

多扩展目标跟踪中基于加权最优子模式分配 距离的传感器管理方法

陈 辉^{1†}, 刘雅婷¹, 张双庆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 综合自动化研究所, 陕西 西安 710049)

摘要: 针对多扩展目标跟踪优化中的传感器管理问题, 本文基于随机有限集(RFS)提出一种基于加权最优子模式分配(W-OSPA)距离的传感器管理方法. 首先, 在部分可观测马尔可夫决策过程(POMDP)理论框架下, 给出基于逆威沙特椭圆分布假设的多扩展目标跟踪传感器管理的基本方法. 其次, 利用W-OSPA距离求解多扩展目标后验分布的离差, 以离差最小化获得最优化的多扩展目标状态估计设计传感器管理策略. 最后, 通过推导给出的离差数值求解方法进行最优传感器管理方案的决策. 仿真实验基于OSPA距离评价验证了所提传感器管理方法相对于其他算法对多扩展目标的质心运动状态和椭圆形状都有更好的估计效果.

关键词: 传感器管理; 随机有限集; 加权最优子模式分配; 多扩展目标跟踪; 离差

引用格式: 陈辉, 刘雅婷, 张双庆, 等. 多扩展目标跟踪中基于加权最优子模式分配距离的传感器管理方法. 控制理论与应用, 2022, 39(5): 887 – 896

DOI: 10.7641/CTA.2021.10112

Sensor management method based on weighted optimal sub-pattern assignment distance in multiple extended target tracking

CHEN Hui^{1†}, LIU Ya-ting¹, ZHANG Shuang-qing¹, HAN Chong-zhao²

(1. School of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou Gansu 730050, China;
2. Institute of Integrated Automation, Xi'an Jiaotong University, Xi'an Shaanxi 710049, China)

Abstract: To solve the problem of sensor management in multiple extended target tracking optimization, on the basis of the random finite set (RFS), a sensor management algorithm is proposed through the weighted optimal sub-pattern assignment (W-OSPA) distance. First, in the framework of partially observable Markov decision process (POMDP) theory, the basic sensor management method is given in multiple extended target tracking based on the ellipse assumption of inverse Wishart distribution. Then, the W-OSPA distance is used to solve the dispersion of the multiple extended target posterior distribution and correspondingly the sensor management strategy is designed to obtain the optimal multiple extended target state estimation by minimizing dispersion. After that, the decision of optimal sensor management scheme is made through the proposed numerical solution method of dispersion. The simulation experiments based on the OSPA distance evaluation verify that the proposed sensor management algorithm has a better estimation effect on the centroid motion state and the ellipse shape of multiple extended target than other algorithms.

Key words: sensor management; random finite set; W-OSPA; multiple extended target tracking; dispersion

Citation: CHEN Hui, LIU Yating, ZHANG Shuangqing, et al. Sensor management method based on weighted optimal sub-pattern assignment distance in multiple extended target tracking. *Control Theory & Applications*, 2022, 39(5): 887 – 896

1 引言

随着传感器技术和信息融合技术的快速发展, 传感器可以根据不同的任务目的进行工作方式及运行

参数的最优配置, 这就是传感器管理. 传感器管理通常依照某一评价准则对传感器给定参数进行调节^[1-3], 以达到监控系统整体效用最大化的目的. 传感器管理

收稿日期: 2021-02-01; 录用日期: 2021-08-05.

[†]通信作者. E-mail: huich78@hotmail.com; Tel.: +86 931-2973506.

本文责任编辑: 陈积明.

国家自然科学基金项目(62163023, 61873116, 61763029), 国防基础科研项目(JCKY2018427C002), 甘肃省教育厅产业支撑计划项目(2021CYZC-02)资助.

Supported by the National Natural Science Foundation of China (62163023, 61873116, 61763029), the National Defense Basic Research Project (JCKY2018427C002) and the Industrial Support Project of Education Department of Gansu Province (2021CYZC-02).

问题通常在部分可观测马尔科夫决策过程(partially observable Markov decision processes, POMDP)理论框架下展开研究^[4-5]。然而,在复杂的多目标跟踪中,由于在状态空间和量测空间存在多维不确定因素,为传感器管理技术研究增加了难度。

利用多目标滤波器可对复杂环境下的多目标信息进行有效感知。其中,感知可为传感器管理决策提供信息依据,进而获取以优化滤波性能为目的的最佳量测信息^[6-7]。一般来说,获取最佳量测过程的方法有两种,一种是基于信息论的传感器管理方法,该方法利用多目标的概率分布来建立评价准则。通常使用散度函数(如Rényi散度)来度量信息量的差异^[8-9],将量测空间所选散度函数的统计期望作为评价函数,在信息增益最大化的准则下解决传感器管理问题。虽然,基于信息论的传感器管理方法能够使得系统信息增量最大化,但在复杂的实际环境中容易忽略传感器管理任务的实际需求。而基于任务论的传感器管理方法^[10-11]目的性更强,这类方法更加注重跟踪系统的预期目标,以具体任务的需求建立传感器管理的评价准则作为决策最优管理的依据。基于此,本文重点研究基于任务论的传感器管理方法,其任务需求是研究得到多目标后验分布的离差,从而以离差最小化优化多扩展目标含形状信息的状态估计。

传统的多目标跟踪假设目标为点目标,即每个时刻一个目标至多对应一个量测。然而随着现代传感器分辨率不断提高,一个目标可以由多个量测源产生多个量测,该目标被称为扩展目标(extended target, ET),此时的跟踪问题被称为扩展目标跟踪(ET tracking, ETT)。而多扩展目标跟踪(multiple ETT, METT)问题是利用各目标的多源量测信息,可基于信息融合技术对多目标特征信息进行更深层次的估计,其已经成为现代目标跟踪系统的热门议题。但是,由于扩展目标每个采样周期对应了多个量测,这进一步加剧了量测关联关系的不确定性和目标的不确定性,使得METT问题的求解愈加困难。值得一提的是,在有限集统计(finite set statistics, FISST)理论框架下^[12-14],多目标状态和量测分别被建模为随机有限集(random finite set, RFS)的形式,该方法避免直接应对目标和量测之间复杂的数据关联决策,直接由集值随机变量的贝叶斯递推滤波解决多目标估计问题。鉴于RFS方法的这一便利性,基于RFS多扩展目标跟踪的研究备受关注。Mahler首次提出了概率假设密度(probability hypothesis density, PHD)滤波器^[15],并将其由点目标跟踪推广至扩展目标跟踪,实现了扩展目标概率假设密度(ET-PHD)滤波器^[16]。Granstrom在其基础上给出了ET-PHD滤波算法高斯混合形式,即扩展目标高斯混合概率假设密度(ET Gaussian mixture PHD, ET-GM-PHD)滤波器^[17]。基于RFS的多目标滤波方法极大的

推动了多扩展目标跟踪^[18-19]的研究。

如何利用由监控系统获得的多源量测信息来估计目标的形状特征是现阶段扩展目标跟踪研究的热点。针对该问题, Koch提出了基于随机矩阵(random matrix model, RMM)模型的多扩展目标跟踪算法^[20],该方法利用椭圆基本形状假设描述扩展目标的基本轮廓信息,而椭圆是一种经典的抽象模型,且保留了大小和方向这两个基本特征,能够在杂波环境和量测精度低的情况下有效刻画扩展目标的形状特征,这对于目标特征的有效提取和目标识别具有重要的现实意义。RMM的理论基础是在乘积运算的条件下依据威沙特分布和逆威沙特分布概率密度存在的闭合性质。若将多扩展目标的运动状态建模为高斯分布,进一步将多目标的形状信息利用可描述椭圆信息的服从逆威沙特分布的随机矩阵去建模,其形状的演变建模为威沙特分布,则可通过贝叶斯递推对目标的运动状态和形状进行联合递推估计。随后,在杂波和漏检的情况下, Granstrom等将RMM模型结合扩展目标GM-PHD滤波框架,实现了对多目标运动状态和扩展状态的联合跟踪估计,即提出了高斯逆威沙特概率假设密度(Gaussian inverse Wishart-PHD, GIW-PHD)滤波器^[21]和高斯逆威沙特势概率假设密度(Gaussian inverse Wishart cardinalized PHD, GIW-CPHD)滤波器^[22]。此外, Baum等提出了随机超曲面(random hypersurface model, RHM)模型的建模方法^[23-24],在杂波较少和量测精度高的条件下,可以直接对不规则形状目标跟踪估计。

在杂波环境且目标量测误差较高的情况下, METT存在形状估计以及质心估计精度低的问题。本文利用传感器管理的方法,通过对传感器参数进行合理配置,以获得最佳量测信息达到对多扩展目标形状和运动状态进行联合跟踪估计优化的目的。然而,现阶段出现的传感器管理方法大多基于点目标提出,本文重点讨论椭圆轮廓多扩展目标跟踪优化中的传感器管理方法。

本文的重点和创新点描述如下:在POMDP理论框架下,基于RFS研究多扩展目标跟踪优化中的传感器管理方法。本文基于任务论以提高多扩展目标状态估计精度为期望设计传感器管理策略,利用加权最优子模式分配(weighted optimal sub-pattern assignment, W-OSPA)距离^[25]依据目标的运动状态、扩展状态和量测率综合评价多扩展目标状态估计的质量,并利用W-OSPA距离构造评价函数对多扩展目标后验分布的离差进行量化,通过蒙特卡罗方法推导出离差的具体数值求解方法,并以离差最小化为最优准则进行传感器管理方法的研究。最后,构造多扩展目标跟踪优化的仿真实验,验证所提方法的有效性。

2 系统建模及问题描述

2.1 多扩展目标RFS建模

假设 k 时刻多扩展目标的状态集合可以表示为

$$Y_k = \{\xi_k^{(i)}\}_{i=1}^{N_{\xi,k}}, \xi_k^{(i)} = (\gamma_k^{(i)}, \mathbf{x}_k^{(i)}, \mathbf{X}_k^{(i)}), \quad (1)$$

其中: 随机变量 $\gamma_k^{(i)} > 0$ 表示泊松率, $\mathbf{x}_k^{(i)}$ 表示目标的运动状态, 用来描述目标的位置和运动参数, $\mathbf{X}_k^{(i)}$ 表示目标的扩展状态, 用来描述目标的形状信息, $|Y_k| = N_{\xi,k}$ 表示集合中元素的数目.

1) 运动状态模型.

k 时刻多扩展目标的运动状态模型定义为

$$\mathbf{x}_{k+1}^{(i)} = (F_{k+1|k} \otimes I_d) \mathbf{x}_k^{(i)} + \mathbf{w}_{k+1}^{(i)}, \quad (2)$$

式中: $\mathbf{w}_{k+1}^{(i)}$ 表示零均值的高斯过程噪声, 方差为 $\Delta_{k+1|k}^{(i)} = Q_{k+1|k} \otimes \mathbf{X}_{k+1}^{(i)}$, $Q_{k+1|k}$ 表示过程噪声协方差矩阵, $\mathbf{X}_{k+1}^{(i)}$ 表示 $d \times d$ 的正定对称矩阵, d 表示目标扩展状态的维数, I_d 表示 $d \times d$ 维的单位矩阵, $A \otimes B$ 表示矩阵 A 和矩阵 B 的克罗内克积, $F_{k+1|k}$ 表示状态转移矩阵.

2) 量测模型.

k 时刻多扩展目标的量测模型定义为

$$\mathbf{z}_k^{(j)} = h(\mathbf{x}_k^{(i)}, \mathbf{x}_{s,k}(u)) + \mathbf{e}_k^{(j)} = (H_k \otimes I_d)(\mathbf{x}_k^{(i)} - \mathbf{x}_{s,k}(u)) + \mathbf{e}_k^{(j)}, \quad (3)$$

其中: $\mathbf{e}_k^{(j)} \sim (\mathbf{e}_k^{(j)}; 0, \mathbf{X}_k^{(i)})$, $\mathbf{e}_k^{(j)}$ 为量测噪声, 每个目标生成的量测数服从泊松分布, $\mathbf{x}_{s,k}(u)$ 表示 k 时刻传感器管理方案 u 对应的传感器位置. 传感器监测到目标的量测集是一个RFS的形式, 表示为 $\Theta_k(\mathbf{x}_k)$, 考虑到杂波等因素的影响, k 时刻传感器实际接收到的多扩展目标量测集 Z_k 可建模为

$$Z_k = \left[\bigcup_{\mathbf{x}_k \in Y_k} \Theta_k(\mathbf{x}_k) \right] \cup K_k, \quad (4)$$

其中 K_k 表示 k 时刻传感器接收到杂波构成的集合, 并且该杂波过程服从参数为 λ_k 的泊松分布.

3) 形态模型.

目标的扩展状态被建模为椭圆, 可用一个正定矩阵 $\mathbf{X}_k^{(i)}$ 来描述, 即

$$\mathbf{X}_k^{(i)} = M(\varphi_k^{(i)}) \text{diag}\{\sigma_{k,1}^2, \sigma_{k,2}^2\} M^T(\varphi_k^{(i)}), \quad (5)$$

$$M(\varphi_k^{(i)}) = \begin{bmatrix} \cos \varphi_k^{(i)} & -\sin \varphi_k^{(i)} \\ \sin \varphi_k^{(i)} & \cos \varphi_k^{(i)} \end{bmatrix}, \quad (6)$$

其中: 椭圆中心点(即目标质心)由 \mathbf{x}_k 的位置分量确定, 方向角由旋转矩阵 $M(\varphi_k^{(i)})$ 确定, 大小(即长短轴)由随机矩阵 $\mathbf{X}_k^{(i)}$ 的特征值 $\sigma_{k,1}^2$ 和 $\sigma_{k,2}^2$ 确定, 椭圆长半轴和短半轴分别通过求解 $\mathbf{X}_k^{(i)}$ 特征值的平方根得到.

目标扩展状态的转移密度函数用Wishart分布可以表示为

$$p(\mathbf{X}_{k+1}^{(i)} | \mathbf{X}_k^{(i)}) = \mathcal{W}(\mathbf{X}_{k+1}^{(i)}; n, \frac{\mathbf{X}_k^{(i)}}{n}), \quad (7)$$

其中 $p(\mathbf{X}_{k+1}^{(i)} | \mathbf{X}_k^{(i)})$ 描述了形状矩阵 $\mathbf{X}_k^{(i)}$ 到 $\mathbf{X}_{k+1}^{(i)}$ 的演化规律, 自由度 n 描述了形状演化的不确定性.

4) 量测率模型.

假设量测率是随时间近似恒定的, 那么

$$\gamma_{k+1}^{(i)} = \gamma_k^{(i)}. \quad (8)$$

本文假设扩展目标产生的量测个数服从泊松分布, 且其均值为服从参数为 γ_k 的伽玛分布. 量测率通常取决于目标尺寸及其与传感器的距离(即目标的大小和位置), 而为这些依赖关系建立一个通用的数学模型是非常困难的. 模型(8)简化了这些依赖性, 并为后续的分析研究提供了很大的便利.

2.2 多扩展目标跟踪中传感器管理问题提出

多扩展目标跟踪中的传感器管理方法一般是在POMDP理论框架下进行的. 首先定义在POMDP理论框架下传感器管理的相关要素: 当前的多扩展目标状态信息, 一套可实现传感器动作集合以及相应的评价函数. 其中, 多扩展目标状态信息可用多扩展目标后验分布 $\mathcal{GGIW}_{k+H}(\xi_k | Z_{1:k})$ 描述, 表示 k 时刻向后 H 步的多扩展目标后验分布, U_k 表示传感器动作集合, $Z_{k+1:k+H}(u_H)$ 表示传感器方案 $u_H (u_H \in U_k)$ 所对应的理想量测集(predicted ideal measurement set, PIMS). 其次, 由于随着 H 的增加, 将会导致计算复杂度加大, 为了便于计算, 本文选用 $H = 1$ 的管理方案, 该方案称为“Myopic”方案^[26-27]. 对于每个传感器动作 u 都有一个相应的评价函数 $\mathcal{V}(u)$, 若用 \hat{u}_k 表示最优传感器管理序列, 则通过以下准则确定该最优序列:

$$\hat{u}_k = \arg \min_{u \in U_k} \mathbf{E}[\mathcal{V}_{k+H}(u)], \quad (9)$$

即最优序列 \hat{u}_k 通过评价函数 $\mathcal{V}_{k+H}(u)$ 最小化来确定.

本文以多扩展目标后验分布离差最小化为最优准则, 进行传感器参数的控制, 评价函数 $\mathcal{V}_{k+H}(u)$ 可以表示为

$$\mathcal{V}_{k+H}(u) = D(\mathcal{GGIW}_{k+H}(\xi_k | Z_{1:k}, Z_{k+1:k+H}(u))). \quad (10)$$

3 伽玛高斯逆威沙特-PHD滤波器

3.1 预测过程

GGIW-PHD滤波器预测方程由存活和新生目标两部分组成, 其中存在目标的PHD可以表示为

$$D_{k|k-1}^S(\xi_{k|k-1}) = \sum_{j=1}^{J_{k-1|k-1}} w_{k|k-1}^{(j)} \mathcal{GGIW}(\xi_{k|k-1}; \zeta_{k|k-1}^{(j)}), \quad (11)$$

其中: $w_{k|k-1}^{(j)} = p_S w_{k-1|k-1}^{(j)}$, p_S 表示目标的存活概率, $\{\alpha_{k|k-1}^{(j)}, \beta_{k|k-1}^{(j)}, m_{k|k-1}^{(j)}, P_{k|k-1}^{(j)}, v_{k|k-1}^{(j)}, V_{k|k-1}^{(j)}\}$ 是GGIW分布的参数集合 $\zeta_{k|k-1}^{(j)}$.

伽玛分布中的形状参数和逆比例参数分别表示为

$$\alpha_{k|k-1}^{(j)} = \frac{\alpha_{k-1|k-1}^{(j)}}{\eta_{k-1}}, \quad \beta_{k|k-1}^{(j)} = \frac{\beta_{k-1|k-1}^{(j)}}{\eta_{k-1}}. \quad (12)$$

高斯分布中的均值和协方差分别表示为

$$\mathbf{m}_{k|k-1}^{(j)} = (F_{k|k-1} \otimes I_d) \mathbf{m}_{k-1|k-1}^{(j)}, \quad (13)$$

$$\mathbf{P}_{k|k-1}^{(j)} = F_{k|k-1} \mathbf{P}_{k-1|k-1}^{(j)} F_{k|k-1}^T + Q_{k|k-1}. \quad (14)$$

逆威沙特分布中的自由度和逆尺度矩阵分别表示为

$$\mathbf{v}_{k|k-1}^{(j)} = e^{-T_s/\tau} \mathbf{v}_{k-1|k-1}^{(j)}, \quad (15)$$

$$\mathbf{V}_{k|k-1}^{(j)} = \frac{\mathbf{v}_{k|k-1}^{(j)} - d - 1}{\mathbf{v}_{k-1|k-1}^{(j)} - d - 1} \mathbf{V}_{k-1|k-1}^{(j)}, \quad (16)$$

其中: T_s 表示采样时间, τ 是时间衰减常数, $\frac{1}{\eta_{k-1}}$ 表示遗忘因子.

新生目标的PHD可以表示为

$$D_k^b(\boldsymbol{\xi}_k) = \sum_{j=1}^{J_{b,k}} w_{b,k}^{(j)} \mathcal{GGIW}(\boldsymbol{\xi}_k; \boldsymbol{\zeta}_{b,k}^{(j)}). \quad (17)$$

整体的GGIW-PHD预测方程 $D_{k|k-1}(\boldsymbol{\xi}_k)$ 是由式(11)–(17)构成, 总体预测分量表示为

$$J_{k|k-1} J_{k-1|k-1} + J_{b,k}.$$

3.2 更新过程

若扩展目标在同一时刻产生量测数目服从泊松分布, 传感器将检测到来自多个目标的多个量测. 因此在更新多扩展目标概率密度之前需要对量测集进行划分, 将来自同一目标的量测划分为一簇. 本文采用距离划分方法进行量测集的划分, 下面给出多扩展目标概率密度的量测更新过程.

更新后的扩展目标PHD可以表示为

$$D_{k|k}(\boldsymbol{\xi}_k) = D_{k|k}^{ND}(\boldsymbol{\xi}_k) + D_{k|k}^D(\boldsymbol{\xi}_k, W) = \sum_{j=1}^{J_{k|k-1}} w_{k|k}^{(j)} \mathcal{GGIW}(\boldsymbol{\xi}_k; \boldsymbol{\zeta}_{k|k}^{(j)}) + \sum_{p \in \mathcal{Z}_k} \sum_{W \in \mathcal{P}} \sum_{j=1}^{J_{k|k-1}} w_{k|k}^{(j),p,W} \mathcal{GGIW}(\boldsymbol{\xi}_k; \boldsymbol{\zeta}_{k|k}^{(j),W}), \quad (18)$$

$$w_{k|k}^{(j)} = (1 - (1 - e^{-\theta^{(j)}}) p_D) w_{k|k-1}^{(j)}, \quad (19)$$

$$\boldsymbol{\zeta}_{k|k}^{(j)} = \boldsymbol{\zeta}_{k|k-1}^{(j)}, \quad (20)$$

其中: $D_{k|k}^{ND}(\cdot)$ 和 $D_{k|k}^D(\boldsymbol{\xi}_k, W)$ 分别表示漏检目标和检测到目标的强度函数, $\theta^{(j)} = \frac{\alpha_{k|k}^{(j)}}{\beta_{k|k}^{(j)}}$ 表示每个周期内单

扩展目标量测数的均值, $(1 - e^{-\theta^{(j)}})$ 为量测数至少为1的概率, p_D 是传感器检测概率, $(1 - e^{-\theta^{(j)}}) p_D$ 表示传感器在每周期内至少检测到一个目标量测的概率, 即有效检测概率.

更新后的GGIW分布参数表示为

$$\mathbf{m}_{k|k}^{(j),W} = \mathbf{m}_{k|k-1}^{(j)} + (K_{k|k-1}^{(j),W} \otimes I_d) \boldsymbol{\varepsilon}_{k|k-1}^{(j),W}, \quad (21)$$

$$\mathbf{P}_{k|k}^{(j),W} = \mathbf{P}_{k|k-1}^{(j)} - K_{k|k-1}^{(j),W} \mathbf{S}_{k|k-1}^{(j),W} (K_{k|k-1}^{(j),W})^T, \quad (22)$$

$$\mathbf{v}_{k|k}^{(j),W} = \mathbf{v}_{k|k-1}^{(j)} + |W|, \quad (23)$$

$$\mathbf{V}_{k|k}^{(j),W} = \mathbf{V}_{k|k-1}^{(j)} + N_{k|k-1}^{(j),W} + Z_k^W, \quad (24)$$

$$\boldsymbol{\alpha}_{k|k}^{(j),W} = \boldsymbol{\alpha}_{k|k-1}^{(j)} + |W|, \quad (25)$$

$$\boldsymbol{\beta}_{k|k}^{(j),W} = \boldsymbol{\beta}_{k|k-1}^{(j)} + 1, \quad (26)$$

$$w_{k|k}^{(j),p,W} = \frac{\omega_p}{d_W} e^{-\theta^{(j),W}} w_{k|k-1}^{(j)} \left(\frac{\theta^{(j),W}}{\lambda_{FA,k}} \right)^{|W|} p_D^{(j)} \mathcal{L}^{(j),W}, \quad (27)$$

其中: ω_p 表示划分 p 对应的权值, d_W 表示每个划分子集对应的权值, $\lambda_{FA,k}$ 是 k 时刻的杂波平均值, $\theta^{(j),W} = \frac{\alpha_{k|k}^{(j),W}}{\beta_{k|k}^{(j),W}}$, 对于检测到目标的所有分量 j 以及划分 p 中的所有单元 W : 质心量测、散射矩阵、信息因素、增益向量、信息向量和信息矩阵的具体公式分别如下:

$$\bar{z}_k^W = \frac{1}{|W|} \sum_{z_k^{(j)} \in W} z_k^{(j)}, \quad (28)$$

$$Z_k^W = \sum_{z_k^{(j)} \in W} (z_k^{(j)} - \bar{z}_k^W)(z_k^{(j)} - \bar{z}_k^W)^T, \quad (29)$$

$$S_{k|k-1}^{(j),W} = H_k P_{k|k-1}^{(j)} H_k^T + \frac{1}{|W|}, \quad (30)$$

$$K_{k|k-1}^{(j),W} = P_{k|k-1}^{(j)} H_k^T (S_{k|k-1}^{(j),W})^{-1}, \quad (31)$$

$$\boldsymbol{\varepsilon}_{k|k-1}^{(j),W} = \bar{z}_k^W - (H_k \otimes I_d) \mathbf{m}_{k|k-1}^{(j)}, \quad (32)$$

$$N_{k|k-1}^{(j),W} = (S_{k|k-1}^{(j),W})^{-1} \boldsymbol{\varepsilon}_{k|k-1}^{(j),W} (\boldsymbol{\varepsilon}_{k|k-1}^{(j),W})^T. \quad (33)$$

扩展目标的似然函数计算如下:

$$\mathcal{L}^{(j),W} = \mathcal{L}^{(j),\gamma} \mathcal{L}^{(j),\mathbf{x},\mathbf{X}}, \quad (34)$$

$$\mathcal{L}^{(j),\gamma} = \frac{\Gamma(\boldsymbol{\alpha}_{k|k}^{(j),|W|}) (\boldsymbol{\beta}_{k|k-1}^{(j)})^{\boldsymbol{\alpha}_{k|k-1}^{(j)}}}{\Gamma(\boldsymbol{\alpha}_{k|k-1}^{(j)}) (\boldsymbol{\beta}_{k|k}^{(j),W})^{\boldsymbol{\alpha}_{k|k}^{(j),W}}}, \quad (35)$$

$$\mathcal{L}^{(j),\mathbf{x},\mathbf{X}} = \frac{(\pi^{|W|} |W|)^{-d/2} |V_{k|k-1}^{(j)}|^{\frac{v_{k|k-1}^{(j)}}{2}} \Gamma_d\left(\frac{v_{k|k}^{(j),W}}{2}\right)}{(S_{k|k-1}^{(j),W})^{d/2} |V_{k|k}^{(j),W}|^{\frac{v_{k|k}^{(j),W}}{2}} \Gamma_d\left(\frac{v_{k|k}^{(j)}}{2}\right)}, \quad (36)$$

$$d_W = \delta_{|W|,1} + \sum_l^{J_{k|k-1}} e^{-\theta^{(j),W}} \left(\frac{\theta^{(j),W}}{\lambda_{FA,k}} \right)^{|W|} p_D^{(j)} \mathcal{L}^{(j),W} w_{k|k-1}^{(j)}, \quad (37)$$

$$w_p = \frac{\prod_{W \in \mathcal{P}} d_W}{\sum_{p' \in \mathcal{Z}_k} \prod_{W' \in \mathcal{P}'} d_{W'}}, \quad (38)$$

其中: $|V|$ 表示矩阵 V 的行列式, $|W|$ 表示单元 W 中量测的数目, $\Gamma(\cdot)$ 表示伽玛函数, $\Gamma_d(\cdot)$ 表示多元伽玛函数. 假设 $|p_p|$ 表示第 p 个划分中单元 W 的数目, 更新后的PHD高斯分量数 $J_{k|k} = J_{k|k-1} + J_{k|k-1} \sum_{p=1}^P |p_p|$.

4 基于W-OSPA距离的传感器管理方法

在多目标跟踪领域, 设计合适的评价函数以满足滤波的预期性能是制定基于任务论传感器管理方法的核心. 多目标状态估计是由更新的后验概率密度计算得到, 其精度可由多目标后验分布在其均值周围的离差所表征. 而在多目标滤波的场景中, 需要一个合适的距离来量化多扩展目标运动状态、扩展(形状)状态和量测率的估计结果, OSPA距离已被推广为度量集合之间距离的理想指标^[28-29], 而W-OSPA距离相较于OSPA距离是联合考虑多目标的运动状态、扩展状态和量测率来得到多目标的估计误差. 以下使用W-OSPA距离构造多扩展目标分布后验离差, 进行相应传感器管理方法研究.

4.1 OSPA距离函数

集合之间的距离可以采用优化分配的方法对集合之间的元素进行关联配对. 假设 k 时刻两个多目标状态集合可以分别表示为: 真实的多目标状态 $\mathbf{O}_k = \{\mathbf{x}_k^1, \mathbf{x}_k^2, \dots, \mathbf{x}_k^N\}$, 估计的多目标状态 $\hat{\mathbf{O}}_k = \{\hat{\mathbf{x}}_k^1, \hat{\mathbf{x}}_k^2, \dots, \hat{\mathbf{x}}_k^M\}$, 其中 M 和 N 分别表示真实的目标数和估计的目标数, 若 $N \leq M$, 多目标状态集合 \mathbf{O}_k 和 $\hat{\mathbf{O}}_k$ 之间的距离为

$$\bar{d}_p^{(c)}(\mathbf{O}_k, \hat{\mathbf{O}}_k) = \left\{ \frac{1}{M} \left[\min_{\pi(l) \in \prod_{l=1}^N} \sum_{l=1}^N (d(c, \mathbf{x}_k^l, \hat{\mathbf{x}}_k^{\pi(l)}))^p + c^p \times \Psi \right] \right\}^{\frac{1}{p}}. \quad (39)$$

如果 $N > M$, $\bar{d}_p^{(c)}(\mathbf{O}_k, \hat{\mathbf{O}}_k) = \bar{d}_p^{(c)}(\hat{\mathbf{O}}_k, \mathbf{O}_k)$. 其中, $\Psi = M - N$, $d(c, \mathbf{x}_k^l, \hat{\mathbf{x}}_k^{\pi(l)}) = \min(c, \|\mathbf{x}_k^l - \hat{\mathbf{x}}_k^{\pi(l)}\|)$, p 表示阶数, c 表示每个势误差的平均距离误差, \prod_M 表示集合 $\{1, 2, \dots, M\}$ 的所有排列方式, $\pi(l)$ 表示其中的第 l 种排列方式. 该距离被解释为每个目标的 p 阶误差, 包括每个目标的 p 阶位置误差和每个目标势的 p 阶误差, 阶数系数 p 决定对异常值的敏感度, 截断系数 c 决定分配给目标势和位置误差惩罚的相应权重. 正是由于上述特性, OSPA距离被推广为度量集合之间距离的理想指标.

4.2 W-OSPA距离函数

多扩展目标的状态不仅包含运动状态还有扩展状态和量测率. 因此, 本文用一个加权OSPA距离的方法, 即W-OSPA距离, 对多扩展目标状态估计的效果进行综合评价. 假设多扩展目标的真实状态集合和估计状态集合分别表示为 $\xi_k^{(j)}$ 和 $\hat{\xi}_{k|k}^{(i)}$, 那么它们之间的距离可以表示为

$$d(\xi_k^{(j)}, \hat{\xi}_{k|k}^{(i)}) = \frac{w_\gamma}{c_\gamma} d_{j,i}^{(c_\gamma)} + \frac{w_x}{c_x} d_{j,i}^{(c_x)} + \frac{w_X}{c_X} d_{j,i}^{(c_X)}, \quad (40)$$

其中:

$$\begin{cases} w_\gamma + w_x + w_X = 1, \\ d_{j,i}^{(c_\gamma)} = \min(c_\gamma, |\gamma_k^{(j)} - \hat{\gamma}_{k|k}^{(i)}|), \\ d_{j,i}^{(c_x)} = \min(c_x, \|\mathbf{x}_k^{(j)} - \hat{\mathbf{x}}_{k|k}^{(i)}\|_2), \\ d_{j,i}^{(c_X)} = \min(c_X, \|\mathbf{X}_k^{(j)} - \hat{\mathbf{X}}_{k|k}^{(i)}\|_F), \end{cases} \quad (41)$$

其中: $|\cdot|$ 表示绝对值, $\|\cdot\|_2$ 表示欧几里得范数, $\|\cdot\|_F$ 表示弗罗贝尼乌斯范数, c_γ, c_x, c_X 分别表示量测率、运动状态和扩展状态的截断系数. 一个最优分配 $\bar{\pi}$ 可以表示为

$$\bar{\pi} = \arg \min_{\pi \in \prod_{\pi}} \sum_{i=1}^{N_{\xi,k}} (d_{j,i}^{(c_l)})^p. \quad (42)$$

因此, 多扩展目标的W-OSPA距离可以表示为

$$\bar{d}_p^{(c_l)} = \left(\frac{1}{n} \sum_{i=1}^{N_{\xi,k}} (d_{i,\bar{\pi}(i)}^{(c_l)})^p + c_l^p (\hat{N}_{\xi,k} - N_{\xi,k}) \right)^{\frac{1}{p}}, \quad (43)$$

其中: $c_l = c_\gamma + c_x + c_X$, $N_{\xi,k}$ 表示真实的目标数, $\hat{N}_{\xi,k}$ 表示估计的目标数.

4.3 传感器管理方案的求解

根据预测的GGIW分布 $GGIW(\xi_{k|k-1}; \zeta_{k|k-1}^{(j)})$, 提取预测的多扩展目标状态

$$\hat{\xi}_{k|k-1} = \text{State extraction}(GGIW(\xi_{k|k-1}; \zeta_{k|k-1}^{(j)})), \quad (44)$$

$\hat{\xi}_{k|k-1}$ 表示预测的多扩展目标状态集合. 为了方便传感器能够快速有效地做出决策, 本文在 $H = 1$ 的条件下构造PIMS. 在检测概率 $p_D(\xi_k) = 1$, 不考虑杂波和噪声的理想情况下, 根据 $\hat{\xi}_{k|k-1}$ 去构造多扩展目标PIMS. 对于每一个传感器管理方案 $u \in U_k$ 都有一个相应的PIMS, 可表示为

$$Z_k(u) = \bigcup_{\hat{\mathbf{x}}_k^{(j)} \in \hat{\xi}_{k|k-1}} \{h(\hat{\mathbf{x}}_k^{(j)}, \mathbf{x}_{s,k}(u), \mathbf{X}_{k|k-1}^{(j)})\}. \quad (45)$$

即通过预测的位置分量 $\hat{\mathbf{x}}_k^{(j)} \in \hat{\xi}_{k|k-1}$, 传感器位置 $\mathbf{x}_{s,k}(u)$ 以及预测的 $\mathbf{X}_{k|k-1}^{(j)}$, 结合量测生成模型构造 $Z_k(u)$. 其中, $\mathbf{X}_{k|k-1}^{(j)}$ 表示预测的扩展状态, 根据预测的自由度 $\mathbf{v}_{k|k-1}^{(j)}$ 和逆尺度矩阵 $\mathbf{V}_{k|k-1}^{(j)}$ 进行计算

$$\mathbf{X}_{k|k-1}^{(j)} = \frac{\mathbf{V}_{k|k-1}^{(j)}}{\mathbf{v}_{k|k-1}^{(j)} - 2d - 2}. \quad (46)$$

利用 $Z_k(u)$ 对预测的强度函数 $D_{k+1|k}(\xi_{k+1})$ 更新, 进而得到传感器管理方案 u 对应的伪更新强度函数

$$D_{k|k}(\xi_k, u) = D_{k|k}^{ND}(\xi_k, u) + \sum_{p \in Z_k} \sum_{W \in P} D_{k|k}^D(\xi_k, W, u), \quad (47)$$

其中伪更新的GGIW($\xi_k; \zeta_{k|k}^{(j,W)}, u$)分布参数计算参照式(18)–(38), 进而提取伪更新的多扩展目标状态, 对相应的多扩展目标伪更新中的运动状态集合 $\xi_{k,u}$ 进行提取

$$\xi_{k,u} = \text{State extraction}(\text{GGIW}(\xi_k; \zeta_{k|k}^{(j,W)}, u)). \quad (48)$$

用 $\bar{d}_p^{(c_l)}(\xi_k, \hat{\xi}_{k|k})$ 表示 ξ_k 和 $\hat{\xi}_{k|k}$ 两个集合之间的W-OSPA距离, 根据式(10)–(43), 本文以W-OSPA距离构造多扩展目标估计的离差, 其可表示为

$$\begin{aligned} \mathcal{V}(u; \xi_{k|k-1}) &= \mathbf{E}[\bar{d}_p^{(c_l)}(\xi_{k,u}, \mathbf{E}[\xi_{k,u}])] = \\ &= \mathbf{E}[\bar{d}_p^{(c_l)}(\xi_{k,u}, \bar{\xi}_{k,u})] = \\ &= \int \bar{d}_p^{(c_l)}(\xi_{k,u}, \bar{\xi}_{k,u}) \pi_{k,u}(\xi) \delta \xi, \quad (49) \end{aligned}$$

其中: $\bar{\xi}_{k,u} = \mathbf{E}[\xi_{k,u}] = \int \xi \pi_{k,u}(\xi) \delta \xi$, $\pi_{k,u}(\cdot)$ 为多扩展目标后验分布. 为了计算上述评价函数, 依据 L 个蒙特卡罗(MC)样本的采样方法构造多扩展目标后验分布, $\pi_{k,u}(\xi)$ 可以最终被描述为

$$\begin{aligned} \pi_{k,u}(\xi) &\approx \text{MC}(w_{k|k}^{(j,W)}(u, \xi_{k,u}) \approx \\ &= \frac{1}{L} \sum_{i=1}^L \delta_{\xi^{(i)}_{k,u}}(\xi), \quad (50) \end{aligned}$$

其中 $w_{k|k}^{(j,W)}(u)$ 表示传感器管理方案 u 对应的GGIW分量权重. 通过以上采样方法, 计算多扩展目标伪更新高斯分布的离差, 最终的评价函数表示为

$$\mathcal{V}(u; \xi_{k|k-1}) = \frac{1}{L} \sum_{i=1}^L \bar{d}_p^{(c_l)}(\xi_{k,u}^{(i)}, \bar{\xi}_{k,u}), \quad (51)$$

最后, 依据式(9)确定最优的传感器管理方案.

4.4 算法程序伪码

为了说明算法流程, 列出扩展目标跟踪传感器控制算法伪码如下:

输入: $\{w_{k-1}^{(j)}, m_{k-1}^{(j)}, P_{k-1}^{(j)}, v_{k-1}^{(j)}, V_{k-1}^{(j)}, \alpha_{k-1}^{(j)}, \beta_{k-1}^{(j)}\}_{j=1}^{J_{k-1}}$, 当前传感器位置 $x_{s,k-1}$,

步骤 1 预测与新生.

for $j = 1 : J_{k-1}$

根据式(11)–(16)可以得到存活目标的GGIW参数.

end for

for $j = 1 : J_{k-1} + J_{b,k}$

按式(17)得到新生目标的GGIW参数.

end for

由此得到预测的多扩展目标GGIW分布.

步骤 2 传感器管理.

根据预测的多扩展目标GGIW分布, 提取预测多扩展目标状态集 $\hat{\xi}_{k|k-1}$, 确定所有可能的管理集合 U_k .

for all $u \in U_k$ do

通过方案 u 确定传感器位置 $x_{s,k}(u)$, 并按式(45)生成相应的理想量测集 $Z_k(u)$.

对每种控制方案的 $Z_k(u)$ 进行量测集划分, 然后根

据式(18)–(38)更新预测分布得到伪更新GGIW分布, 进而得到伪更新后验分布 $\pi_{k,u}$.

$\bar{\xi}_{k,u} \leftarrow \text{EAP}(\pi_{k,u});$

$\{\xi_{k,l}\}_{l=1}^L \leftarrow \text{MC}(\pi_{k,u}, L);$

$\mathcal{V}(u; \xi_{k|k-1}) \leftarrow 0;$

for all $l \in \{1, \dots, L\}$ do

$\mathcal{V}(u; \xi_{k|k-1}) \leftarrow \mathcal{V}(u; \xi_{k|k-1}) +$

$\frac{1}{L} \bar{d}_p^{(c_l)}(\xi_{k,u}, \bar{\xi}_{k,u});$

end for

end for

确定传感器管理方案.

$\hat{u} \leftarrow \arg \min_{u \in U_k} \mathcal{V}(u; \xi_{k|k-1}).$

则传感器在新的位置 $x_{s,k}(\hat{u})$ 接收到的实际量测为 $Z_k(\hat{u})$.

步骤 3 更新.

for $j = 1 : J_{k|k-1}$

由式(18)–(38)可以得到更新后相应的GGIW分量.

end for

步骤 4 高斯分量的删减与合并.

设定相应的阈值, 除去权值较小的高斯分量, 合并距离相近的高斯分量.

步骤 5 状态提取.

$\text{target_index} = \text{find}(w_k^{(i)} > 0.5)$, 提取目标状态集合 ξ_k^i . 求取目标个数, $\hat{N}_{k|k} = \text{length}(\text{target_index})$.

步骤 6 输出.

目标数 $\hat{N}_{k|k}$, 多扩展目标状态集合 Y_k , 传感器位置 $x_{s,k}$.

5 仿真分析

5.1 场景构建

在 $[-1000, 1000] \times [-1000, 1000](m^2)$ 的监控区域范围内设定有3个目标, 针对这3个目标构造多扩展目标跟踪场景并进行蒙特卡罗 (Monte Carlo, MC) 仿真实验, 通过设计不同的传感器管理方案进行对比并对实验结果进行分析. 按照文中对OSPA参数的解释, 结合实验数据分析, 选取OSPA距离函数的参数 $p = 1, c = 2$. 参考文献[25], 选取W-OSPA距离函数的参数分别为 $c_\gamma = 5, c_x = 10, c_X = 10, w_\gamma = 0.1, w_x = 0.7, w_X = 0.2$. 此外, 按照已有文献[21]的常规取值, 设定采样时间 $T_s = 1$ s, 时间衰减常数 $\tau = 5$, 遗忘因子 $\eta_k = 8$, 目标的存活概率和检测概率分别为 $p_D = 0.99$ 和 $p_S = 0.99$, 杂波平均数 $\lambda_{FA} = 5$, 高斯混合实现的最大高斯分量数 $J_{\max} = 100$. A 和 a 分别表示扩展状态的长半轴和短半轴, 3个目标的长半轴和短半轴均为 $A = 4$ 和 $a = 2$. 以椭圆长轴与笛卡尔坐标系 x 轴夹角为方向角, 逆时针方向为正方向, 椭圆方向角均设定为 45° . 每个扩展目标采样周期内的量测数目

服从均值 $\gamma = 15$ 的泊松分布. 目标的状态方程和量测方程如式(2)–(3)所示, 其中

$$F_{k+1|k} = \begin{bmatrix} 1 & T_s \\ 0 & 1 \end{bmatrix}, H_k = [1 \ 0], \quad (52)$$

$$Q_{k+1|k} = \Sigma^2(1 - e^{-(2T_s/\theta)}) \text{diag}\{[0 \ 1]\}, \quad (53)$$

式中 $\theta = 1 \text{ s}$, $\Sigma = 0.1 \text{ m}^2\text{s}$, 新生目标的个数 $J_{b,k} = 3$, 权重 $w_{b,k}^j = 0.1$, 新生目标的其他参数:

$$\mathbf{m}_{b,k}^{(j)} = (\mathbf{x}_0^{(j)})^T, \mathbf{P}_{b,k}^{(j)} = \text{diag}\{[100 \ 25]\}, \quad (54)$$

$$\mathbf{v}_{b,k}^{(j)} = 7, \mathbf{V}_{b,k}^{(j)} = \text{diag}\{[1 \ 1]\}, \quad (55)$$

$$\boldsymbol{\alpha}_{b,k}^{(j)} = 20, \boldsymbol{\beta}_{b,k}^{(j)} = 1. \quad (56)$$

假设在 k 时刻传感器位置为 $\mathbf{x}_{s,k} = [x_{s,k} \ y_{s,k}]^T$, 那么下一时刻传感器所有可能的位置集合 U_{k+1} 可表示为

$$U_{k+1} = \left\{ \left(x_{s,k} + jv_{s,c} \frac{T_s}{N_R} \cos\left(l \frac{2\pi}{N_\theta}\right), \right. \right. \\ \left. \left. y_{s,k} + jv_{s,c} \frac{T_s}{N_R} \sin\left(l \frac{2\pi}{N_\theta}\right), \right. \right. \\ \left. \left. j = 1, \dots, N_R; l = 1, \dots, N_\theta \right\}, \quad (57)$$

其中: $N_R = 2, N_\theta = 8$, 则传感器的管理方案共有 17 种(包括传感器处于静默状态). $v_{s,c}$ 是传感器自身容许的径向速度, 取值为 10 m/s .

5.2 多扩展目标不同状态估计性能评价

根据构建的仿真场景, 多扩展目标参数如表1所示, 多扩展目标真实运动轨迹如图1所示.

表 1 多扩展目标初始参数

Table 1 Initial parameters of multiple extended target

	新生时刻/s	消亡时刻/s	初始位置/m	速度/(m·s ⁻¹)
目标1	1	40	[200, 200]	[15, 15]
目标2	10	40	[-500, 500]	[13, -10]
目标3	20	30	[200, -600]	[10, 15]




图 1 目标的真实轨迹

Fig. 1 Actual target trajectories

为了验证所提传感器管理方案有效性, 本文将所提方案与另外3种不同方案进行对比. 其中, 方案1是“Stationary”, 即传感器保持静止. 方案2是“Prior zigzag”, 如图2所示1种先验方案, 即传感器按照预定轨迹运动. 方案3是“Random control”, 即从传感器动作集合所有方案中随机选择1种方案. 方案4是“W-OSPA based”, 即本文所提传感器管理方案.




图 2 方案2中的传感器控制轨迹

Fig. 2 Sensor control trajectory in the second control strategy

图3是单次MC仿真的多扩展目标形状估计的局部放大图. 从图中可以看出, 本文提出的传感器管理方案相比于其他3种方案, 对扩展目标形状的估计效果更加逼近于目标的真实椭圆轮廓, 可以有效体现所提传感器管理方案对目标质心位置与目标形状估计的一致性. 图4是本文所提传感器管理算法在单次仿真试验中的传感器运动轨迹. 在整个传感器管理过程中, 传感器会依据多扩展目标跟踪W-OSPA离差最小化的准则不断调节自身的位置, 以保证每周期都能获得最优的多扩展目标量测信息. 从图中还可以看到, 伴随着目标的新生和消亡, 传感器的位置会随之发生相应的变化. 这是由于随着目标的随机更替, 多扩展目标后验离差也会发生明显的改变, 为了适应这种变化传感器的位置会发生明显的机动控制, 使自己处于最佳观测的位置. 在目标数目突变完成后, 传感器会依据离差最小化的原则进行相应的传感器轨迹控制, 以满足传感器优化的预期性能.

图5是100次MC仿真实验多扩展目标位置估计的OSPA距离统计. 在多扩展目标跟踪中, 由于扩展目标对应多个量测源信息, 因此从图表看出各类方案对多扩展目标位置的估计精度都相对较高, 并且OSPA距离具有收敛的整体趋势. 然而, 从图5可以看出, 本文所提方案对多扩展目标位置的估计效果明显优于其他3种方案, 即该方案对多扩展目标位置的估计最为接近目标的真实位置, 在目标数目(势)稳定期间跟踪均呈显著的收敛趋势, 从而有效验证了所提方法的跟踪一致性. 由于所提传感器管理方案是基于GGIW分布多扩展目标跟踪的W-OSPA离差最小化建立传感

器管理的目标函数, 相对应的, 所提传感器管理方案可以有效的实现对多扩展目标运动状态的优化.




图3 多扩展目标形状估计效果

Fig. 3 Multiple extended target shape estimation effect




图4 单次MC方案4传感器控制轨迹

Fig. 4 Sensor control trajectory of single MC in the fourth control strategy

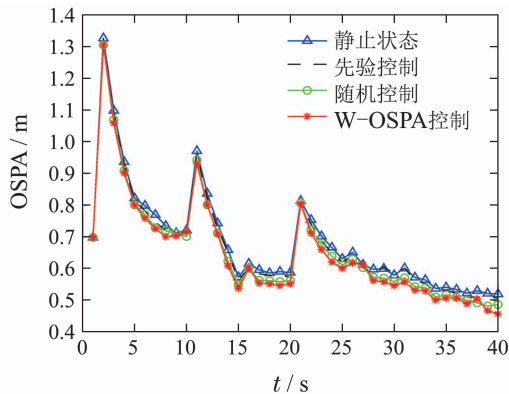


图5 4种传感器控制方案质心位置估计OSPA

Fig. 5 OSPA statistics of four control strategies to centroid position estimation

图6和图7分别是MC仿真实验中对多扩展目标长轴和短轴估计的OSPA距离, 表2是多扩展目标长轴和短轴估计的OSPA均值统计. 从图表中看出4种方案对多目标形状估计的优劣, 即本文所提算法对多扩展目标形状估计效果最好.

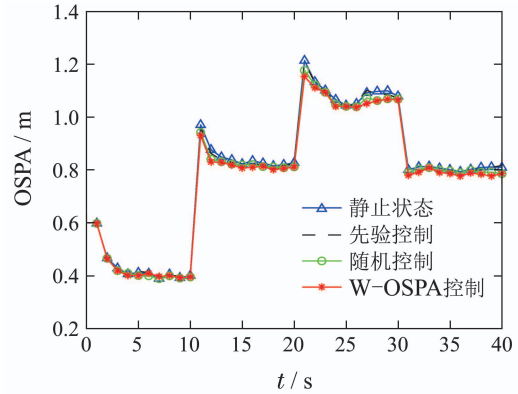


图6 长轴OSPA距离

Fig. 6 OSPA statistics of long axis




图7 短轴OSPA距离

Fig. 7 OSPA statistics of short axis

表2 各方案长轴和短轴的OSPA均值

Table 2 The mean value of OSPA of the long axis and short axis of each strategy

传感器管理方案	方案1	方案2	方案3	方案4
长轴/m	0.7961	0.7915	0.7840	0.7786
短轴/m	0.4532	0.4468	0.4385	0.4241

图8给出了以W-OSPA距离为综合评价指标对4种传感器管理方案下多扩展目标状态估计的对比结果, 表3是各方案下W-OSPA距离的统计均值. 从图表中可以明显看出所提传感器管理方案下的多扩展目标状态W-OSPA距离总体最小, 因此在对多扩展目标状态的综合优化上要优于其他3种方案. 因为基于W-OSPA的度量客观反映了多扩展目标综合状态(运动状态、形状、量测率)的估计效果, 所以所提算法对多扩展目标综合状态优化的效果得以验证.

图9显示了在100次MC仿真实验中传感器的所有运动轨迹, 即传感器运动轨迹云. 从图中可以看出在同一最优准则下单次MC中传感器的运动轨迹是不尽相同的, 这是由于受到杂波和噪声等随机因素的影响, 每次仿真中传感器的管理决策方案都会相应的发生变化, 但是从传感器运动轨迹云中依旧可以看出传感

器优化运动的总体趋势以及整个跟踪优化过程中传感器控制运动所在的大致区域。




图 8 4种传感器控制方案质心位置估计W-OSPA距离
Fig. 8 W-OSPA statistics of four control strategies to centroid position estimation

表 3 各方案下W-OSPA的统计均值

Table 3 The mean value of W-OSPA statistics of each strategie

传感器管理方案	方案1	方案2	方案3	方案4
W-OSPA的均值/m	0.1755	0.1742	0.1731	0.1719




图 9 传感器的轨迹云
Fig. 9 Sensor trajectory cloud

6 结论

本文的重点和创新点是在POMDP的理论框架下,提出了一种基于任务论的多扩展目标传感器管理方法.该传感器管理方法中,以联合优化多扩展目标运动状态和扩展(形状)状态为目的设计传感器管理策略,利用W-OSPA距离构造多扩展目标伽玛高斯逆威沙特(gamma Gaussian inverse Wishart, GGIW)分布的离差,提出了离差最小化的多扩展目标跟踪优化的传感器管理策略.最后,通过仿真实验验证了所提算法的有效性.所提方案的意义在于,依据所提传感器管理优化算法,成功使得多扩展目标运动状态估计与形状估计实现了联合优化,同时其估计精度得到有效提升.显然,这对实现跟踪精度要求更高且带形状估计

信息的多扩展目标跟踪优化问题具有重要的理论价值,并且可以进一步推广至其他类型的多扩展目标传感器管理问题中.

参考文献:

- [1] BELLO L L, LOMBARDO A, MILARDO S, et al. Experimental assessments and analysis of an SDN framework to integrate mobility management in industrial wireless sensor networks. *IEEE Transactions on Industrial Informatics*, 2020, 16(8): 5586 – 5595.
- [2] CUI Guolong, YU Xianxiang, YANG Jing, et al. A survey of waveform optimization design methods for cognitive radar. *Journal of Radar*, 2019, 8(5): 537 – 557.
(崔国龙, 余显祥, 杨婧, 等. 认知雷达波形优化设计方法综述. *雷达学报*, 2019, 8(5): 537 – 557.)
- [3] ELBIR A M, MISHRA K V, ELДАР Y C. Cognitive radar antenna selection via deep learning. *IET Radar, Sonar and Navigation*, 2019, 13(6): 871 – 880.
- [4] PANICKER S, GOSTAR A K, BAB-HADIASHAR A, et al. Sensor control for selective object tracking using labeled multi-Bernoulli filter. *The 21st International Conference on Information Fusion*. Cambridge, UK: IEEE, 2018: 2218 – 2224.
- [5] GOSTAR A K, HOSEINNEZHAD R, BAB-HADIASHAR A. Information theoretic approach to robust multi-Bernoulli sensor control. *2014 IEEE Workshop on Statistical Signal Processing*. Gold Coast, QLD, Australia: IEEE, 2014: 224 – 227.
- [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] KRISHNAMURTHY V, EVANS R J. Hidden Markov model multiarm bandits: A methodology for beam scheduling in multitarget tracking. *IEEE Transactions on Signal Processing*, 2001, 49(12): 2893 – 2908.
- [8] RISTIC B, VO B N. Sensor control for multi-object state-space estimation using random finite sets. *Automatica*, 2010, 46(11): 1812 – 1818.
- [9] GOSTAR A K, HOSEINNEZHAD R, BAB-HADIASHAR A. Cauchy-Schwarz divergence-based distributed fusion with poisson random finite sets. *The 2017 International Conference on Control, Automation and Information Sciences*. Chiang Mai, Thailand: IEEE, 2017: 112 – 116.
- [10] GOSTAR A K, HOSEINNEZHAD R, BAB-HADIASHAR A, et al. Sensor-management for multitarget filters via minimization of posterior dispersion. *IEEE Transactions on Aerospace and Electronic Systems*, 2017, 53(6): 2877 – 2884.
- [11] 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.
- [12] MAHLER R P S. *Advances in Statistical Multisource-Multitarget Information Fusion*. Norwood, MA: Artech House, 2014: 825 – 860.
- [13] MAHLER R P S. *Statistical Multisource-Multitarget Information Fusion*. Norwood, MA: Artech House, 2007: 655 – 667.
- [14] GRANSTROM K, SVENSSON L, XIA Y, et al. Poisson multi-Bernoulli mixture trackers: Continuity through random finite sets of trajectories. *The 21st International Conference on Information Fusion*. Cambridge, UK: IEEE, 2018: 1 – 5.
- [15] MAHLER R P S. Multi-target bayes filtering via first-order multitarget moments. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1152 – 1178.
- [16] MAHLER R P S. PHD filters for nonstandard targets, I: Extended targets. *Proceedings of the International Conference on Information Fusion*, Seattle, WA, USA. 2009: 915 – 921.

- [17] GRANSTROM K, LUNDQUIST C, ORGUNER U. Extended target tracking using a Gaussian-mixture PHD filter. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(4): 3268 – 3286.
- [18] KAULBERSCH H, HONER J, BAUM M. EM-based extended target tracking with automotive radar using learned spatialdistribution models. *The 22nd International Conference on Information Fusion*. Ottawa, Canada: IEEE, 2019: 1 – 8.
- [19] TANG X, LI M, THARMARASA R, et al. Seamless tracking of apparent point and extended targets using Gaussian process PMHT. *IEEE Transactions on Signal Processing*, 2019, 67(18): 4825 – 4838.
- [20] KOCH J W. Bayesian approach to extended object and cluster tracking using random matrices. *IEEE Transactions on Aerospace and Electronic Systems*, 2008, 44(3): 1042 – 1059.
- [21] GRANSTROM K, ORGUNER U. A PHD filter for tracking multiple extended targets using random matrices. *IEEE Transactions on Signal Processing*, 2012, 60(11): 5657 – 5671.
- [22] ORGUNER U, LUNDQUIST C, GRANSTROM K. Extended target tracking with a cardinalized probability hypothesis density filter. *The 14th International Conference on Information Fusion*. Chicago, IL, USA: IEEE, 2011: 1 – 8.
- [23] BAUM M, HANEBECK U D. Extended object tracking with random hypersurface models. *IEEE Transactions on Aerospace and Electronic Systems*, 2013, 50(1): 149 – 159.
- [24] BAUM M, NOACK B, HANEBECK U D. Extended object and group tracking with elliptic random hypersurface models. *The 13th International Conference on Information Fusion*. Edinburgh, UK: IEEE, 2010: 1 – 8.
- [25] LUNDQUIST C, GRANSTROM K, ORGUNER U. An extended target CPHD filter and a gamma Gaussian inverse Wishart implementation. *IEEE Journal of Selected Topics in Signal Processing*, 2013, 7(3): 472 – 483.
- [26] 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.)
- [27] MAHLER R P S. Multi-target sensor management of dispersed mobile sensors. *Theory and Algorithms for Cooperative Systems*. Singapore: World Scientific Publishing Co., 2004: 239 – 310.
- [28] BEARD M, ARULAMPALAM S. Performance of PHD and CPHD filtering versus JIPDA for bearings-only multi-target tracking. *The 15th International Conference on Information Fusion*. Singapore, Singapore: IEEE, 2012: 542 – 549.
- [29] RISTIC B, VO B N, CLARK D, et al. A metric for performance evaluation of multi-target tracking algorithms. *IEEE Transactions on Signal Processing*, 2011, 59(7): 3452 – 3457.

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;

刘雅婷 硕士研究生, 目前研究方向为多扩展目标跟踪与传感器管理, E-mail: liuyt0630@163.com;

张双庆 硕士研究生, 目前研究方向为多扩展目标跟踪与传感器管理, E-mail: zhangsq95@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.