

基于 Cauchy-Schwarz 散度的多传感器控制

吴 莎, 杨小军

(长安大学 信息工程学院, 陕西 西安 710064)

摘 要:对传感器网络下的多目标跟踪问题,基于 Cauchy-Schwarz 准则提出一种多传感器多目标跟踪的传感器控制方法,主要包括多目标跟踪、信息融合和传感器决策三大部分。将信息理论的柯西-施瓦兹(CS)散度作为多传感器控制的目标函数,利用目标函数对传感器所采取的决策的优劣进行评价。采用带标签多伯努利滤波器(LMB),基于鲁棒广义协方差交叉(R-GCI)准则对多目标概率密度进行分布式融合,获得多目标运动的航迹估计。基于序贯蒙特卡洛(SMC)方法得到CS散度和LMB滤波器的逼近执行,对传感器决策的选择问题,由于最优算法在实际应用中存在计算难且代价高的问题,故而采用局部搜索算法得到多传感器控制问题的次优解。仿真结果表明了基于CS散度的多目标跟踪多传感器控制算法的可行性和优越性。

关键词:多目标跟踪;传感器控制;LMB滤波器;柯西-施瓦兹准则;鲁棒广义协方差交叉准则

中图分类号:TP273

文献标识码:A

文章编号:1673-629X(2020)06-0160-07

doi:10.3969/j.issn.1673-629X.2020.06.031

Multi-sensor Control Based on Cauchy-Schwarz Divergence

WU Sha, YANG Xiao-jun

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

Abstract: For multi-target tracking in sensor networks, based on Cauchy-Schwarz criterion, we propose a multi-sensor multi-target tracking sensor control method which mainly includes multi-target tracking, information fusion and sensor decision-making. The Cauchy-Schwarz (CS) divergence of information theory is taken as multi-sensor control objective function to evaluate the decision made by the sensor. Based on the robust generalized covariance intersection (R-GCI) rules to the distributed fusion of multiple objective probability density, track estimation of multi-target motion is obtained by using labeled Bernoulli filter (LMB). Based on sequential Monte Carlo (SMC) method, the approximate execution of CS divergence and LMB filter is obtained. As the optimal algorithm is difficult and costly in practical application, a local search algorithm is proposed to obtain the suboptimal solution of multi-sensor control problem. The simulation results show the feasibility and superiority of the multi-target tracking and multi-sensor control algorithm based on CS divergence.

Key words: multi-target tracking; sensor control; LMB filter; Cauchy-Schwarz criterion; R-GCI rule

0 引言

多目标跟踪多传感器技术无论在军事领域还是在民事领域均有广泛的应用,它可用于探测、跟踪和攻击、机器视觉等^[1-2]。随着目标的增多,多传感器对于目标的跟踪相较于单传感器有着明显的优势,它对于目标信息的获取有着重大的意义,提高了对目标状态估计的精确性和系统的可信度。由于通信和计算的限制,需要把每个传感器控制在适当的位置,使整个系统达到最优。那么对于诸多传感器采取合适的决策成为必要解决的问题。在大多数目标跟踪场景中,可以通

过对传感器的位置、方向等工作方式及参数进行调控而获得不同的量测数据,从而提高传感器检测目标的能力和系统的估计性能,实现整体系统优化。

1997年随机有限集(random finite set, RFS)的提出,避免了多目标跟踪航迹关联的复杂问题,它允许多传感器多目标滤波适应统一的随机集框架进行数据融合^[3]。其最大优势是可以将多目标跟踪和传感器控制统一描述为一个贝叶斯框架下部分可观测的马尔可夫决策过程(partially observed Markov decision process, POMDP)^[4]。但RFS不能对目标进行唯一标识,进而

收稿日期:2019-11-20

修回日期:2020-03-23

基金项目:河南省重点计划项目(220024140173)

作者简介:吴莎(1995-),女,硕士研究生,CCF会员(G4586M),研究方向为多目标跟踪、计算机控制、计算机算法研究、信息融合;杨小军,博士,教授,研究方向为多目标跟踪、多源融合、统计信号处理、无线传感器网络。

Vo 等学者在 2013 年提出带标签随机有限集 (labeled random finite set, LRFS) 的概念, 并且提出了广义带标签的多伯努利 (generalized labeled Multi-Bernoulli filter, GLMB) 滤波器。 δ -广义带标签的多伯努利 (δ -GLMB) 和带标签的多伯努利 (LMB) 滤波器都是 GLMB 滤波器的特殊形式, GLMB 和 δ -GLMB 因含有多组分量从而在迭代过程中呈指数形式增长导致计算复杂的问题, 而 LMB 滤波器在定义中只包含一组组件, 所以其在迭代过程中的假设分量呈线性增长, 有效地解决了 GLMB 和 δ -GLMB 计算难的问题。由于 LMB 滤波器计算效率高, 精确地产生目标航迹而得到广泛应用。

多传感器管理是通过优化决策对传感器进行配置。评价函数是产生决策集的重要指标^[5], 评价函数可大致分为成本函数和回报函数: 成本函数主要包括估计目标势方差^[6]、势和状态后验期望误差 (PEECS)^[7]、最优子模式分配 (OSPA) 距离^[8]。成本函数在单目标跟踪中能发挥其性能, 但在多目标跟踪中仍有一定挑战。回报函数是基于信息论的, 在目标跟踪领域, 基于信息论的传感器控制的主要目的是为了通过与目标环境的相互作用以减少目标环境的不确定性, 这种不确定性可以用信息熵来定性描述^[9]。回报函数最常用一些信息散度, 如 Rényi 散度、Kullback-Leibler (KL) 散度和 Cauchy-Schwarz (CS) 散度。Hoang 等人推导出两种泊松点过程混合物的柯西-施瓦兹散度的封闭形式^[10], 因此与基于信息论的其他散度相比, CS 散度在数学计算上更加简单。文献[11]的结果显示 CS 和 KL 虽具有相似的计算趋势, 但 CS 的计算要快得多, 特别是在维度高的情况下更高效, 故选取 CS 散度作为评价函数对于多传感器管理的研究更为合适。

对于多目标跟踪多传感器控制问题, 传感器的管理决策需要信息融合结果的支持, 并通过对传感器资源的合理调度来提高信息融合的质量和效率^[12]。广义交叉协方差 (GCI) 被广泛地应用于分布式多传感器多目标跟踪中, 但其存在标签不一致的问题。在文献[13-14]中解决此问题的方法是将目标的标签在融合时去掉从而避免标签不一致带来的影响。未带标签的后验密度进行 GCI 融合确实避免了标签对 GCI 信息融合的影响, 但是因为去掉了标签而不能产生跟踪轨迹, 因此文献[15]提出了鲁棒 GCI 融合 (R-GCI), 保留后验密度的标签, 在不丢失目标轨迹的情况下对信息进行融合但却不会因标签的错误匹配对 GCI 融合产生影响, 通过融合后的密度使传感器的数据得到有效结合, 实现了对目标更好的估计^[16]。

文中在 LMB 滤波器框架下, 通过选用最优传感

器控制决策对目标进行更加精确的跟踪。首先叙述了预备知识: LMB 滤波器、Cauchy-Schwarz 散度、R-GCI 多目标密度融合准则; 然后讲述 LMB 滤波器和 CS 散度的 SMC 执行并给出多传感器管理的具体算法步骤; 最后通过仿真验证了提出的算法的有效性。

1 预备知识和问题描述

1.1 LMB 滤波器

LMB 滤波器可以实现目标跟踪的要求, 首先, 对 RFS 加入标签将目标的状态扩展为 $X = \{(x_i, \ell_i)\} (i = 1, 2, \dots, |X|)$, $x_i \in \mathbb{X}$, $\ell_i \in \mathbb{L}$, \mathbb{X} 为目标状态空间, \mathbb{L} 是标签空间, $|\cdot|$ 表示目标的势。LMB RFS 可以用参数 $\{(r^{(\ell)}, p^{(\ell)}(\cdot)) : \ell \in \mathbb{L}\}$ 完全表示, 这里的 $r^{(\ell)} \in [0, 1]$ 是目标标签 ℓ 的存在概率, $p^{(\ell)}(\cdot)$ 是目标状态的概率密度函数。LMB RFS 密度如下:

$$\pi^X(X) = \Delta(X) w(\mathcal{L}(X)) p^X \quad (1)$$

其中:

$$\Delta(X) = \delta_{|X|}(|\mathcal{L}(X)|) \quad (2)$$

$$w(L) = \prod_{i \in \mathbb{L}} (1 - r^i) \prod_{\ell \in L} \frac{1_{\mathbb{L}}(\ell) r^{\ell}}{1 - r^{\ell}} \quad (3)$$

$$p^X \triangleq \prod_{(x, \ell) \in X} p^{(\ell)}(x) \quad (4)$$

其中, $\Delta(X)$ 是离散标签指示器; $\mathcal{L}(X)$ 是标签集且 $\mathcal{L}(X) = \{\mathcal{L}(X) : x \in X\}$, 其中映射: $\mathcal{L} : \mathbb{X} \times \mathbb{L} \rightarrow \mathbb{L}$; $w(\mathcal{L}(X))$ 是加权系数并依赖于状态标签 $\mathcal{L}(X)$ ^[17]; $1_{\mathbb{L}}(X)$ 是指示函数, 当 $X \subseteq Y$ 时等于 1, 其他等于 0。

1.2 柯西-施瓦兹 (CS) 散度

CS 散度是基于内积的柯西-施瓦兹不等式的对称量测距离^[18-19], 其描述的是两个密度函数 $f(x)$ 和 $g(x)$ 之间信息含量的差异性。CS 散度的定义如下:

$$D_{CS}(f, g) = -\log \frac{\int f(X) g(X) \delta X}{\sqrt{\int f^2(X) \delta X \int g^2(X) \delta X}} \quad (5)$$

其中, $f(X)$ 和 $g(X)$ 分别表示目标预测密度和目标后验密度, 上式的积分是集积分。

Hong 等人在文献[19]中提出泊松点过程的 CS 散度并证明了两个泊松点过程之间的 CS 散度是它们各自强度函数之间距离的平方的一半, 两个泊松点过程的 CS 散度的公式表达为:

$$D_{CS}(\pi_1, \pi_2) = \frac{K}{2} \|G_1 - G_2\|^2 \quad (6)$$

其中, G_1 和 G_2 分别是泊松点过程预测密度和更新密度的强度函数, K 表示单目标状态的 (超体积) 测量单位。上述公式是计算两个带标签多伯努利密度之间的 CS 散度的基础, 在第二部分会给出 CS 散度的具体计算。

1.3 LMB 多目标概率密度的鲁棒 GCI 融合

Mahler 提出次优的广义交叉协方差 (generalized covariance intersection, GCI) 准则以解决最优融合准则在实际中计算昂贵且公共信息计算难的问题。GCI 准则如下:

$$\pi_s(X) = \frac{\prod_{i \in N} [\pi_i(X)]^{\omega_i}}{\int \prod_{i \in N} [\pi_i(X)]^{\omega_i} \delta X} \quad (7)$$

其中, ω_i 是恒定权重, 表示在融合过程中强调传感器 i 的强度。式 (7) 中的后验密度是未带标签的, 文献 [15] 提出了带标签后验密度的鲁棒 GCI 融合准则。

文献 [15] 先定义了多标签的联合条件概率密度:

$$\bar{\omega}(\{\ell_1 | x_1\}, \dots, \{\ell_n | x_n\}) \triangleq \frac{\pi(\{(x_1, \ell_1), \dots, (x_n, \ell_n)\})}{\pi(\{x_1, \dots, x_n\})} \quad (8)$$

带标签的融合后验密度为:

$$\pi_s(\{(x_1, \ell_1), \dots, (x_n, \ell_n)\}) = \bar{\omega}_s(\{\ell_1 | x_1\}, \dots, \{\ell_n | x_n\}) \pi_s(\{x_1, \dots, x_n\}) \quad (9)$$

式 (9) 中的联合多标签密度 $\bar{\omega}_s(\cdot)$ 和未带标签的融合后验密度 $\pi_s(\cdot)$ 都是将局部分布通过式 (7) 融合求得, 具体步骤可参考文献 [15]。用 R-GCI 准则对 LMB 密度进行融合, 各个融合参数为:

$$r_s^{(\ell)} = \frac{\int \prod_{i=1}^N (r_i^{(\ell)} p_i^{(\ell)}(x))^{\omega_i} dx}{\prod_{i=1}^N (1 - r_i^{(\ell)})^{\omega_i} + \int \prod_{i=1}^N (r_i^{(\ell)} p_i^{(\ell)}(x))^{\omega_i} dx} \quad (10)$$

$$p_s^{(\ell)} = \frac{\prod_{i=1}^N (p_i^{(\ell)})^{\omega_i}}{\int \prod_{i=1}^N (p_i^{(\ell)})^{\omega_i} dx} \quad (11)$$

多目标的状态是由 N 个传感器进行观测, 每个传感器返回一组量测值, Z_i 是第 i 个传感器返回的量测, 量测空间为 \mathbb{Z} , 设累积的量测集为:

$$\mathfrak{Z}_k = (Z_1, \dots, Z_N) \in \mathbb{Z} \quad (12)$$

多传感器控制问题可以转化为部分可观测马尔可夫决策过程 (POMDP), POMDP 定义为一个 6 元组:

$$\Psi = \{\mathbb{X}, \mathbb{U}, f(\cdot | \cdot), \mathbb{Z}, g(\cdot | \cdot), R(u_1, \dots, u_N)\} \quad (13)$$

其中, \mathbb{X} 是状态空间; $\mathbb{U} = \mathbb{U}_1 \times \dots \times \mathbb{U}_N$ 是 N 个传感器的决策空间, u_i 是第 i 个传感器采取的有限决策集; $f(\cdot | \cdot)$ 是转移函数; $g(\cdot | \cdot)$ 是似然函数; $R(u_1, \dots, u_N)$ 是目标函数, 其是通过有限的决策集 u_1, \dots, u_N 所得到的。

在控制问题上, 目标函数 $R(u_1, \dots, u_N)$ 采用 CS 散度, CS 散度是用预测和后验多目标密度距离之间的

关系表示的:

$$R(u_1, \dots, u_N) = D_{\text{CS}}(\pi_+, \pi_{s,u}) \quad (14)$$

其中, π_+ 是融合预测密度, $\pi_{s,u}$ 是融合后验密度。最优决策集是通过最大化目标函数的期望值:

$$(u_1^*, \dots, u_N^*) = \underset{(u_1, \dots, u_N)}{\operatorname{argmax}} \mathbb{E}[R(u_1, \dots, u_N)] \quad (15)$$

其中, \mathbb{E} 表示数学期望; u_1^*, \dots, u_N^* 表示最优决策集。

2 基于 SMC 的多目标多传感器控制问题求解

文献 [20] 中讨论了三种抵消未来量测不确定性的方法, 预测理想量测集 (predicted ideal measurement set, PIMS) 是其中能更好地产生传感器管理决策的方法。故选用 PIMS 作为更新步骤中所需的假设量测。对于每个决策 $u_i \in \mathbb{U}$, 利用每个状态估计产生无噪声和无杂波的量测, 这样的一组量测作为 PIMS, 用 $\tilde{Z}(u)$ 表示:

$$\tilde{Z}(u) = \bigcup_{\hat{x} \in \hat{\mathbf{X}}} \{h(\hat{x})\} \quad (16)$$

其中, $\hat{\mathbf{X}}$ 是预测多目标状态, \hat{x} 是所检测到的目标状态, h 是量测函数。用传感器决策集和 PIMS 更新后验密度, 选择最优决策集。由于最优决策问题 (15) 没有解析解, 文中求助于 SMC 逼近求解。

2.1 LMB 滤波器的 SMC 执行

多目标后验密度 $f(X | Z)$ 可以通过一组随机粒子 X^j 进行近似, 每个粒子都有合适的权重。目标的带标签多伯努利密度 $\pi = \{r^{(\ell)}, p^{(\ell)}\}_{\ell \in \mathbb{L}}$, 目标的状态密度 $p^{(\ell)}(x)$ 可以用一组粒子集进行近似:

$$p^{(\ell)}(x) = \sum_{j=1}^{J^{(\ell)}} \omega^{(\ell)} \delta(x - x_j^{(\ell)}) \quad (17)$$

其中, $J^{(\ell)}$ 是目标采样的粒子数目; $\omega^{(\ell)}$ 是每个粒子的权重; $\delta_Y(X)$ 是狄利克雷函数, 当 $X = Y$ 时等于 1, 其他等于 0。下面介绍 LMB 滤波器用 SMC 实现的预测和更新方程。

预测: 在这里考虑目标的存活和新生两种, 所以 LMB 预测多目标密度的参数可以表示为:

$$\pi_+ = \{(r_{+,S}^{(\ell)}, p_{+,S}^{(\ell)})\}_{\ell \in \mathbb{L}} \cup \{(r_B^{(\ell)}, p_B^{(\ell)})\}_{\ell \in \mathbb{B}} \quad (18)$$

其中:

$$r_{+,S}^{(\ell)} = \eta_s(\ell) r^{(\ell)} \quad (19)$$

$$p_{+,S}^{(\ell)} = \langle p_s(\cdot, \ell), f(x | \cdot, \ell) \rangle / \eta_s(\ell) \quad (20)$$

$$\eta_s(\ell) = \langle p_s(\cdot, \ell), p^{(\ell)}(\cdot) \rangle \quad (21)$$

预测目标的 LMB 参数为 $\{r_+^{(\ell)}, \{w_{+,j}^{(\ell)}, x_{+,j}^{(\ell)}\}_{j=1}^{J_+^{(\ell)}}\}_{\ell \in L_+}$, 其中 $L_+ = \mathbb{L} \cup \mathbb{B}$; p_s 是目标存活概率; $\langle \cdot, \cdot \rangle$ 是内积函数, 定义式为 $\langle f, g \rangle \triangleq \int_{\mathbb{X}} f(x) g(x) dx$ 。

更新: 传感器 i 将相应的控制决策 $u \in \mathbb{U}$ 和理想量

测集 \tilde{Z} 应用于滤波器更新,更新的 LMB 密度为:

$$\pi_{i,u}(\cdot | \tilde{Z}_i) = \{r_{i,u}^{(\ell)}, p_{i,u}^{(\ell)}(\cdot)\}_{\ell \in L_i} \quad (22)$$

根据文献[22]得出的 LMB 更新方程,LMB 密度的各个参数如下:

$$r_{i,u}^{(\ell)} = \sum_{(I_+, \theta) \in (F(L_i) \times \Theta_{I_i})} w^{(I_+, \theta)}(\tilde{Z}) 1_{I_i}(\ell) \quad (23)$$

$$p_{i,u}^{(\ell)} = \frac{1}{r^{(\ell)}} \sum_{(I_+, \theta) \in (F(L_i) \times \Theta_{I_i})} w^{(I_+, \theta)}(\tilde{Z}) 1_{I_i}(\ell) p^\theta(x, \ell) \quad (24)$$

其中:

$$w^{(I_+, \theta)}(\tilde{Z}) \propto w_+(I_+) [\eta_Z^{(\theta)}]^{I_+} \quad (25)$$

$$p^{(\theta)}(x, \ell) = \frac{p_+^{(\ell)}(x) \psi_Z(x, \ell, \theta)}{\eta_Z^{(\theta)}(\ell)} \quad (26)$$

$$\eta_Z^{(\theta)}(\ell) = \langle p_+^{(\ell)}(x) \psi_Z(x, \ell, \theta) \rangle \quad (27)$$

$$w_+(I_+) = \prod_{i \in L_i} (1 - r_+^{(i)}) \prod_{\ell \in I_+} \frac{1_{L_i}(\ell) r_+^{(\ell)}}{1 - r_+^{(\ell)}} \quad (28)$$

$$\psi_Z(x, \ell, \theta) = \begin{cases} \frac{p_D(x, \ell) g(z_{\theta(\ell)} | x, \ell)}{K(z_{\theta(\ell)})}, & \text{if } \theta(\ell) > 0 \\ 1 - p_D(x, \ell), & \text{if } \theta(\ell) = 0 \end{cases} \quad (29)$$

其中, θ 是融合映射函数, Θ_{I_i} 是 θ 的映射空间: $I_+ \rightarrow \{0, 1, \dots, |\tilde{Z}| \}$, 所以 $\theta(i) = \theta(i') > 0$ 意味着 $i = i'$; p_D 是检测概率; $K(\cdot)$ 是杂波函数。

2.2 基于 SMC 的 R-GCI 融合

在 LMB 的更新步骤中,粒子不发生改变,仅粒子的权重发生改变,所以, $x_{i,u,j}^{(\ell)} = x_{+j}^{(\ell)}$ [21]。用 R-GCI 准则对多个 LMB 密度进行融合,对于每一个传感器决策 $u = u_1, \dots, u_N \in \mathbb{U}$, 相应的 LMB 密度参数为 $\{\{r_{i,u_i}^{(\ell)}, p_{i,u_i}^{(\ell)}(\cdot)\}_{\ell \in L_i}\}_{i=1}^N$, 每个密度由相同的粒子不同的权重进行近似:

$$p_{i,u_i}^{(\ell)}(x) = \sum_{j=1}^{J_i^{(\ell)}} w_{i,u_i,j}^{(\ell)} \delta(x - x_{+j}^{(\ell)}) \quad (30)$$

将式(29)带入式(13)和式(14)中,用粒子表示融合参数:

$$r_{s,u}^{(\ell)} = \frac{\sum_{j=1}^{J_i^{(\ell)}} \prod_{i=1}^N (r_{i,u_i}^{(\ell)} w_{i,u_i,j}^{(\ell)})^{\omega_i}}{\prod_{i=1}^N (1 - r_{i,u_i}^{(\ell)})^{\omega_i} + \sum_{j=1}^{J_i^{(\ell)}} \prod_{i=1}^N (r_{i,u_i}^{(\ell)} w_{i,u_i,j}^{(\ell)})^{\omega_i}} \quad (31)$$

$$p_{s,u}^{(\ell)}(x) = \sum_{j=1}^{J_i^{(\ell)}} w_{s,u,j}^{(\ell)} \delta(x - x_{+j}^{(\ell)}) \quad (32)$$

$$w_{s,u,j}^{(\ell)} = \frac{\prod_{i=1}^N (w_{i,u_i,j}^{(\ell)})^{\omega_i}}{\sum_{j=1}^{J_i^{(\ell)}} \prod_{i=1}^N (w_{i,u_i,j}^{(\ell)})^{\omega_i}} \quad (33)$$

2.3 CS 散度的 SMC 实现

结合上面 LMB 预测和更新方程对 CS 散度进行

SMC 执行。预测和更新的 LMB 强度函数为:

$$G_+(x) = \sum_{\ell=1}^{L_i} \sum_{j=1}^{J_i^{(\ell)}} [r_+^{(\ell)} w_{+,j}^{(\ell)}] \delta(x - x_{+,j}^{(\ell)}) \quad (34)$$

$$G_{s,u}(x) = \sum_{\tilde{Z} \in \tilde{Z}} \sum_{\ell=1}^{L_i} \sum_{j=1}^{J_i^{(\ell)}} [r_{s,u}^{(\ell)}(\tilde{Z}) w_{s,u}^{(\ell,j)}(\tilde{Z})] \delta(x - x_{+,j}^{(\ell)}) \quad (35)$$

对多目标后验分布最有效的近似是多目标分布的一阶矩[22]。文献[9]证明了关于两个多伯努利强度函数的 CS 散度的公式表达,由此得出两个 LMB 密度的 CS 散度公式:

$$D_{CS}(\tilde{\pi}_+, \pi_{s,u}) = \frac{K}{2} \int \sum_{\ell=1}^{L_i} \sum_{j=1}^{J_i^{(\ell)}} \left(\sum_{Z \in \tilde{Z}} r_{s,u}^{(\ell)}(\tilde{Z}) w_{s,u}^{(\ell,j)}(\tilde{Z}) - r_+^{(\ell)} w_{+,j}^{(\ell)} \right)^2 \delta(x - x_{+,j}^{(\ell)}) \quad (36)$$

根据 δ 函数的积分特性,回报函数为:

$$R^j(u_1, \dots, u_N) = \frac{K}{2} \int \sum_{\ell=1}^{L_i} \sum_{j=1}^{J_i^{(\ell)}} \left(\sum_{Z \in \tilde{Z}} r_{s,u}^{(\ell)}(\tilde{Z}, u_i) w_{s,u,j}^{(\ell)}(\tilde{Z}, u_i) - r_+^{(\ell)} w_{+,j}^{(\ell)} \right)^2 \quad (37)$$

采用逼近之后,问题(15)最优决策的求解为:

$$(u_1^*, \dots, u_N^*) \approx \underset{(u_1, \dots, u_N)}{\operatorname{argmax}} \frac{1}{M} \sum_{j=1}^M R^{(j)}(u_1, \dots, u_N) \quad (38)$$

其中, M 是采样的粒子数。

综上所述,由于积分计算难的问题,采用 SMC 逼近融合密度和 CS 散度以对最优决策进行求解,问题(15)的算法总结如下。

算法1:滤波器迭代、融合和多传感器控制算法。

输入:标签空间 \mathbb{L} ,对上一时刻的融合后验密度粒子采样: $T = \{X^1, \dots, X^M\}$,当前 LMB 密度存在概率 $\{r^{(\ell)}\}_{\ell \in \mathbb{L}}$,当前 LMB 目标状态的概率密度 $p^{(\ell)} = \{\{\omega_j^{(\ell)}, x_j^{(\ell)}\}_{j=1}^{J_i^{(\ell)}}\}_{\ell \in \mathbb{L}}$,出生模型 LMB 参数 $B = \{r_B^{(i)}, \{\omega_{j,B}^{(i)}, x_{j,B}^{(i)}\}_{j=1}^{J_i^{(i)}}\}_{i \in \mathbb{L}}$,生存概率 $p_s(x, \ell)$,单目标转移函数 $f(x | \cdot, \ell)$,单目标似然函数 $g(z | x, \ell)$,检测概率 $p_D(x, \ell)$ 和杂波密度 $K(\cdot)$,传感器控制决策空间 \mathbb{U} 。输出可分为以下几步:

Step1:根据式(14)~式(17)的预测步进行预测:

预测 $(r^{(\ell)}, \{\omega_j^{(\ell)}, x_j^{(\ell)}\}_{j=1}^{J_i^{(\ell)}})_{\ell \in \mathbb{L}}, B, p_s(x, \ell), f(\cdot | \cdot, \cdot)) \rightarrow \{r_+^{(\ell)}, \{\omega_{+,j}^{(\ell)}, x_{+,j}^{(\ell)}\}_{j=1}^{J_i^{(\ell)}}\}_{\ell \in \mathbb{L}} \circ$

Step2:计算回报函数:

(1)对于每个粒子 $X^{(j)} \in T$ 和控制决策 $(u_1, \dots, u_N) \in \mathbb{U}$,计算理想量测集: $X^{(j)} \rightarrow \tilde{Z}(u_i, X^{(j)})$;

(2)根据式(19)~式(25)更新 LMB,并保存后验

参数和粒子: $(\{r_+^{(\ell)}, \{\omega_{+,j}^{(\ell)}, x_{+,j}^{(\ell)}\}_{j=1}^{J_i^{(\ell)}}\}_{\ell \in \mathbb{L}}, \tilde{Z}, p_D(\cdot, \cdot), g(\cdot | \cdot, \cdot), K(\cdot)) \rightarrow \{r_{i,u}^{(\ell)}, \{\omega_{i,u,j}^{(\ell)}, x_{i,u,j}^{(\ell)}\}_{j=1}^{J_i^{(\ell)}}\}_{\ell \in L_i}$,粒子本身和粒子数目不改变,仅仅改变权重, $\forall i, u: x_{i,u,j}^{(\ell)} = x_{+,j}^{(\ell)}, J_{i,u}^{(\ell)} = J_+^{(\ell)}$;

(3) 对于每个粒子 $X^{(j)} \in T$, 每一个控制决策 $(u_1, \dots, u_N) \in \mathbb{U}$ 的 R-GCI 融合:

$$\text{R-GCI}(\pi_{u_1}\{X|\tilde{Z}^1\}, \dots, \pi_{u_N}\{X|\tilde{Z}^N\}) \rightarrow \pi_u\{u_1, \dots, u_N, X^{(j)}\}$$

(4) 计算每个回报函数: $D_{\text{CS}}(\pi_+, \pi_u) \rightarrow R^{(j)}(u_1, \dots, u_N)$ 。

Step3: 最优决策: $\arg\max_{(u_1, \dots, u_N)} \mathbb{E}[R(u_1, \dots, u_N)] \approx$

$$\arg\max_{(u_1, \dots, u_N)} \frac{1}{M} \sum_{j=1}^M R^{(j)}(u_1, \dots, u_N) \rightarrow (u_1^*, \dots, u_N^*)。$$

求解最优问题(38)是对 N 个传感器并行求解, 这是一个 NP 难的问题, 计算复杂度随着传感器个数的增加而呈指数增加, 求解有很大的挑战。而局部迭代搜索^[23]是多项式难的问题, 在实际中是可行的。故采用局部迭代搜索的方法寻找次优解。

算法 2: 局部迭代搜索算法。

Step1: 选择一组初始决策。

(1) 对第一个传感器, 应用可选决策分别进行更新并计算回报函数, 选择对于第一个传感器的最优决策, 其他传感器保持初始决策不变, 得到一组新的决策集 $\{u_1^{*(1)}, u_2^{(1)}, \dots, u_N^{(1)}\}$;

(2) 对第二个传感器, 应用可选决策分别进行更新并计算回报函数, 选择对于第二个传感器的最优决策, 其他传感器保持初始决策不变, 即 $\{u_1^{*(1)}, u_2^{*(1)}, \dots, u_N^{(1)}\}$;

(3) 对每个传感器都选择对其最优的决策, 每个传感器都得到对于自己最优的决策, 组成决策集 $\{u_1^{*(1)}, u_2^{*(1)}, \dots, u_N^{*(1)}\}$ 。此决策集中的每一个决策对应于相应的传感器都是最优决策, 但其集合不一定最优。

Step2: 在初始解的邻域内搜索更好的解。

(1) 对于第一步选择的决策集 $\{u_1^{*(1)}, u_2^{*(1)}, \dots, u_N^{*(1)}\}$, 将第一个传感器的决策 $u_1^{*(1)}$ 与其他可选决策进行交换, 即得到新的决策集 $\{u_1^{(2)}, u_2^{*(1)}, \dots, u_N^{*(1)}\}$, 将这两组决策集分别计算回报函数, 若新的决策集获得更好的全局回报函数性能, 则接受该组决策集, 若得到的回报函数性能较差, 则保持原决策集不变;

(2) 对于第一步选择的决策集 $\{u_1^{*(1)}, u_2^{*(1)}, \dots, u_N^{*(1)}\}$, 将第二个传感器的决策 $u_2^{*(1)}$ 与其他可选决策进行交换, 即得到新的决策集 $\{u_1^{*(1)}, u_2^{(2)}, \dots, u_N^{*(1)}\}$, 将这两组决策集应用于计算回报函数, 若新的决策集获得更好的全局回报函数性能, 则接受该组决策集, 若得到的回报函数性能较差, 则保持原决策集不变;

(3) 将余下的传感器重复(1)、(2)的操作, 直到所有的传感器都重新选择决策;

(4) 对每一个传感器的决策都进行选择, 直到穷

举完每个传感器的最大决策数, 选取使回报函数最大的决策集。

3 仿真分析

设在平面区域 $[-2\ 000\ \text{m}, 2\ 000\ \text{m}] \times [0\ \text{m}, 2\ 000\ \text{m}]$, 目标的状态 $x_k^T = [p_{x,k}, \dot{p}_{x,k}, p_{y,k}, \dot{p}_{y,k}]^T$, x_k^T 包含目标运动的位置向量和速度向量, 转移密度 $f_{k|k-1}(x|x_k) = N(x_k; F_k x_{k-1}, Q_k)$, 其中

$$F_k = \begin{bmatrix} 1 & \frac{\sin \omega T}{\omega} & 0 & -\frac{1 - \cos \omega T}{\omega} \\ 0 & \cos \omega T & 0 & -\sin \omega T \\ 0 & \frac{1 - \cos \omega T}{\omega} & 1 & \frac{\sin \omega T}{\omega} \\ 0 & \sin \omega T & 0 & \cos \omega T \end{bmatrix}$$

$$Q_k = \sigma_\omega^2 \begin{bmatrix} \frac{T^3}{4} & \frac{T^2}{3} & 0 & 0 \\ \frac{T^2}{3} & \frac{T}{2} & 0 & 0 \\ 0 & 0 & \frac{T^3}{4} & \frac{T^2}{3} \\ 0 & 0 & \frac{T^2}{3} & \frac{T}{2} \end{bmatrix}$$

T 是采样周期等于 1 s, ω 表示目标运动的角速度, 目标的模型是 CT 模型, 选取的角速度 $\omega = \frac{\pi}{60}$ rad/s, 模型速度为 $v = 5\ \text{m/s}$, 过程噪声为 $\sigma_\omega^2 = 5.0\ \text{m/s}^2$ 。

每个目标都有出生和死亡两种状态, 目标的存活概率 $p_{s,k}(x) = 0.99$, 多伯努利 RFS 的出生密度为 $\pi_B = \{(r_B^{(i)}, p_B^{(i)})\}_{i=1}^4$, 其中

$$r_B^{(1)} = r_B^{(2)} = 0.03,$$

$$r_B^{(3)} = r_B^{(4)} = 0.04,$$

$$p_B^{(i)}(x) = N(x; m_B^{(i)}, P_B),$$

$$m_B^{(1)} = [-1000\ 0\ 350\ 0\ 0]^T,$$

$$m_B^{(2)} = [350\ 0\ 1100\ 0\ 0]^T,$$

$$m_B^{(3)} = [250\ 0\ 1000\ 0\ 0]^T,$$

$$m_B^{(4)} = [1000\ 0\ 1500\ 0\ 0]^T,$$

$$P_B = \text{diag}([50; 50; 50; 50; 6(\pi/180)]^T)^2。$$

传感器测量的是具有噪声的极坐标矢量形式:

$$z_k = \begin{bmatrix} \arctan\left(\frac{p_{y,k} - s_{y,k}}{p_{x,k} - s_{x,k}}\right) \\ \sqrt{(p_{x,k} - s_{x,k})^2 + (p_{y,k} - s_{y,k})^2} \end{bmatrix} + w_k(x_k, u_k)$$

其中, $u_k = [s_{x,k}, s_{y,k}]$ 表示传感器的位置; $w_k(x_k, u_k) \sim N(\cdot, 0, R_k)$ 是量测噪声, 协方差为 $R_k = \text{diag}(\sigma_\theta^2, \sigma_r^2)$, 范围和方位噪声分别为 $\sigma_r = \sigma_0 + \eta_r \|x_k - u_k\|^2$, $\sigma_\theta = \sigma_0 + \eta_\theta \|x_k - u_k\|^2$; 参数 $\sigma_0 = 10\ \text{m}$, $\eta_r = 5 \times 10^{-5}$

m^{-1} , $\theta_0 = \pi/180 \text{ rad}$, $\eta_\theta = 5 \times 10^{-6} \text{ m}^{-1}$ 。每个传感器的检测效率是独立的且符合以下形式:

$$P_D(x_k, u_k) = \frac{N(\|x_k - u_k\|; 0, \sigma_D)}{N(0; 0, \sigma_D)}$$

其中, $\sigma_D = 10\,000 \text{ m}$ 控制检测概率的速率随着范围增大而减小。目标的存活概率 $p_{s,k}(x) = 0.98$, 单位体积的平均杂波数目 $\lambda_c = 12$ 。

传感器平台以 8 m/s 的恒定速度移动,但在预先指定的决策时间改变航向。每个传感器允许的控制集合是 $u_i = [-180^\circ, -150^\circ, \dots, 0^\circ, \dots, 150^\circ, 180^\circ]$, 样本数量为 $M = 10^3$, 测试场景由三个目标和两个传感器组成,观测时间是 60 s ,用两个传感器对三个目标进行跟踪,每个传感器每隔 10 s 做一次决策, 10 s 内传感器保持当前运动方向不变,每次时间末重新决策,考虑是否改变传感器的运动方向,在仿真时间 60 s 内,每个传感器共做 6 次决策。局部滤波器是 LMB 滤波器,每个节点的 GCI 融合权重选取 0.5 。




图1 目标的真实运动轨迹

如图1所示,目标的起始和结束分别用○和△符号表示,每个目标的出生和死亡时间不同,分别在图中标注,图中两个传感器所在位置为初始位置。




图2 传感器运动轨迹

如图2所示,带箭头的线为两个传感器的运动轨迹;由图可看出两个传感器靠近目标运动,可知,提出的控制方法可以做出传感器靠近目标运动的正确决策。

如图3所示,对目标的跟踪性能,局部迭代的搜索法寻找的次优解与穷举法的最优解的性能相近,而随

机决策对应的 OSPA 距离峰值时间滞后且误差大。所以,当传感器数量多且难以计算时,用局部迭代搜索法替代穷举法是可行的。




图3 OSPA 距离对比

4 结束语

对多传感器多目标跟踪问题,文中提出一种多传感器最优控制策略。选择 CS 散度作为系统性能评价函数,通过最大化回报函数实现多个传感器的最优控制。在随机有限集框架下,采用 LMB 滤波器获得多目标的航迹估计,并且基于保留标签的 R-GCI 融合准则对多传感器多目标航迹估计进行分布式融合。基于 SMC 逼近,得到多目标概率密度之间 CS 散度的数值求解,并且给出基于 SMC 的 LMB 滤波器和 R-GCI 融合地逼近执行。在此基础上提出一种基于局部迭代搜索的传感器控制策略的次优算法。后续工作包括寻找更加有效的多传感器航迹融合方法和优化算法。

参考文献:

- [1] 吕学斌,周群彪,陈正茂,等. 高斯混合概率假设密度滤波器在多目标跟踪中的应用[J]. 计算机学报,2012,35(2): 397-404.
- [2] JIANG M, YI W, KONG L. Multi-sensor control for multi-target tracking using Cauchy-Schwarz divergence [C]//2016 19th international conference on information fusion (FUSION). Heidelberg, Germany: IEEE, 2016: 2059-2066.
- [3] VO B, SINGH S, DOUCET A. Sequential Monte Carlo methods for multitarget filtering with random finite sets [J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(4): 1224-1245.
- [4] CASTANÓN D A, CARIN L. Stochastic control theory for sensor management [M]//Foundations and applications of sensor management. Berlin: Springer, 2008: 7-32.
- [5] 胡卫东. 多传感器用于多目标跟踪的优化分配方法[J]. 舰船电子工程, 2000(2): 15-17.
- [6] HOANG H G, VO B T. Sensor management for multi-target tracking via multi-Bernoulli filtering [J]. Automatica, 2014, 50(4): 1135-1142.
- [7] GOSTAR A K, HOSEINNEZHAD R, BAB-HADIASHAR A.

- Multi-bernoulli sensor control via minimization of expected estimation errors[J]. IEEE Transactions on Aerospace and Electronic Systems, 2015, 51(3): 1762-1773.
- [8] GOSTAR A K, HOSEINNEZHAD R, GOSTAR A, et al. OSPA-based sensor control [C]//International conference on control, automation and information sciences (ICCAIS). Changshu: IEEE, 2015: 214-218.
- [9] 陈辉, 贺忠良, 刘备. 多目标跟踪中基于信息熵测度的传感器控制方法[J]. 控制与决策, 2018, 33(2): 337-344.
- [10] GOSTAR A K, HOSEINNEZHAD R, BAB-HADIASHAR A. Multi-Bernoulli sensor control using Cauchy-Schwarz divergence [C]//2016 19th international conference on information fusion (FUSION). Heidelberg, Germany: IEEE, 2016: 651-657.
- [11] KAMPA K, HASANBELLIU E, PRINCEPI J C. Closed-form cauchy-schwarz PDF divergence for mixture of Gaussians [C]//The 2011 international joint conference on neural networks. San Jose, CA: IEEE, 2011: 2578-2585.
- [12] 吕春英, 于飞, 李晨, 等. 多传感器管理结构及功能模型探讨[J]. 中国无线电, 2014(1): 65-67.
- [13] WEI B, NENER B. Consensus labeled multi-Bernoulli filtering for distributed space debris tracking [C]//International conference on control, automation and information sciences (ICCAIS). Chiang Mai, Thailand: IEEE, 2017: 203-208.
- [14] WANG B, YI W, LI S, et al. Distributed multi-target tracking via generalized multi-Bernoulli random finite sets [C]//2015 18th international conference on information fusion (FUSION). Washington, DC, USA: IEEE, 2015: 253-261.
- [15] LI S, YI W, HOSEINNEZHAD R, et al. Robust distributed fusion with labeled random finite sets [J]. IEEE Transactions on Signal Processing, 2018, 66(2): 278-293.
- [16] WEI B, NENER B, LIU W, et al. Centralized multi-sensor multi-target tracking with labeled random finite sets [C]//2016 international conference on control, automation and information sciences (ICCAIS). Ansan, South Korea: IEEE, 2016: 82-87.
- [17] WANG X, HOSEINNEZHAD R, GOSTAR A K, et al. Multi-sensor control for multi-object Bayes filters [J]. Signal Processing, 2018, 142: 260-270.
- [18] HASANBELLIU E, GIRALDO L S, PRINCEPI J C. A robust point matching algorithm for non-rigid registration using the Cauchy-Schwarz divergence [C]//2011 IEEE international workshop on machine learning for signal processing. Santander, Spain: IEEE, 2011: 1-6.
- [19] HOANG H G, VO B N, VO B T. The Cauchy-Schwarz divergence for poisson point processes [C]//2014 IEEE workshop on statistical signal processing (SSP). Gold Coast, VIC, Australia: IEEE, 2014: 240-243.
- [20] MAHLER R P S. Multitarget sensor management of dispersed mobile sensors [M]. Singapore: World Scientific Publishing, 2004: 239-310.
- [21] GOSTAR A K, HOSEINNEZHAD R, GOSTAR T, et al. Constrained sensor control for labeled multi-Bernoulli filter using Cauchy-Schwarz divergence [J]. IEEE Signal Processing Letters, 2017, 24(9): 1313-1317.
- [22] 刘艳君, 刘祖鹏. 基于箱粒子的 ET-CBMeMBer 滤波算法 [J]. 电光与控制, 2017, 24(8): 56-60.
- [23] 杨小军, 梁中华, 徐先峰, 等. 基于 CPCRLB 和一致性算法的分散式传感器管理 [J]. 信息与控制, 2016, 45(5): 593-599.

(上接第210页)

类簇数之间的关系。通过实验表明,使用改进的聚类算法确定枢纽站点为公交枢纽站点二次规划提供了可靠的数据支持,并且使用遗传算法改进的聚类算法的聚类效果有了较好的提升。

参考文献:

- [1] 罗军锋, 锁志海. 一种基于密度的 K-means 聚类算法 [J]. 微电子学与计算机, 2014, 31(10): 28-31.
- [2] 王吉源, 孟祥茂, 廖列法. 具有层次结构的 K-means 聚类算法研究 [J]. 电子学与计算机, 2015, 32(12): 63-67.
- [3] 李硕. 聚类算法的研究与改进 [D]. 北京: 北京邮电大学, 2017.
- [4] 孔令凯, 向毅, 梁松. 关于结合层次聚类和 K-means 算法进行聚类研究 [J]. 科技创新与应用, 2015(25): 80.
- [5] 王泽, 张宏军, 张睿, 等. 基于遗传算法与密度及距离计算的聚类方法 [J]. 计算机应用, 2015, 35(11): 3243-3246.
- [6] 朱连江, 马炳先, 赵学泉. 基于轮廓系数的聚类有效性分析 [J]. 计算机应用, 2012, 30: 139-141.
- [7] 陈新泉, 周灵晶, 刘耀中. 聚类算法研究综述 [J]. 集成技术, 2017, 6(3): 41-49.
- [8] 杨娟, 屈传慧. 改进 K 均值聚类算法 [J]. 舰船电子对抗, 2017, 40(6): 91-93.
- [9] 胡晓庆, 马儒宁, 钟宝江. 层次聚类算法的有效性研究 [J]. 山东大学学报: 工学版, 2010, 40(5): 146-149.
- [10] 张靖, 段富. 优化初始聚类中心的改进 k-means 算法 [J]. 计算机工程与设计, 2013, 34(5): 1691-1694.
- [11] 张登荣, 杜要, 寻丹丹, 等. Kernel-Kmeans: 一种基于核密度估计的空间聚类算法 [J]. 杭州师范大学学报: 自然科学版, 2017, 16(3): 324-329.
- [12] 黄永青, 杨善林, 梁昌勇. 交互式蚁群遗传算法 [J]. 小型微型计算机系统, 2016, 37(11): 2567-2570.
- [13] 张雁翔, 祁育仙. 改进遗传算法求解 TSP [J]. 山西电子技术, 2016(1): 28-30.
- [14] 朱彦廷. 自适应遗传算法 [J]. 普洱学院学报, 2013(6): 27-30.
- [15] 郭来军. 基于改进遗传算法的应用研究 [J]. 无线互联技术, 2017(18): 145-146.