 框架下进行, 但相对于单传感器控制系统而言, 由于高维优化问题的存在, 多传感器控制的求解计算复杂度更高, 运行速率更慢, 实时性更差. 这对于大多数精度要求不是很高, 却对实时性很敏感的多目标跟踪系统, 显然难以适应. 有鉴于此, 本文提出一种次优, 但实时性更好的分布式多传感器控制方法. 详细的控制过程如图 1 所示.




图 1 分布式多传感器控制

Fig. 1 Distributed multi-sensor control

如图 1 所示, 每个传感器在控制阶段都独立地进行控制决策, 这使得多个传感器能够并行执行控制步骤. 此时, 整个分布式多传感器控制的计算复杂度为 $O(|U_1| + |U_2| + \cdots + |U_n|)$. 可以看出, 该多传感器控制策略不但控制方式灵活, 而且还能极大的降低计算复杂度, 提升运算效率, 这对于多传感器系统的实时管理具有重要的理论价值.

在多传感器自主决策阶段, 最优控制策略往往通过求取某种评价函数来获得. 本文首先基于信息论对多传感器进行控制, 并选取巴氏距离 (Bhattacharyya distance) 作为评价函数. 如图 1 所示, 每个传感器的最优决策都是在最大化信息增益 (巴氏距离) 的准则下获得.

此外, 在多传感器控制中, 多目标的后验融合发生在所有传感器更新步骤之后. 本文基于迭代-修正的思想, 通过 SMC-CBMeMBer 滤波器, 对多个传感器的多伯努利密度进行融合. 融合的结果将返回到每个传感器下一时刻的初始阶段.

4.2 巴氏距离的求解

评价函数在多传感器控制问题中起着至关重要的作用. 本文选取巴氏距离用于基于信息的多传感器控

制, 其本质上是两个多目标密度之间的相对熵测度 (信息增益). 巴氏距离值的增加意味着可以从下一时刻量测中获得更多的多目标信息. 此外, 巴氏距离的最大值可以确定下一时刻多传感器的最佳位置. 首先给出其定义如下:

$$\mathcal{R}(\nu) = -\ln \int \sqrt{p_{k|k}(X; \nu) p_{k|k-1}(X)} \delta X, \quad (38)$$

其中: $p_{k|k}(X; \nu)$ 表示后验概率密度函数, $p_{k|k-1}(X)$ 表示先验概率密度函数.

值得注意的是, SMC-CBMeMBer 本质上是通过一组数目固定且相互独立的伯努利参数来近似表征多目标密度, 即 $\pi_{k|k-1} = \{(r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)})\}_{i=1}^{M_{k|k-1}}$. 这显然难以直接用来求解巴氏距离. 为此, 本文利用所提出的 TOMB 采样方法^[31], 通过对存在概率 $r_{k|k-1}^{(i)}$ 和概率密度 $p_{k|k-1}^{(i)}$ 分别采样, 进而利用一组带有权值的粒子集直接近似预测多目标密度. 即

$$p_{k|k-1}(X) \approx \sum_{j=1}^{L_{k|k-1}} w_{k|k-1}^{(j)} \delta_{\mathbf{x}_{k|k-1}^{(j)}}(\mathbf{x}), \quad (39)$$

其中 $L_{k|k-1}$ 为预测多目标密度粒子数.

此外, 对于每种控制方案 $\nu \in U_k$ 确定传感器的位

置 $x_{s,k}(\nu)$. 随后对每一个控制 ν 仅产生一个相应的 PIMS, 可表示为

$$Z_k(\nu) = \bigcup_{\hat{\mathbf{x}} \in \hat{X}_{k|k-1}} \{h(\hat{\mathbf{x}}, \mathbf{x}_{s,k}(\nu))\}, \quad (40)$$

其中 $\hat{X}_{k|k-1}$ 是 k 时刻的多目标预测状态.

由于不考虑杂波和噪声, 且 $p_{D,k} = 1$, 因此不存在继承航迹(漏检)的伯努利RFS, 而对于每个 PIMS 更新的伯努利RFS(航迹), 其存在概率恒为1. 此时, 只需要结合 SMC-CBMeMBer 滤波算法, 利用 PIMS 对式(39)中的权值进行更新. 则更新后的多目标概率密度有如下形式:

$$p_{k|k}(X) \approx \sum_{j=1}^{L_{k|k-1}} w_{k|k}^{(j)} \delta_{\mathbf{x}_{k|k-1}^{(j)}}(\mathbf{x}), \quad (41)$$

$$w_{k|k}^{(j)} = \frac{\hat{w}_{k|k}^{(j)}}{\sum_{i=1}^{L_{k|k-1}} \hat{w}_{k|k}^{(i)}}, \quad (42)$$

$$\hat{w}_{k|k}^{(j)} = \sum_{\mathbf{z} \in Z_k(\nu)} \hat{w}_{U,k}^{(j)}(\mathbf{z}), \quad (43)$$

$$\hat{w}_{U,k}^{(j)}(\mathbf{z}) = \frac{\hat{w}_{U,k}^{*(j)}(\mathbf{z})}{\sum_{j=1}^{L_{k|k-1}} \hat{w}_{U,k}^{*(j)}(\mathbf{z})}, \quad (44)$$

$$\hat{w}_{U,k}^{*(j)}(\mathbf{z}) = w_{k|k-1}^{(j)} M^j(r) g_k(\mathbf{z} | \mathbf{x}_{k|k-1}^{(j)}), \quad (45)$$

$$M^j(r) = \frac{r_{k|k-1}^{(j*)}}{(1 - r_{k|k-1}^{(j*)})}, \quad (46)$$

其中 j^* 表示预测假设轨迹的索引.

此时, 结合式(38)–(39)和式(41), 巴氏距离可表示为

$$\mathcal{R}(\nu) = -\ln \int \left(\sqrt{\left(\sum_{j=1}^{L_{k|k-1}} w_{k|k-1}^{(j)} \delta_{\mathbf{x}_{k|k-1}^{(j)}}(\mathbf{x}) \right)} \cdot \sqrt{\left(\sum_{j=1}^{L_{k|k-1}} w_{k|k-1}^{(j)} \delta_{\mathbf{x}_{k|k-1}^{(j)}}(\mathbf{x}) \right)} \right) \delta \mathbf{x}. \quad (47)$$

根据德尔塔函数的正交特性, 式(47)可简化为

$$\begin{aligned} \mathcal{R}(\nu) = & -\ln \int \sum_{j=1}^{L_{k|k-1}} (w_{k|k}^{(j)})^{1/2} \cdot (w_{k|k-1}^{(j)})^{1/2} \delta_{\mathbf{x}_{k|k-1}^{(j)}}(\mathbf{x}) \delta \mathbf{x}. \end{aligned} \quad (48)$$

进一步利用德尔塔函数的积分特性, 上式可最终化简为

$$\mathcal{R}(\nu) = -\ln \sum_{j=1}^{L_{k|k-1}} \sqrt{w_{k|k}^{(j)} \cdot w_{k|k-1}^{(j)}}. \quad (49)$$

此外, 为了详细说明基于巴氏距离的多传感器控制方法, 以下给出详细的算法伪码.

算法 1 基于多目标信息增益的多传感器控制.

输入 预测多伯努利密度 $\{r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)}\}_{i=1}^{M_{k|k-1}}$,

其中 $p_{k|k-1}^{(i)}(\mathbf{x}) = \sum_{j=1}^{L_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} \delta_{\mathbf{x}_{k|k-1}^{(i,j)}}(\mathbf{x})$, 传感器控制位置 $\mathbf{x}_{s,k-1}^1, \mathbf{x}_{s,k-1}^2, \mathbf{x}_{s,k-1}^3$.

1) 根据预测多伯努利密度提取多目标状态

$\hat{X}_{k|k-1} = \{\hat{\mathbf{x}}_{k|k-1}\}_{i=1}^M$.

2) 利用 TOMB 方法采样多伯努利密度, 进而近似预测多目标密度 $p_{k|k-1}(X)$.

3) 对于传感器1, 令 $U_k^1 = \{\nu^l\}_{l=1}^N$.

4) **for** $l = 1 : N$ **do**

5) 根据 $\hat{X}_{k|k-1}$ 和 ν^l 生成一个 PIMS $Z_k(\nu^l)$.

6) $s_1 \leftarrow \emptyset$

7) **for** $j = 1 : L_{k|k-1}$ **do**

8) **for each** $\mathbf{z} \in Z_k(\nu^l)$ **do**

$$9) \quad M^j(r) = \frac{r_{k|k-1}^{(j*)}}{(1 - r_{k|k-1}^{(j*)})}$$

$$10) \quad \hat{w}_{U,k}^{*(j)}(\mathbf{z}) = w_{k|k-1}^{(j)} M^j(r) g_k(\mathbf{z} | \mathbf{x}_{k|k-1}^{(j)})$$

11) **end for**

$$12) \quad s_1 = s_1 + \hat{w}_{U,k}^{*(j)}(\mathbf{z})$$

13) **end for**

$$14) \quad s_3 \leftarrow \emptyset$$

15) **for** $j = 1 : L_{k|k-1}$ **do**

$$16) \quad s_2 \leftarrow \emptyset$$

17) **for each** $\mathbf{z} \in Z_k(\nu^l)$ **do**

$$18) \quad \hat{w}_{U,k}^{(j)}(\mathbf{z}) = \frac{\hat{w}_{U,k}^{*(j)}(\mathbf{z})}{s_1}$$

$$19) \quad s_2 = s_2 + \hat{w}_{U,k}^{(j)}(\mathbf{z})$$

20) **end for**

$$21) \quad \hat{w}_{k|k}^{(j)} = s_2$$

$$22) \quad s_3 = s_3 + s_2$$

23) **end for**

$$24) \quad s_4 \leftarrow \emptyset$$

25) **for** $j = 1 : L_{k|k-1}$ **do**

$$26) \quad w_{k|k}^{(j)} = \frac{\hat{w}_{k|k}^{(j)}}{s_3}$$

$$27) \quad \mathcal{R}_1(\nu^l) = \sqrt{w_{k|k}^{(j)} \cdot w_{k|k-1}^{(j)}}$$

$$28) \quad s_4 = s_4 + \mathcal{R}_1(\nu^l)$$

29) **end for**

$$30) \quad \mathcal{R}(\nu^l) = -\ln(s_4)$$

31) **end for**

32) $u_k^1 = \operatorname{argmax}_{\nu \in U_k^1} E[R(\nu)]$. 注: 对 PIMS 求期望

33) 对于传感器2和3, 与传感器1的计算过程类似.

输出 $u_k = (u_k^1, u_k^2, u_k^3)$.

5 基于多目标战术重要性评估的多传感器控制

5.1 战术重要性标绘

多目标战术重要性评估在现代战场的指挥决策中发挥着重要作用. 例如, 它是对敌监视和对敌战术意图分析的重要因素. 通常, 多目标战术重要性(威胁)评估旨在根据目标战术重要性水平确立目标优先级.

而目标战术重要性水平的建立需要全面分析各种威胁因素, 且其往往和目标运动态势密切相关. 基于目标运动态势分析建立目标战术重要性水平是现代战场目标跟踪系统态势感知中非常重要的一种举措. 目前, 依据目标运动态势建立目标战术重要性水平常见的有两种方法. 第1种方法是将距离、速度等各因素决定的威胁水平进行加权. 该方法需要在不同的跟踪场景和态势评估条件下对权值进行赋值, 对环境的适应性较差. 另外一种经典的战术意义标绘(tactical significance map, TSM)函数^[32-33], TSM可译作目标战术重要性标绘, 该方法考虑了各因素对综合威胁水平贡献程度的非线性变化, 处理方式简单有效. 因此, 基于多传感器多伯努利参数提取多目标运动状态, 本文利用该状态信息分析多目标运动态势, 进而借助TSM函数来确定当前时刻各目标的威胁程度.

本文以下仅针对一个给定的传感器和给定的目标进行其TSM函数的定义, 其他目标和传感器之间TSM函数的定义类似, 不再另行说明.

若 k 时刻目标的位置表示为 $\mathbf{x}_{t,k}$, 传感器位置表示为 $\mathbf{x}_{s,k}$, 则目标和传感器之间的距离可表示为

$$d_k = \|\mathbf{x}_{t,k} - \mathbf{x}_{s,k}\|. \quad (50)$$

鉴于目标的战术重要性相关于目标与传感器之间的距离 d_k , 此时TSM函数可表达式

$$f_{\text{TSM}} \sim \exp\left(-\frac{d_k^2}{2\sigma_{\text{TSM}}^2}\right). \quad (51)$$

式(51)表明, 目标和传感器之间的距离和目标的威胁度成正比, 目标离传感器越近, 其威胁度越高. σ_{TSM} 与目标的航向和速度有关. 若 $\mathbf{p}_k$ 表示目标相对于传感器的位置矢量, $\mathbf{v}_k$ 表示目标速度矢量, 则

$$\sigma_{\text{TSM}}(\mathbf{p}_k, \mathbf{v}_k) = \left(1 - \frac{\theta_k(\mathbf{p}_k, \mathbf{v}_k)}{\pi}\right)(k_0\|\mathbf{v}_k\| + m_0), \quad (52)$$

其中: k_0 和 m_0 为常数; $\theta_k(\mathbf{p}_k, \mathbf{v}_k)$ 为目标相对传感器的航向角, 其表达式为

$$\theta_k(\mathbf{p}_k, \mathbf{v}_k) = \cos^{-1}\left(\frac{(\mathbf{p}_k, \mathbf{v}_k)}{\|\mathbf{p}_k\| \cdot \|\mathbf{v}_k\|}\right), \quad (53)$$

其中 $(\mathbf{p}_k, \mathbf{v}_k)$ 表示标量积. 该目标航向角可理解为目标相对传感器的视线向量和目标速度矢量的夹角.

结合式(50)–(53), TSM函数最终可表示为

$$f_{\text{TSM}} = \exp\left(\frac{-d_k^2}{2\left(1 - \frac{\theta_k(\mathbf{p}_k, \mathbf{v}_k)}{\pi}\right)^2(k_0\|\mathbf{v}_k\| + m_0)^2}\right). \quad (54)$$

由式(54)可以看出, TSM函数的建立综合考虑了目标和传感器的相对距离、目标速度以及目标相对于传感器的航向角.

5.2 基于战术重要性评估的多传感器控制

TSM函数的重要意义在于建立了多目标战术重要性等级, 进而实时评估得到当前时刻最具战术价值的目标. 作为另外一个重要内容, 本章节研究利用巴氏距离来求解基于多目标战术重要性评估的多传感器控制策略. 该策略所采用分布式传感器网络如图1所示, 传感器独立决策过程如图2所示.




图 2 基于多目标战术重要性评估的传感器控制框图

Fig. 2 The schematic block diagram of sensor control based on multi-target tactical significance assessment

由式(38)可知, 最大威胁度目标的先验概率密度和后验概率密度是求解巴氏距离的两个重要因子. 因

此, 如何从多目标概率密度中提取最大威胁度目标对应的概率分布就成为解决问题的关键. 值得注意的是,

CBMeMBer滤波器通过传递一组数目固定且相互独立的伯努利参数来近似多目标密度, 这为提取最大威胁度目标的概率密度函数提供了极大的便利. 假设 k 时刻的最大威胁度目标 $\hat{\mathbf{x}}_{\text{th},k|k-1}$ 来自于第 i 个预测伯努利参数集 $\{(r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)})\}$, 则 $p_{k|k-1}^{(i)}$ 显然是最大威胁度目标对应的预测概率密度函数, 可描述为

$$p_{\text{th},k|k-1}(\mathbf{x}) = \sum_{j=1}^{L_{\text{th},k|k-1}} w_{\text{th},k|k-1}^{(j)} \delta_{\hat{\mathbf{x}}_{\text{th},k|k-1}^{(j)}}(\mathbf{x}). \quad (55)$$

此时, 最大威胁度目标对应的后验概率密度可利用PIMS更新式(55)来获得, 且有如下形式:

$$p_{\text{th},k|k}(\mathbf{x}) = \sum_{j=1}^{L_{\text{th},k|k-1}} \tilde{w}_{\text{th},k}^{*(j)}(\mathbf{z}) \delta_{\hat{\mathbf{x}}_{\text{th},k|k-1}^{(j)}}(\mathbf{x}), \quad (56)$$

其中:

$$\tilde{w}_{\text{th},k}^{*(j)}(\mathbf{z}) = \frac{w_{\text{th},k}^{*(j)}(\mathbf{z})}{\sum_{j=1}^{L_{\text{th},k|k-1}} w_{\text{th},k}^{*(j)}(\mathbf{z})}, \quad (57)$$

$$w_{\text{th},k}^{*(j)}(\mathbf{z}) = w_{\text{th},k|k-1}^{(j)} g_k(\mathbf{z}|\hat{\mathbf{x}}_{\text{th},k|k-1}^{(j)}). \quad (58)$$

为了详细说明基于多目标战术重要性评估的多传感器控制方法, 以下给出详细的算法伪码.

算法2 基于战术重要性评估的多传感器控制.

输入 预测多伯努利密度 $\{r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)}\}_{i=1}^{M_{k|k-1}}$,

其中 $p_{k|k-1}^{(i)}(\mathbf{x}) = \sum_{j=1}^{L_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} \delta_{\mathbf{x}_{k|k-1}^{(i,j)}}(\mathbf{x})$, 传感器控制位置 $\mathbf{x}_{s,k-1}^1, \mathbf{x}_{s,k-1}^2, \mathbf{x}_{s,k-1}^3$.

1) 根据预测多伯努利密度提取多目标状态 $\hat{X}_{k|k-1} = \{\hat{\mathbf{x}}_{k|k-1}\}_{i=1}^M$.

2) 利用TSM函数从多目标状态集 $\hat{X}_{k|k-1}$ 中提取最大威胁度目标 $\hat{\mathbf{x}}_{\text{th},k|k-1}$.

3) 从多伯努利密度中提取最大威胁度目标的概率分布 $p_{\text{th},k|k-1}(\mathbf{x})$.

4) 对于传感器1, 令 $U_k^1 = \{\nu^l\}_{l=1}^N$.

5) **for** $l = 1 : N$ **do**

6) 根据 $\hat{\mathbf{x}}_{\text{th},k|k-1}$ 和 ν^l 生成一个PIMS $Z_k(\nu^l)$.

7) $s_1 \leftarrow \emptyset$

8) **for** $j = 1 : L_{\text{th},k|k-1}$ **do**

9) **for each** $\mathbf{z} \in Z_k(\nu^l)$ **do**

10) $w_{\text{th},k}^{*(j)}(\mathbf{z}) = w_{\text{th},k|k-1}^{(j)} g_k(\mathbf{z}|\hat{\mathbf{x}}_{\text{th},k|k-1}^{(j)})$

11) **end for**

12) $s_1 = s_1 + w_{\text{th},k}^{*(j)}(\mathbf{z})$

13) **end for**

14) **for** $j = 1 : L_{\text{th},k|k-1}$ **do**

15) $\tilde{w}_{\text{th},k}^{*(j)}(\mathbf{z}) = \frac{w_{\text{th},k}^{*(j)}(\mathbf{z})}{s_1}$

16) **end for**

17) $s_2 \leftarrow \emptyset$

18) **for** $j = 1 : L_{\text{th},k|k-1}$ **do**

19) $\mathcal{R}_1(\nu^l) = \sqrt{w_{\text{th},k|k-1}^{(j)} \cdot \tilde{w}_{\text{th},k}^{*(j)}}$

20) $s_2 = s_2 + \mathcal{R}_1(\nu^l)$

21) **end for**

22) $\mathcal{R}(\nu^l) = -\ln(s_2)$

23) **end for**

24) $u_k^1 = \operatorname{argmax}_{\nu \in U_k^1} E[R(\nu)]$. 注: 对PIMS求期望

25) 对于传感器2和3, 与传感器1的计算过程类似.

输出 $u_k = (u_k^1, u_k^2, u_k^3)$.

6 仿真分析

6.1 多传感器多目标跟踪性能评价

本文采用最优子模式分配(optimal subpattern assignment, OSPA)距离^[34]来评估多传感器多目标跟踪的性能. 其定义如下: 设真实的和估计的多目标状态集合分别为 $X = \{\mathbf{x}_1, \dots, \mathbf{x}_m\}$ 和 $\hat{X} = \{\hat{\mathbf{x}}_1, \dots, \hat{\mathbf{x}}_n\}$, 若 $m \leq n$, 则OSPA距离为

$$\begin{aligned} \bar{d}_p^{(c)}(X, \hat{X}) = \\ \left(\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m d^{(c)}(\mathbf{x}_i, \hat{\mathbf{x}}_{\pi(i)})^p + c^p(n-m) \right) \right)^{\frac{1}{p}}, \end{aligned} \quad (59)$$

其中: $\bar{d}^{(c)}(\mathbf{x}, \hat{\mathbf{x}}) = \min(c, \|\mathbf{x} - \hat{\mathbf{x}}\|)$; Π_n 表示所有 $\{1, \dots, n\}$ 的排列构成的集合, 距离阶次 $p \geq 1$, 截断系数 $c > 0$. 如果 $m > n$, 则 $\bar{d}_p^{(c)}(X, \hat{X}) = \bar{d}_p^{(c)}(\hat{X}, X)$. 本次仿真中选取 $c = 50$ m, $p = 1$. 实验软硬件条件为MATLAB 2016b, Windows 7, Inter Core i5-4590 CPU 3.30 GHz, RAM 8 GB.

6.2 传感器控制集合

由于传感器下一时刻所能控制的可能位置有无穷多个, 即传感器控制的位置集合是无穷集. 显然, 考虑并计算所有位置的控制方案是不现实的. 基于此, 本文借鉴文献[20]的做法来构建传感器控制的备选集合. 若 k 时刻传感器实际位置为 $\mathbf{x}_{s,k} = [x_{s,k} \ y_{s,k}]^T$, 则下一时刻传感器所有可允许控制的位置集合 U_{k+1} 可表示为

$$\begin{aligned} U_{k+1} = \{ & (x_{s,k} + j \frac{v_{s,c} \cdot T}{N_R} \cos(\ell \frac{2\pi}{N_\theta}); y_{s,k} + \\ & j \frac{v_{s,c} \cdot T}{N_R} \sin(\ell \frac{2\pi}{N_\theta})), \\ & j = 1, \dots, N_R; \ell = 1, \dots, N_\theta \}. \end{aligned} \quad (60)$$

本文选择 $N_\theta = 8$, $N_R = 2$, 则 U_{k+1} 总共包括17种控制方案(包含传感器处于静默状态). $v_{s,c}$ 是传感器自身的容许控制速度, 设为50 m/s.

6.3 实验1

实验1考虑距离方位跟踪(range-bearing tracking,

RBT). 设置监控区域为 $[-\pi, \pi] \times [0, 600\sqrt{2}\text{m}]$. 场景中目标轨迹均为近常速运动模型(nearly constant velocity model, NCVM^[35]), 共计出现 5 个目标, 其状态转移密度为

$$f(\mathbf{x}_k|\mathbf{x}_{k-1}) = \mathcal{N}(\mathbf{x}_k; F_k \mathbf{x}_{k-1}, Q_k), \quad (61)$$

其中:

$$F_k = \begin{bmatrix} I_2 & TI_2 \\ 0_2 & I_2 \end{bmatrix}, \quad Q_k = \sigma_v^2 \begin{bmatrix} \frac{T^4}{4} I_2 & \frac{T^3}{2} I_2 \\ \frac{T^3}{2} I_2 & T^2 I_2 \end{bmatrix}, \quad (62)$$

I_n 表示 $n \times n$ 的单位矩阵, $\sigma_v = 5 \text{ m/s}^2$. $T = 1 \text{ s}$ 为量测采样周期, 总共采样 50 次. 新生过程是一个多伯努利 RFS, 其密度 $\pi_T = \{(r_T^{(i)}, p_T^{(i)})\}_{i=1}^5$, 其中:

$$r_T^{(i)} = 0.01, \quad p_T^{(i)}(\mathbf{x}) = \mathcal{N}(\mathbf{x}; \mathbf{m}_\gamma^{(i)}, P_\gamma),$$

$$\mathbf{m}_\gamma^{(1)} = [500 \quad -400 \quad 0 \quad 0]^T,$$

$$\mathbf{m}_\gamma^{(2)} = [300 \quad 500 \quad 0 \quad 0]^T,$$

$$\mathbf{m}_\gamma^{(3)} = [-300 \quad 200 \quad 0 \quad 0]^T,$$

$$\mathbf{m}_\gamma^{(4)} = [-500 \quad 320 \quad 0 \quad 0]^T,$$

$$\mathbf{m}_\gamma^{(5)} = [200 \quad -300 \quad 0 \quad 0]^T,$$

$$P_\gamma = \text{diag}\{[100 \quad 100 \quad 50 \quad 50]^T\}.$$

目标存活概率和检测概率分别为 $p_{S,k} = 0.99$ 和 $p_{D,k} = 0.98$. 杂波强度 $\kappa_k(z) = \lambda_c V u(z)$, 其中: 每周期杂波平均数 $\lambda_c = 5$, V 为监控区域体积, $u(z)$ 表示监控区域内的杂波均匀分布. 假设轨迹删减阈值为 $r_T = 10^{-3}$. 每条航迹平均采样粒子数为 $L_k = 500$, 最小粒子采样数为 $L_{\min} = 100$.

在 RBT 中, 量测模型有如下形式:

$$z_k = \begin{bmatrix} \sqrt{(x_k - x_{s,k})^2 + (y_k - y_{s,k})^2} \\ \tan^{-1} \left(\frac{y_k - y_{s,k}}{x_k - x_{s,k}} \right) \end{bmatrix} + v_k, \quad (63)$$

其中:

$$v_k \sim \mathcal{N}(\cdot; 0_{2 \times 1}, R_k), \quad R_k = \text{diag}\{[\sigma_r^2 \quad \sigma_\theta^2]^T\},$$

$$\sigma_r = 5 \text{ m}, \quad \sigma_\theta = (\pi/180) \text{ rad/s}.$$

首先给出实验 1 中多目标运动参数, 如表 1 所示. 多目标运动轨迹如图 3 所示.

表 1 多目标参数

Table 1 Parameters of multi-target

目标	新生时刻/s	消亡时刻/s	初始位置/m	速度/(m · s ⁻¹)
1	1	50	[500, -400]	[-6, 6]
2	1	30	[300, 500]	[-6, -4]
3	10	50	[-300, 200]	[-2, 7]
4	20	40	[-500, -320]	[6, -2]
5	20	50	[200, -300]	[6, 7]




图 3 实际的目标轨迹

Fig. 3 Actual target trajectories

为了对比说明所提控制方案的合理性和有效性. 本文选择了几种颇为有效的多传感器控制方案分别进行 200 次蒙特卡罗 (Monte Carlo, MC) 仿真实验. 其中, 方案 1 为多传感器 “随机控制” 策略. 该方案包括 3 个传感器同时参与多目标跟踪优化, 且每个传感器控制方案均在可允许的控制集合中随机选取. 由于随机控制方案往往能够获得出乎意料的控制效果, 因此通常被作为典型的控制方案加以比较. 方案 2 为基于 “巴氏距离” 的多传感器控制策略. 即本文所给出的控制方案. 该方案所对应的分布式网络包括 3 个独立并行控制的传感器, 每个传感器都通过巴氏距离来量化多目标密度之间的信息增益, 并以信息增益最大化为准则进行最终传感器控制决策. 方案 3 是 “PENT” 控制方案. 稍有不同的是, 对于分布式网络中每个独立并行控制的传感器, PENT 方案旨在决策出相应的控制方案, 使得传感器检测到目标势的后验期望值达到最大.




图 4 3 种控制方案位置估计的 OSPA 比较

Fig. 4 Position OSPA for three control strategies

图 4 给出了 3 种控制方案在 MC 实验中对多目标位置估计的 OSPA 距离统计结果. 可以看出, 3 种控制方案都对应了比较好的多目标跟踪估计效果, 这是因为多传感器协同跟踪与控制系统的管理和优化能够很大程度上降低多目标跟踪的不确定性, 提高多目标的

估计精度. 此外, 具体比较3种控制方案可以看出, “PENT”效果较差, 是因为该控制方案仅以目标势后验期望值最大化为评价准则, 其决策目标并不能完全兼顾到多目标跟踪性能的整体优化. 相比较而言, “随机控制”效果较好, 这或许是因为随机控制这种“随机不规律”运动使得跟踪系统获取了更多的多目标信息增益, 使得多目标跟踪性能得到相应地提高. “巴氏距离”估计效果最好, 这得益于以信息增益(巴氏距离)最大化为导向的评价体系. 该体系下多传感器有目的的以最大化接收多目标信息进行决策制定, 以优化传感器观测质量. 而决策的优化效果最终会反映在多目标跟踪估计精度上.

图5给出了本文所提出的多传感器控制方案在单次实验中对多传感器的最优控制轨迹. 可以看出, 在整个控制过程中, 每个传感器都会始终依据当前的多传感器多目标跟踪滤波融合结果不断地对自身的位置进行自适应调节, 即基于最大化多目标信息增益准则求解出当前时刻每个传感器相对于所有目标的最佳观测位置. 特别是随着目标的新生和消亡, 传感器总是会产生明显的机动控制轨迹来适应这种变化, 进而适应多目标概率密度的变化, 以调整自身位置获取最大化的多目标信息增益.




图5 所提方案的传感器控制轨迹

Fig. 5 Sensor control trajectory for the proposed strategy

此外, 为了说明传感器容许控制速度与目标运动速度相对关系对多目标跟踪估计效果的影响, 本文分别在设定不同的传感器容许控制速度($v_{s,c} \in [5, 50]$)的基础上进行100次MC仿真, 并统计多目标跟踪估计的OSPA均值. 如图6所示, 随着传感器容许控制速度的增大, 多目标状态的估计精度相应提高. 分析得知, 传感器的初始位置与目标的运动区域相隔较远(如图5). 此时, 设置较大的传感器容许控制速度(比如50 m/s)能让传感器有更大的控制范围, 能更快的靠近目标运动区域, 有利于优化多目标的跟踪性能.




图6 所提方案中不同的传感器控制速度对估计性能的影响

Fig. 6 Tracking performance of different sensor control speeds for the proposed strategy

MC仿真中的多目标势估计统计如图7所示. 显然, 3种控制方案的势估计均值都很接近真实目标数. 但通过统计目标势估计标准差(如图8所示), 仍能发现基于“巴氏距离”的多传感器控制呈现出相对较好的估计效果. 这一方面得益于多传感器系统提供的更为可靠的多目标量测信息. 另一方面基于巴氏距离的传感器决策也涵盖了对多目标势估计的优化过程.




图7 多目标势估计

Fig. 7 Cardinality estimation of multi-target




图8 多目标势估计标准差

Fig. 8 Standard deviation of multi-target cardinality estimation

“PENT”对目标势的估计效果最好,这要归功于该方案纯粹以目标势的后验期望值最大化为准则的评价体系.该方案虽然任务单一,也不能从根本上显著提升多目标跟踪性能(如图4所示),但在某些特定的应用场合却有非常重要的控制意义,因为该方案通过多传感器有目的(最大可能的优化势估计)的决策可以显著提升滤波器对于多目标的检测性能.

3种多传感器控制方案单步平均运行时间如表2所示.可以看出,3种控制方案在执行效率上差异明显,这种差异主要来自于多传感器评价函数的求解所花的时间.具体地,“随机控制”运行较快,这是因为每个传感器自主决策之后,需要对更新的后验分布进行迭代融合,时间代价主要来自于融合过程.“巴氏距离”运算效率较低,这主要是因为每个传感器优化决策过程中对巴氏距离的运算求解和多个传感器数据的融合.“PENT”运行最慢,这源于其代价函数的复杂求解过程,因为在此过程中需要对所有伯努利过程的预测粒子进行更新.此外,多传感器数据融合进一步加剧了其复杂的计算过程.

表 2 3种控制方案单步平均运行时间对比
Table 2 The average execution time for three control strategies

方案	单步平均运行时间/s
随机控制	2.2688
巴氏距离	8.0288
PENT	8.9432

图9给出了RBT在200次MC仿真中,本文所提方案所遍历的所有传感器控制位置.可以看出,随着多目标的不断变化(新生、消亡及状态的变化),每个传感器总会及时调整自身的位置以适应目标的不确定性所带来的多目标状态空间分布的变化.尽管跟踪场景中存在诸多随机因素,导致每次MC仿真中的每个传感器运动轨迹都不大可能一致,但该轨迹云仍能充分展示传感器轨迹控制的总体最优趋势.




图 9 传感器轨迹云和目标轨迹
Fig. 9 Sensor trajectory cloud and target trajectories

6.4 实验 2

正如实验1所示,所提多传感器控制方法基于信息增益最大化准则可以快速有效的对多目标跟踪精度进行优化.但有时候,人们更关心那些更具战术价值(威胁)的目标,如果能够集中传感器资源对那些最具战术价值的目标进行优先跟踪,将显著提升跟踪系统的作战效能.为此,作为本文的另外一个重要内容,本小节进一步将所提多传感器控制方法与目标战术重要性评估相结合.并通过仿真实验验证控制方案及时应对多目标运动态势变化的控制效果.

实验2仍考虑距离方位跟踪(range-bearing tracking, RBT),且相应参数设置与实验1相同.场景中出现5个目标,其运动参数如表3所示.多目标运动轨迹如图10所示.

表 3 多目标参数
Table 3 Parameters of multi-target

目标	新生时刻/s	消亡时刻/s	初始位置/m	速度/(m·s ⁻¹)
1	1	50	[-450, -450]	[3, 4]
2	1	30	[300, -300]	[3, 2]
3	10	50	[400, 300]	[-2, 2]
4	20	40	[-300, 220]	[8, 3]
5	20	50	[300, -200]	[2, -4]




图 10 实际的目标轨迹
Fig. 10 Actual target trajectories

为了对比说明所提控制方案的合理性和应对环境态势变化的有效性.本文在实验2所示的RBT中构造两种控制方案并进行200次MC试验.其中:方案1是基于多目标战术重要性评估的多传感器控制,方案2是基于多目标整体信息增益的多传感器控制.

如图11所示,两种多传感器控制方案都有较好的估计效果.但仔细比较,两者仍存在一定差异,方案2在整体跟踪效果上要优于方案1.这种差异不难理解,因为方案2是以优化多目标整体的估计精度为目的进行多传感器控制方案的制定,并不是对多目标“有差

别地”进行跟踪优化.相反,方案1仅是以最大威胁度目标子集为优化对象进行传感器的决策,其最优决策并不足以使多目标的整体信息增益最大.因此,方案1在效果呈现上较差.




图 11 两种控制方案中多目标位置估计的OSPA

Fig. 11 Position OSPA of multi-target for two control strategies

图12给出了两种控制方案仅对最大威胁度目标子集位置估计的OSPA距离统计:方案1为基于多目标战术重要性评估的多传感器控制,方案2为基于多目标整体信息增益的多传感器控制,显然方案1要优于方案2,这也证实了基于最大威胁度目标的传感器控制确实能够对威胁目标进行有效的跟踪优化.




图 12 最大威胁度目标子集位置估计的OSPA比较

Fig. 12 Position OSPA for the maximum threat target set

图13–15分别给出了3个传感器基于各自最大威胁度目标的运动轨迹.可以看出,图13–15有一个共性变化,即随着多目标对每个传感器威胁程度(战术重要性)不断变化,传感器总会第一时间响应并及时调整自身位置以应对这种多目标态势变化.这是由多目标战术重要性评估体系和目标跟踪优先级的变化所决定的,基于最大威胁度目标的传感器控制方案旨在决策出相应的传感器控制方案,该方案能够针对性的提高对威胁目标的跟踪质量.




图 13 方案1中传感器1的控制轨迹

Fig. 13 Sensor 1 control trajectory for the first strategy




图 14 方案1中传感器2的控制轨迹

Fig. 14 Sensor 2 control trajectory for the first strategy




图 15 方案1中传感器3的控制轨迹

Fig. 15 Sensor 3 control trajectory for the first strategy

两种方案单步平均运行时间如表4所示. 方案1在计算效率上要优于方案2. 这主要来源于传感器控制优化决策函数的求解. 方案1仅对最大威胁目标子集进行跟踪优化, 因此其在评价函数求解过程中仅需要对威胁目标的多伯努利密度预测粒子进行更新, 并不需要对所有目标对应的粒子进行更新计算, 这使得其在计算效率上要略好于方案2, 这对复杂跟踪环境下针对优先跟踪目标(具有最大威胁度)的快速决策与认知对抗具有非常重要的意义.

表 4 两种控制方案单步平均运行时间对比
Table 4 The average execution time for two control strategies

方案	单步平均运行时间/s
1	3.8538
2	7.9672

7 结论

本文的主要工作是基于POMDP理论框架, 利用多伯努利滤波器, 提出了相应的多目标跟踪中的多传感器控制策略. 文中首先利用多传感器多目标RFS建模, 给出了多传感器多伯努利滤波器, 并通过一组参数化的多伯努利过程来近似多传感器多伯努利密度. 其次, 通过多伯努利滤波器的序贯蒙特卡罗实现, 设计采样方案对多伯努利密度进行粒子采样, 其目的在于用一组带有权值的粒子集近似多目标状态空间分布. 随后, 借助巴氏距离作为传感器控制的评价函数用于多个传感器的独立并行控制方案的决策制定. 作为另外一个重要内容, 本文提出了一种基于多目标战术重要性评估的多传感器控制策略. 该控制方案旨在评估多目标战术重要性的基础上对威胁度最大的目标子集进行优先跟踪. 最后, 仿真实验验证了所提算法的有效性. 所提多传感器控制策略的意义在于通过对多个传感器独立并行控制, 能够在保证多目标估计精度的基础上提高传感器控制的灵活性和快速性, 这对于实际应用多传感器系统的管理优化具有重要的应用价值. 显然, 所提方法可以进一步推广到其他RFS滤波器中, 未来对大规模传感器网络的选择、部署也具有参考价值. 此外, 随着智能优化算法的快速发展, 处理器数据处理能力的极大提升, 尝试进行更加精细化的多个传感器的控制与管理也成为很有前景的研究内容.

参考文献:

- [1] YIN X Y, LI Z J, ZHANG L X, et al. Distributed state estimation of sensor-network systems subject to Markovian channel switching with application to a chemical process. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2018, 48(6): 864 – 874.
- [2] YANG R N, LIU G P, SHI P, et al. Predictive output feedback control for networked control systems. *IEEE Transactions on Industrial Electronics*, 2014, 61(1): 512 – 520.
- [3] YANG R N, SHI P, LIU G P. Filtering for discrete-time networked nonlinear systems with mixed random delays and packet dropouts. *IEEE Transactions on Automatic Control*, 2011, 56(11): 2655 – 2660.
- [4] LEU J S, CHIANG T H, YU M C, et al. Energy efficient clustering scheme for prolonging the lifetime of wireless sensor network with isolated nodes. *IEEE Communications Letters*, 2015, 19(2): 259 – 262.
- [5] LIU G P. Predictive controller design of networked systems with communication delays and data loss. *IEEE Transactions on Circuits and Systems—II Express Briefs*, 2010, 57(6): 481 – 485.
- [6] KRISHNAMURTHY V. Algorithms for optimal scheduling and management of hidden Markov model sensors. *IEEE Transactions on Signal Processing*, 2002, 50(6): 1382 – 1397.
- [7] MAHLER R P S. *Statistical Multi-source Multi-target Information Fusion*. Norwood, MA, USA: Artech House, 2007.
- [8] MAHLER R P S. *Advances in Statistical Multi-source Multi-target Information Fusion*. Norwood, MA, USA: Artech House, 2014.
- [9] MAHLER R P S. Multitarget Bayes filtering via first-order multitarget moments. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1152 – 1178.
- [10] MAHLER R P S. PHD filters of higher order in target number. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(4): 1523 – 1543.
- [11] VO B N, MA W K. The Gaussian mixture probability hypothesis density filter. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4091 – 4104.
- [12] VO B N, SINGH S, DOUCET A. Sequential Monte Carlo methods for multitarget filtering with random finite sets. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(4): 1224 – 1245.
- [13] VO B N, VO B T, HOANG H G. An efficient implementation of the generalized labeled multi-Bernoulli filter. *IEEE Transactions on Signal Processing*, 2017, 65(8): 1975 – 1987.
- [14] VO B T, VO B N, CANTONI A. The cardinality balanced multi-target multi-Bernoulli filter and its implementations. *IEEE Transactions on Signal Processing*, 2009, 57(2): 409 – 423.
- [15] VO B N, VO B T, PHUNG D. Labeled random finite sets and the Bayes multi-target tracking filter. *IEEE Transactions on Signal Processing*, 2014, 62(24): 6554 – 6567.
- [16] HOANG H G, VO B N, VO B T, et al. The Cauchy-Schwarz divergence for poisson point processes. *IEEE Transactions on Information Theory*, 2014, 61(8): 4475 – 4485.
- [17] KASTELLA K. Discrimination gain to optimize detection and classification. *IEEE Transactions on Systems Man and Cybernetics—Part A Systems and Humans*, 1997, 27(1): 112 – 116.
- [18] AUGHENBAUGH J M, COUR B R L. Metric selection for information theoretic sensor management. *Metric selection for information theoretic sensor management*. Cologne, Germany: IEEE, 2008: 1 – 8.
- [19] KREUCHER C, HERO A O, KASTELLA K. A comparison of task driven and information driven sensor management for target tracking. *Proceedings of the 44th IEEE Conference on Decision and Control*. Seville, Spain: IEEE, 2005: 4004 – 4009.
- [20] RISTIC B, VO B N. Sensor control for multi-object state-space estimation using random finite sets. *Automatica*, 2010, 46(11): 1812 – 1818.
- [21] RISTIC B, VO B N, CLARK D. A note on the reward function for PHD filters with sensor control. *IEEE Transactions on Aerospace and Electronic Systems*, 2011, 47(2): 1521 – 1529.
- [22] HOANG H G, VO B T. Sensor management for multi-target tracking via multi-Bernoulli filtering. *Automatica*, 2014, 50(4): 1135 – 1142.

- [23] GOSTAR A K, HOSEINNEZHAD R, BAB-HADIASHAR A. Multi-bernoulli sensor control via minimization of expected estimation errors. *IEEE Transactions on Aerospace and Electronic Systems*, 2015, 51(3): 1762 – 1773.
- [24] GOSTAR A K, HOSEINNEZHAD R, BAB-HADIASHAR A. Robust multi-Bernoulli sensor selection for multi-target tracking in sensor networks. *IEEE Signal Processing Letters*, 2013, 20(12): 1167 – 1170.
- [25] GOSTAR A K, HOSEINNEZHAD R, BAB-HADIASHAR A, et al. OSPA-based sensor control. *2015 International Conference on Control, Automation and Information Sciences (ICCAIS)*. Changshu, China: IEEE, 2015: 214 – 218.
- [26] MAHLER R P S, ZAJIC T R. Probabilistic objective functions for sensor management. *Proceedings of the Signal Processing, Sensor Fusion, and Target Recognition XIII*. Orlando, FL: Ivan Kadar, 2004: 233 – 244.
- [27] WANG X Y, HOSEINNEZHAD R, GOSTAR A K, et al. Multi-sensor control for multi-object Bayes filters. *Signal Processing*, 2018, 142(1): 260 – 270.
- [28] LIAN F, HOU L M, LIU J, et al. Constrained multi-sensor control using a multi-target MSE bound and a δ -GLMB filter. *Sensors*, 2018, 18(7): 2308.
- [29] LI W, HAN C Z. Dual sensor control scheme for multi-target tracking. *Sensors*, 2018, 18(5): 1653.
- [30] HERO A O, KREUCHER C M, BLATT D. Information theoretic approaches to sensor management. *Foundations and Applications of Sensor Management*. Boston, MA, USA: Springer, 2008.
- [31] CHEN Hui, HAN Chongzhao. Sensor control strategy for maneuvering multi-target tracking. *Acta Automatica Sinica*, 2016, 42(4): 512 – 523.
(陈辉, 韩崇昭. 机动多目标跟踪中的传感器控制策略的研究. 自动化学报, 2016, 42(4): 512 – 523.)
- [32] ELFALLAH A, ZATEZALO A, MAHLER R S, et al. Unified Bayesian situation assessment sensor management. *Proceedings of SPIE Signal Processing, Sensor Fusion, and Target Recognition*. Orlando, FL, United States: SPIE, 2005: 253 – 264.
- [33] ELFALLAH A, ZATEZALO A, MEHRA R K, et al. Advancements in situation assessment sensor management. *Proceedings of SPIE*. Kissimmee, FL, United states: SPIE, 2006, 6235: 62350M – 62350M-11.
- [34] SCHUHMACHER D, VO B T, VO B N. A consistent metric for performance evaluation of multi-object filters. *IEEE Transactions on Signal Processing*, 2008, 56(8): 3447 – 3457.
- [35] LI X R, JILKOV V P. Survey of maneuvering target tracking. part I: dynamic models. *IEEE Transactions on Aerospace and Electronic Systems*, 2004, 39(4): 1333 – 1364.

作者简介:

陈 辉 教授, 博士生导师, 主要从事目标跟踪和传感器管理等方法的研究, E-mail: huich78@hotmail.com;

邓东明 硕士研究生, 从事多目标跟踪方法的研究, E-mail: dengdongming19@163.com;

韩崇昭 教授, 博士生导师, 主要从事多源信息融合、随机控制与自适应控制、非线性频谱分析等方面的研究, E-mail: czhan@mail.xjtu.edu.cn.