

多目标跟踪中基于信息熵测度的传感器控制方法

陈 辉[†], 贺忠良, 刘 备

(兰州理工大学 电气工程与信息工程学院, 兰州 730050)

摘 要: 针对多目标跟踪中的传感器控制问题, 提出一种基于有限集统计 (FISST) 理论的传感器控制策略. 首先, 基于随机有限集 (RFS), 建模给出基于信息论的传感器控制的一般方法; 然后, 利用多目标概率密度的近似统计特性推导柯西施瓦兹 (CS) 距离的表达形式, 并最终利用粒子概率假设密度滤波器对评价函数进行求解, 在信息增益最大化的准则下得到传感器的最优控制方案. 传感器的轨迹控制实验仿真验证了所提出算法的有效性.

关键词: 传感器控制; 随机有限集; 多目标概率密度; 柯西施瓦兹

中图分类号: TP273

文献标志码: A

Sensor control method based on information entropy measure for multi-target tracking

CHEN Hui[†], HE Zhong-liang, LIU Bei

(School of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: In consideration of the sensor control problem for multi-target tracking, a sensor control strategy is proposed based on the finite set statistics (FISST) theory. Firstly, the general method of sensor control based on the information theory is given based on the random finite set (RFS) modeling. Then, the expression of Cauchy-Schwarz (CS) distance is deduced by the approximate statistical properties of multi-target probability density. The evaluation function is solved through the particle probability hypothesis density filter. Thus, the optimal control scheme of the sensor is obtained under the criterion of maximizing the information gain. Simulation results of sensor trajectory control show the effectiveness of the proposed algorithm.

Keywords: sensor control; random finite set; multi-target probability density; Cauchy-Schwarz

0 引 言

在目标跟踪领域中, 传感器控制^[1]的方案对于整体目标跟踪系统中所获取的信息质量有重大意义. 通常情况下, 传感器的控制包括改变传感器平台的位置、方向或运动状态等, 而这样控制的主要目的是依照某种评价准则使得目标跟踪性能达到最优. 传感器控制其实是一系列决策过程的最终体现, 而其控制的最终结果都会对应产生新的多目标量测. 在状态和量测空间中存在不确定性的情况下, 通常使用过去的信息积累作出最优的传感器控制决策. 这类控制问题本质上属于传感器管理^[1-2]问题, 它们的解决方案通常在部分可观测马尔可夫决策过程 (POMDP) 的理论框架下进行^[3]. POMDP 的元素包括当前信息状态、传感器动作的集合以及与每个传感器动作相关联的评价函数. 传感器控制可依据多

目标先验概率密度与多目标后验概率密度之间的差异来反映信息量的增益, 进而选取评价函数对传感器控制作指导. 然而, 多目标跟踪中由于各种不确定因素, 如目标的新生、衍生和消亡, 导致目标数目在不断的变化; 同时, 多目标跟踪还需考虑由传感器检测不确定性、多目标量测和杂波的共存等带来的量测起源的不确定性.

基于有限集统计 (FISST) 理论^[1,4-7]的多目标跟踪算法因其有效避免了传统多目标跟踪中的数据关联问题而广受关注, 该方法利用随机有限集 (RFS)^[1,7-8]建模多目标的状态与观测. 利用 FISST 理论解决目标数未知的多目标跟踪问题, 其实质是一组基于 RFS 的多目标贝叶斯滤波公式. 众所周知, FISST 理论比点过程 (PP) 理论^[9-10]更容易被工程人员所接受, 在近几年的国际信息融合大会上, 基于

收稿日期: 2016-11-08; 修回日期: 2017-02-02.

基金项目: 国家自然科学基金项目 (61370037, 61763029, 61461026); 甘肃省自然科学基金项目 (1506RJZA090).

作者简介: 陈辉 (1978—), 男, 副教授, 从事多目标跟踪与传感器管理方法等研究; 贺忠良 (1993—), 男, 硕士生, 从事传感器管理方法的研究.

[†]通讯作者. E-mail: huich78@hotmail.com

该理论的目标跟踪方法已经成为非常重要的研究议题. 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性, Mahler 提出了概率假设密度 (PHD) 滤波器^[1,7-8], 它近似递推了多目标概率密度的一阶统计矩, 其优点是将多目标跟踪问题转移到单目标状态空间上加以解决. 从目前来看, 国外已有一些学者基于 FISST 在 POMDP 的理论框架下提出了传感器的控制方法^[11-14], 而国内也已有最新的研究成果出现^[15].

本文的重点和创新点是研究多目标跟踪中的传感器轨迹控制问题, 利用近似多目标后验概率密度表示多目标跟踪中多目标状态的不确定性, 选取评价函数度量与每个传感器动作相关的多目标概率密度变化所对应的信息增益, 继而在评价准则最优的条件下求出具体的传感器控制方案. 首先, 利用 RFS 建模多目标的状态与观测; 其次, 利用近似多目标滤波器的统计假设条件推导相关柯西施瓦兹 (CS) 距离^[16]的表达式, 研究利用 CS 距离作为评价函数, 结合粒子概率假设密度滤波器 (P-PHDF)^[17]的实现方法对评价函数进行求解, 最终实现对多目标跟踪中传感器的轨迹控制, 并给出算法实现的具体伪码; 最后, 在多目标跟踪的仿真场景下, 将本文所提出的方案与其他几种传感器的控制方案进行跟踪性能比较, 并得到最终结论.

1 有限集统计理论与多目标密度滤波器

1.1 随机有限集

集合微分和积分是有限集统计理论的核心. 下面给出集合积分的定义, 它的定义密切相关于后续传感器控制信息增益评价函数的求解.

设多目标概率密度函数 $f(X)$ 是一个关于 RFS 变量 X 的正值函数, 其中 $X = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ 表示多目标的状态向量, 在区间 $S \subseteq X$ 内集合的积分可定义如下:

$$\int_S f(X) \delta X \triangleq f(\emptyset) + \sum_{n=1}^{\infty} \frac{1}{n!} \int_{S^n} f(\mathbf{x}_1, \dots, \mathbf{x}_n) d\mathbf{x}_1, \dots, d\mathbf{x}_n. \quad (1)$$

其中: $f(\mathbf{x}_1, \dots, \mathbf{x}_n)$ 为多目标的联合概率分布, 基数 (集合势) 分布 $\rho(n) = \Pr\{|X| = n\}$, 即

$$f(\{\mathbf{x}_1, \dots, \mathbf{x}_n\}) \triangleq n! \rho(n) f(\mathbf{x}_1, \dots, \mathbf{x}_n).$$

这里

$$\sum_{n=0}^{\infty} \rho(n) = 1, \int f(\mathbf{x}_1, \dots, \mathbf{x}_n) d\mathbf{x}_1, \dots, d\mathbf{x}_n = 1.$$

1.2 随机有限集的多目标模型

假设 k 时刻在目标状态空间 $\mathcal{X} \subseteq \mathcal{R}^{n_x}$ 中存在 $n_x(k)$ 个目标, 它们的状态分别为 $\mathbf{x}_{1,k}, \dots, \mathbf{x}_{n_x(k),k}$. 同样, k 时刻传感器接收到 $n_z(k)$ 个量测在量测空间 $\mathcal{Z} \subseteq \mathcal{R}^{n_z}$ 中的取值分别为 $\mathbf{z}_{1,k}, \dots, \mathbf{z}_{n_z(k),k}$. 用 X_k 和 Z_k 分别表示 k 时刻多目标状态 RFS 和多目标量测 RFS, 则有

$$X_k = \{\mathbf{x}_{1,k}, \dots, \mathbf{x}_{n_x(k),k}\} \in \mathcal{F}(\mathcal{X}),$$

$$Z_k = \{\mathbf{z}_{1,k}, \dots, \mathbf{z}_{n_z(k),k}\} \in \mathcal{F}(\mathcal{Z}).$$

假设在状态转移过程中 $k-1$ 时刻的目标 $\mathbf{x}_{k-1} \in X_{k-1}$ 继续存活在 k 时刻的概率为 $P_{s,k}(\mathbf{x}_{k-1})$, k 时刻多目标状态集合 X_k 可描述为^[17]

$$X_k = \left[\bigcup_{\mathbf{x}_{k-1} \in X_{k-1}} S_{k|k-1}(\mathbf{x}_{k-1}) \right] \cup \Gamma_k. \quad (2)$$

其中: $S_{k|k-1}$ 为从 $k-1$ 时刻到 k 时刻的存活目标状态 RFS, Γ_k 为 k 时刻新生目标状态 RFS. 此外, 对于 k 时刻传感器检测到的目标状态 $\mathbf{x}_k \in X_k$ 对应量测 $\mathbf{z}_k (\mathbf{z}_k \in Z_k)$ 的概率为 $P_{d,k}(\mathbf{x}_k)$, Z_k 为 k 时刻所接收到的多目标量测集合. 若量测噪声为 \mathbf{v}_k , 则可假设量测方程有如下表达式:

$$\mathbf{z}_k = h(\mathbf{x}_k, \mathbf{x}_{s,k}) + \mathbf{v}_k, \quad (3)$$

其中传感器在 k 时刻的实际位置由传感器控制决策所决定. 目标对应的量测是一个 RFS, 可表示为 $\Theta_k(\mathbf{x}_k)$, 若考虑杂波的影响, 则 k 时刻多目标量测集合 Z_k ^[17] 可描述为

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

其中 K_k 表示 k 时刻的杂波分布. 该集合为服从参数为 λ_k 的泊松 RFS.

根据以上假设, 最优多目标贝叶斯滤波器^[1,7-8] 可表示为

$$p_{k|k-1}(X_k | Z_{1:k-1}) = \int f_{k|k-1}(X_k | X_{k-1}) p_{k-1|k-1}(X_{k-1} | Z_{1:k-1}) \delta(X_{k-1}), \quad (5)$$

$$p_{k|k}(X_k | Z_{1:k}) = \frac{g_k(Z_k | X_k) p_{k|k-1}(X_k | Z_{1:k-1})}{\int g_k(Z_k | X_k) p_{k|k-1}(X_k | Z_{1:k-1}) \delta(X_k)}. \quad (6)$$

其中: $f_{k|k-1}(X_k | X_{k-1})$ 为由 $k-1$ 时刻到 k 时刻的多目标状态 RFS 的状态转移密度, $Z_{1:k}$ 为 1 到 k 时刻的所有量测构成的集合, $p_{k|k}(X_k | Z_{1:k})$ 为 k 时刻多目标状态的后验概率密度, $g_k(Z_k | X_k)$ 为 k 时刻的似然函数.

1.3 多目标状态统计特性的近似描述

概率假设密度函数(也称强度函数)作为多目标随机集的概率密度的一种近似描述,可通过贝叶斯递推公式进行计算,通过对多目标后验概率密度函数求集合积分运算得到多目标强度函数.假设多目标的强度函数为 $D_{k|k}(\mathbf{x}|Z_{1:k})$,多目标的概率密度函数为 $f_{k|k}(X|Z_{1:k})$,则有

$$D_{k|k}(\mathbf{x}|Z_{1:k}) = \int \delta_X(\mathbf{x}) f_{k|k}(X|Z_{1:k}) \delta X,$$

注意到泊松RFS可完全由它的强度函数来定性,如果 X 也是一个泊松RFS,则它的强度函数可表示为

$$D(\mathbf{x}) = \lambda s(\mathbf{x}).$$

此时,多目标概率密度函数可以写成

$$f(X) = e^{-\lambda} \prod_{\mathbf{x} \in X} \lambda s(\mathbf{x}). \quad (7)$$

其中: λ 为RFS中目标的泊松平均数, $s(\mathbf{x})$ 为单目标的密度函数.可以得出

$$\lambda = \int D(\mathbf{x}) d\mathbf{x}, \quad s(\mathbf{x}) = \frac{D(\mathbf{x})}{\lambda}.$$

PHD滤波预测方程为

$$D_{k|k-1}(\mathbf{x}) = \int P_{s,k} f_{k|k-1}(\mathbf{x}|\xi) D_{k-1|k-1}(\xi) d\xi + \gamma_k(\mathbf{x}). \quad (8)$$

其中: $P_{s,k}$ 为目标的存活概率, $f_{k|k-1}$ 为由 $k-1$ 时刻到 k 时刻多目标的状态RFS的状态转移密度, γ_k 为 k 时刻新生目标的强度.

PHD滤波更新方程为

$$D_{k|k}(\mathbf{x}) = (1 - P_{d,k}) D_{k|k-1}(\mathbf{x}) + \sum_{z \in Z_k} \frac{D_{k|k-1}(\mathbf{x}) P_{d,k} g_k(z|\mathbf{x})}{K_k(z) + \langle P_{d,k} g_k(z|\xi), D_{k|k-1} \rangle}. \quad (9)$$

其中: $P_{d,k}$ 为 k 时刻的检测概率, $g_k(\cdot|\mathbf{x})$ 为 k 时刻单目标似然函数, $K_k(\cdot)$ 为 k 时刻杂波RFS的强度.

为了导出更新步骤的闭式解,近似多目标滤波器的统计假设RFS是一个服从独立同分布(IID)的簇生分布,即推导势概率假设密度滤波器(CPHDF)所依据的统计假设.一个服从IID的随机集 X 可以完全由它的势分布 $\rho(n)$ 和单目标的密度函数 $s(\mathbf{x})$ 来表征.若多目标状态集合为 $X = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$, $|X| = n$,则多目标的概率密度函数为

$$f(X) \triangleq n \rho(n) s(\mathbf{x}_1) \cdots s(\mathbf{x}_n), \quad (10)$$

多目标的强度函数为

$$D(X) = s(\mathbf{x}) \sum_{n=1}^{\infty} n \cdot \rho(n). \quad (11)$$

下面给出PHD滤波器的粒子实现形式.

1) 预测步.令 $\{w_{k-1}^{(i)}, \mathbf{x}_{k-1}^{(i)}\}_{i=1}^{L_{k-1}}$ 表示 $k-1$ 时刻的粒子集,其中 L_{k-1} 表示样本数目. k 时刻预测样本由存活目标和新生目标两部分组成,其中存活目标样本由重要性密度函数 $q_k(\cdot|\mathbf{x}_{k-1}^{(i)}, Z_k)$ 来采样,即 $\tilde{\mathbf{x}}_k^{(i)} \sim q_k(\cdot|\mathbf{x}_{k-1}^{(i)}, Z_k)$, $i = 1, 2, \dots, L_{k-1}$,对应预测粒子的权重为

$$\tilde{w}_{k|k-1}^{(i)} = \frac{\phi_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)}, \mathbf{x}_{k-1}^{(i)}) w_{k-1}^{(i)}}{q_k(\tilde{\mathbf{x}}_k^{(i)}|\mathbf{x}_{k-1}^{(i)}, Z_k)}, \quad (12)$$

其中 $\phi_{k|k-1}(\mathbf{x}, \xi) = P_{s,k}(\xi) f_{k|k-1}(\mathbf{x}|\xi)$.

假设 $p_k(\cdot|Z_k)$ 为新生目标的概率密度函数,则采样新生粒子 $\tilde{\mathbf{x}}_k^{(i)} \sim p_k(\cdot|Z_k)$, $i = 1+L_{k-1}, \dots, L_{k-1}+J_k$,其中 J_k 为采样新生粒子的数目,对应粒子权重为

$$\tilde{w}_{k|k-1}^{(i)} = \frac{\gamma_k(\tilde{\mathbf{x}}_k^{(i)})}{J_k p_k(\tilde{\mathbf{x}}_k^{(i)}|Z_k)}. \quad (13)$$

2) 更新步.对于每个观测值 $z \in Z_k$,可以计算

$$E_k(z) = \sum_{j=1}^{L_{k-1}+J_k} \varphi_{k,z}(\tilde{\mathbf{x}}_k^{(j)}) \tilde{w}_{k|k-1}^{(j)},$$

其中 $\varphi_{k,z}(\mathbf{x}) = P_{d,k}(\mathbf{x}) g_k(z|\mathbf{x})$, $g_k(z|\mathbf{x})$ 为似然函数.然后更新粒子权重,得到

$$\tilde{w}_k^{(i)} = \left[1 - P_{d,k}(\tilde{\mathbf{x}}_k^{(i)}) + \sum_{z \in Z_k} \frac{\varphi_{k,z}(\tilde{\mathbf{x}}_k^{(i)})}{K_k(z) + E_k(z)} \right] \tilde{w}_{k|k-1}^{(i)}, \quad i = 1, 2, \dots, L_{k-1} + J_k. \quad (14)$$

3) 目标数估计,有

$$\tilde{N}_{k|k} = \sum_{j=1}^{L_{k-1}+J_k} \tilde{w}_k^{(j)}. \quad (15)$$

4) 重采样.对粒子集 $\{(\tilde{w}_k^{(i)}/\tilde{N}_{k|k}), \tilde{\mathbf{x}}_k^{(i)}\}_{i=1}^{L_{k-1}+J_k}$ 重新采样,并对权值进行归一化,得到粒子集 $\{w_k^{(i)}, \mathbf{x}_k^{(i)}\}_{i=1}^{L_k}$.

5) 目标状态提取.利用聚类算法从重采样后的样本集中提取 $\tilde{N}_{k|k}$ 个聚类中心,作为P-PHD滤波的最终目标状态.

本文研究的主要目的是基于信息论的传感器控制方法,实时地对传感器的位置进行控制,以达到对目标状态更好的估计.以下将详细介绍如何利用前文提到的方法对传感器进行控制.

2 传感器控制方案的求解

在目标跟踪领域,基于信息论的传感器控制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.信息熵可以度量模型参数的不确定性,它可通过贝叶斯统计方法进行计算.根据式(16),传感器轨迹控制问题可看作离散变量的最优控制问题,即使得评价函数对应的控制序列最大化.由式(17)可知,本

文选取的评价函数(即柯西施瓦兹(CS)距离)是由多目标先验概率密度和后验概率密度之间的信息熵确定的,CS距离越大,表明所获取的信息量越大.传感器控制其实是一系列决策过程的最终体现,每个决策的制定都依据一定的评价准则(式(16)),即依据多目标概率密度在控制前后的信息增益的测度达到最大的原则进行传感器控制.

先来定义在传感器控制中的相关要素.首先,依据 k 时刻的多目标后验概率密度函数 $f_k(\cdot|Z_{1:k})$,定义 k 时刻向后 H 步的多目标预测概率密度 $f_{k+H}(\cdot|Z_{1:k})$, $H \geq 1$.其次,用 U_k 表示可实现的传感器控制方案的集合, $Z_{k+1:k+H}(\mathbf{v}_H)$ 表示由控制方案 \mathbf{v}_H 所决定的量测集($\mathbf{v}_H \in U_k$).为了减少计算的复杂度,选用 $H=1$ 的控制方案,该方案亦称为“Myopic”方案^[18].最后,对于每一个传感器运动 \mathbf{v} 给定一个对应的评价函数 $R(\mathbf{v})$,最优控制的准则是使评价函数 $R_{k+H}(\cdot)$ 对应的最优控制序列最大化.用 \mathbf{u}_k 表示最优控制序列,则该序列按以下准则确定:

$$\mathbf{u}_k = \arg \max_{\mathbf{v} \in U_k} E[R_{k+H}(\mathbf{v})]. \quad (16)$$

其中评价函数由多目标的先验概率密度和后验概率密度之间的信息距离 $D_{CS}(\cdot, \cdot)$ 确定,表示为

$$R_{k+H}(\mathbf{v}) = D_{CS}(f_{k+H}(X|Z_{1:k}), f_{k+H}(X|Z_{1:k}, Z_{k+1:k+H}(\mathbf{v}))). \quad (17)$$

以下的重点将介绍如何利用多目标概率密度的近似统计特性去推导CS距离的表达.

2.1 柯西施瓦兹距离的求解

CS距离可通过多目标的先验概率密度函数 f_0 和后验概率密度函数 f_1 来表达,其表达式为

$$D_{CS}(f_0, f_1) = -\log \left(\frac{\int f_0(X)f_1(X)\delta X}{\sqrt{\int f_0(X)^2\delta X \int f_1(X)^2\delta X}} \right), \quad (18)$$

其中 f_0 和 f_1 可由式(5)和(6)得到.

若多目标概率密度服从IID的簇生分布,则根据式(10),有

$$f_0(X) = n! \rho_0(n) \prod_{\mathbf{x} \in X} s_0(\mathbf{x}), \quad (19)$$

$$f_1(X; \mathbf{v}) = n! \rho_1(n; \mathbf{v}) \prod_{\mathbf{x} \in X} s_1(\mathbf{x}; \mathbf{v}). \quad (20)$$

其中: ρ_0 和 ρ_1 为这两个概率密度函数的势分布,分别服从均值为 λ_0 和 λ_1 的泊松分布,可表示为

$$\rho_0(n) = \frac{e^{-\lambda_0} \lambda_0^n}{n!},$$

$$\rho_1(n; \mathbf{v}) = \frac{e^{-\lambda_1(\mathbf{v})} \lambda_1(\mathbf{v})^n}{n!}. \quad (21)$$

假设预测和更新的强度函数都是泊松RFS,并且适用于PHD滤波器的递推公式,如前所述,在这种情况下可分别得到

$$\lambda_0 = \int D_0(\mathbf{x})d\mathbf{x},$$

$$\lambda_1(\mathbf{v}) = \int D_1(\mathbf{x}; \mathbf{v})d\mathbf{x}. \quad (22)$$

2.2 评价函数的计算

根据式(17)和(18),评价函数可表示为

$$R(\mathbf{v}) = -\log \left(\frac{\int f_0(X)f_1(X; \mathbf{v})\delta X}{\sqrt{\int f_0(X)^2\delta X \int f_1(X; \mathbf{v})^2\delta X}} \right). \quad (23)$$

由式(19)和(20),可将评价函数写为如下形式:

$$R(\mathbf{v}) = \frac{1}{2} \log \sum_{n=0}^{\infty} n! \rho_0(n)^2 \left[\int s_0(\mathbf{x})^2 d\mathbf{x} \right]^n + \frac{1}{2} \log \sum_{n=0}^{\infty} n! \rho_1(n; \mathbf{v})^2 \left[\int s_1(\mathbf{x}; \mathbf{v})^2 d\mathbf{x} \right]^n - \log \sum_{n=0}^{\infty} n! \rho_0(n) \rho_1(n; \mathbf{v}) \left[\int s_0(\mathbf{x}) s_1(\mathbf{x}; \mathbf{v}) d\mathbf{x} \right]^n. \quad (24)$$

将式(21)代入(24)可得

$$R(\mathbf{v}) = \lambda_0 + \frac{1}{2} \log \sum_{n=0}^{\infty} \frac{1}{n!} \left[\int \lambda_0^2 s_0(\mathbf{x})^2 d\mathbf{x} \right]^n + \lambda_1(\mathbf{v}) + \frac{1}{2} \log \sum_{n=0}^{\infty} \frac{1}{n!} \left[\int \lambda_1(\mathbf{v})^2 s_1(\mathbf{x}; \mathbf{v})^2 d\mathbf{x} \right]^n - \lambda_0 - \lambda_1(\mathbf{v}) - \log \sum_{n=0}^{\infty} \frac{1}{n!} \left[\int \lambda_0 s_0(\mathbf{x}) \lambda_1(\mathbf{v}) s_1(\mathbf{x}; \mathbf{v}) d\mathbf{x} \right]^n. \quad (25)$$

已知恒等式 $e^x = \sum_{n=0}^{\infty} x^n/n!$,则式(25)可化简,得

$$R(\mathbf{v}) = \frac{1}{2} \left[\int \lambda_0^2 s_0(\mathbf{x})^2 d\mathbf{x} \right] + \frac{1}{2} \left[\int \lambda_1(\mathbf{v})^2 s_1(\mathbf{x}; \mathbf{v})^2 d\mathbf{x} \right] - \left[\int \lambda_0 s_0(\mathbf{x}) \lambda_1(\mathbf{v}) s_1(\mathbf{x}; \mathbf{v}) d\mathbf{x} \right]. \quad (26)$$

通过泊松随机有限集(FLS)的强度函数 $D(\mathbf{x}) = \lambda s(\mathbf{x})$

可得评价函数为

$$R(\mathbf{v}) = \frac{1}{2} \left[\int D_{k|k-1}(\mathbf{x})^2 d\mathbf{x} \right] + \frac{1}{2} \left[\int D_{k|k}(\mathbf{x}; \mathbf{v})^2 d\mathbf{x} \right] - \left[\int D_{k|k-1}(\mathbf{x}) D_{k|k}(\mathbf{x}; \mathbf{v}) d\mathbf{x} \right]. \quad (27)$$

用一组带有权值的随机样本粒子 $\{w_{k|k-1}^{(i)}, \mathbf{x}_{k|k-1}^{(i)}\}_{i=1}^N$

表示预测强度函数,可表示为

$$D_{k|k-1}(\mathbf{x}) \approx \sum_{i=1}^N \tilde{w}_{k|k-1}^{(i)} \delta_{\mathbf{x}_{k|k-1}^{(i)}}(\mathbf{x}), \quad (28)$$

其中 $\delta_{\mathbf{x}}(\mathbf{x})$ 是狄拉克函数. 在执行传感器动作 $\mathbf{v} \in U_k$ 时,得到的更新强度函数为

$$D_{k|k}(\mathbf{x}) \approx \sum_{i=1}^N \tilde{w}_{k|k}^{(i)} \delta_{\mathbf{x}_{k|k-1}^{(i)}}(\mathbf{x}). \quad (29)$$

其中权重 $\tilde{w}_{k|k}^{(i)}$ 可根据式(9)计算,即

$$\tilde{w}_{k|k}^{(i)} = (1 - P_{d,k})\tilde{w}_{k|k-1}^{(i)} + \sum_{\mathbf{z} \in Z_k} \frac{\tilde{w}_{k|k-1}^{(i)} P_{d,k} g_k(\mathbf{z})}{K_k(\mathbf{z}) + \langle P_{d,k} g_k(\mathbf{z}|\xi), \tilde{w}_{k|k-1}^{(i)} \rangle}. \quad (30)$$

由式(28)和(29)可知,可以用一组相同的粒子去近似 $D_{k|k-1}(\mathbf{x})$ 和 $D_{k|k}(\mathbf{x})$,区别仅在于粒子的权重不同. 将式(28)和(29)代入(27),可得评价函数的粒子近似表示为

$$R(\mathbf{v}) \approx \frac{1}{2} \left(\sum_{i=1}^N w_{k|k-1}^{(i)2} \right) + \frac{1}{2} \left(\sum_{i=1}^N w_{k|k}^{(i)2} \right) - \sum_{i=1}^N w_{k|k-1}^{(i)} w_{k|k}^{(i)}. \quad (31)$$

2.3 算法程序伪码

为了说明算法流程,列出算法伪码如下:

1) 输入.

$\{w_{k-1}^{(i)}, \mathbf{x}_{k-1}^{(i)}\}_{i=1}^{L_{k-1}}$, 传感器位置 $\mathbf{x}_{s,k} = [x_{s,k}, y_{s,k}]^T$.

2) 预测和新生.

for $i = 1 : L_{k-1}$

由式(12)得到预测粒子权值;

end for

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

由式(13)得到新生粒子权值;

end for

3) 传感器控制.

确定所有可能的控制集合 U_k ,并对控制集中的每种控制方案确定传感器当前时刻的精确位置 $\mathbf{x}_{s,k}$;

根据滤波部分中预测的目标状态集合 $\hat{X}_{k|k-1}$,结合所有可能的控制方案集合 U_k 生成相应虚拟量测集合 $Z_k(\mathbf{v})$;

按照式(31)求取各位置的评价函数 $R(\mathbf{v})$,并确定最终控制方案 \mathbf{v}_k ;

求取传感器在新位置所接收到的量测 $Z_k(\mathbf{v}_k)$.

4) 更新.

计算 $E_k(\mathbf{z})$;

for $i = 1 : L_{k-1} + J_k$,根据式(14)更新权重得到 $\tilde{w}_k^{(i)}$.

5) 重采样.

计算目标数目 $\tilde{N}_{k|k} = \sum_{j=1}^{L_{k-1}+J_k} \tilde{w}_k^{(j)}$.

6) 权值归一化.

求取 $\{w_k^{(i)}, \mathbf{x}_k^{(i)}\}_{i=1}^{L_k}$.

7) 状态提取.

target_index = find($w_k^{(i)} > 0.5$), 求取目标状态集合 \hat{X}_k .

8) 输出.

目标个数 $\tilde{N}_{k|k}$,目标状态集合 \hat{X}_k ,传感器位置 $\mathbf{x}_{s,k} = [x_{s,k}, y_{s,k}]^T$.

3 仿真分析

3.1 场景

设定监控区域为 $[-\pi, \pi] \times [0, 2500 \text{ m}]$,并在该区域中构造场景进行 Monte Carlo 仿真. $T = 1 \text{ s}$ 为量测采样周期,总共采样40次.单目标粒子采样平均数为500,新生粒子数为50.实验中的检测概率取值为 $P_{d,k} = 0.98$,杂波平均数 $\lambda = 5$,目标存活概率 $P_{s,k} = 0.99$.

滤波的跟踪性能采用 OSPA(Optimal subpattern assignment)距离^[9]来评价,OSPA距离的定义如下:

设多目标状态集合为 $X = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$,滤波器的状态估计集合为 $Y = \{\mathbf{y}_1, \dots, \mathbf{y}_m\}$,若 $n \leq m$,则 OSPA距离为

$$\bar{d}_p^c(X, Y) = \left\{ \frac{1}{m} \left[\min_{\pi \in \Pi_m} \sum_{i=1}^n d^{(c)}(\mathbf{x}_i, \mathbf{y}_{\pi(i)})^p + c^p(m-n) \right] \right\}^{\frac{1}{p}}. \quad (32)$$

其中: $\bar{d}^{(c)}(\mathbf{x}, \mathbf{y}) = \min(c, \|\mathbf{x} - \mathbf{y}\|)$, Π_m 表示所有 $\{1, 2, \dots, m\}$ 的排列构成的集合,距离阶次 $p \geq 1$,截断系数 $c > 0$.若 $n > m$,则 $\bar{d}_p^c(X, Y) = \bar{d}_p^c(Y, X)$.实验中选取 $p = 1, c = 100 \text{ m}$.仿真实验的软硬件条件为: Matlab 2012b, Windows 7, AMD A8-6500 3.5 GHz, RAM 4 GB.

场景中目标轨迹均为近常速运动模型(NCVM),共计出现4个目标.状态转移密度

$$f(\mathbf{x}_k | \mathbf{x}_{k-1}) = \mathcal{N}(\mathbf{x}_k; F_k \mathbf{x}_{k-1}, Q_k). \quad (33)$$

其中

$$F_k = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, Q_k = \sigma_v^2 \begin{bmatrix} \frac{T^2}{2} & 0 \\ 0 & \frac{T^2}{2} \\ T & 0 \\ 0 & T \end{bmatrix},$$

$$\sigma_v = 5 \text{ m/s}^2.$$

对于距离方位跟踪(RBT),式(3)有如下形式:

$$z_k = \begin{bmatrix} \sqrt{(x_k - x_{s,k})^2 + (y_k - y_{s,k})^2} \\ \tan^{-1} \left(\frac{y_k - y_{s,k}}{x_k - x_{s,k}} \right) \end{bmatrix} + v_k. \quad (34)$$

量测噪声 $v_k \sim \mathcal{N}(\cdot, 0, R_k)$, $R_k = \text{diag}\{\sigma_r^2, \sigma_\theta^2\}^T$, $\sigma_r = 0.5 \text{ m}$, $\sigma_\theta = 0.57^\circ$, 分别为距离量测标准差及方位角量测标准差.

3.2 传感器控制集合

假设传感器在当前时刻的实际控制位置可表示为 $x_{s,k} = [x_{s,k}, y_{s,k}]^T$, 则下一时刻传感器所有可能的位置可写成如下形式:

$$U_{k+1} = \left\{ \begin{aligned} &x_{s,k} + jv_{s,c} \frac{T}{N_R} \cos \left(l \frac{2\pi}{N_\theta} \right), \\ &y_{s,k} + jv_{s,c} \frac{T}{N_R} \sin \left(l \frac{2\pi}{N_\theta} \right), \\ &j = 1, 2, \dots, N_R; l = 1, 2, \dots, N_\theta \end{aligned} \right\}. \quad (35)$$

本文选用 $N_R = 2$, $N_\theta = 8$, 则传感器的控制方案共有 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 10m/s.

3.3 实验仿真

通过多目标距离方位跟踪的仿真实验, 可得量测及杂波分布如图 1 所示. 单次跟踪中模型轨迹及滤波结果如图 2 所示, 多目标的新生和消亡的时刻如表 1 所示.

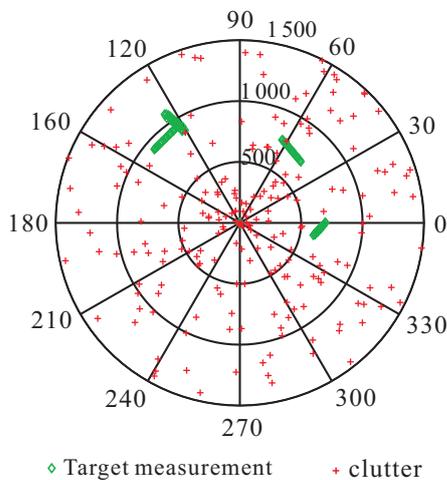


图 1 量测及杂波分布

首先选择 P-PHD 滤波器在设定场景下进行多目标跟踪实验, 对比验证本文所提出算法与其他 4 种不

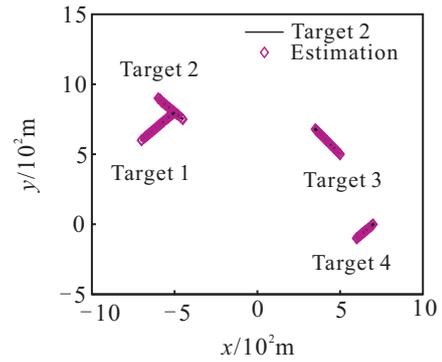


图 2 P-PHD 滤波器的跟踪效果及其真实轨迹运动

表 1 目标的存活周期

	目标 1	目标 2	目标 3	目标 4
新生时间/s	1	1	10	20
消亡时间/s	40	30	40	40

同控制方案的跟踪性能. 其中方案 1 是 Stationary, 即传感器保持原位不动. 方案 2 是 Prior zigzag, 如图 3 所示, 即依据传感器自身的容许速率(10 m/s)运动并多次改变其运动方向, 这是纯方位跟踪中常用的一种控制轨迹. 该方案是在跟踪过程中传感器以几个瞬时机动的方式形成, 目的是使传感器与多目标变化形成较好的几何关系, 其次能够保证纯方位多目标的跟踪可观性. 方案 3 是 Random control, 即从传感器控制集合中随机选择出一种控制方案. 方案 4 是 Rényi control, 即依据 Rényi 距离作为评价函数的传感器控制方案^[14]. 方案 5 是本文所提出的控制方案.

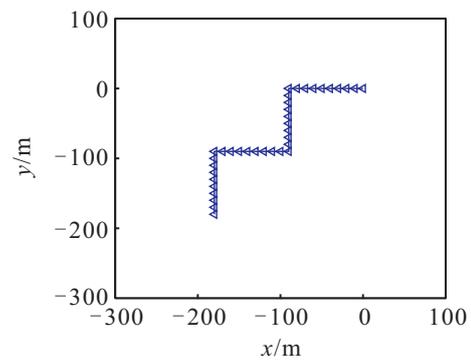


图 3 先验控制方案

图 4 是采用本文控制方案在单次实验中对传感器轨迹控制的效果. 在整个控制过程中, 为了使观测的信息量最大化, 传感器会根据信息增益最大化的准则对自身的位置进行不断地调节, 从而形成每个时刻传感器的最佳观测位置. 由图 4 可看出, 随着目标的新生和消亡, 传感器的位置会产生明显的机动控制作用以适应总体多目标概率密度函数的变化. 而在后续的多目标跟踪过程中, 会始终遵循多目标概率密度在控制前后的信息增益的测度达到最大进行传感器控制.

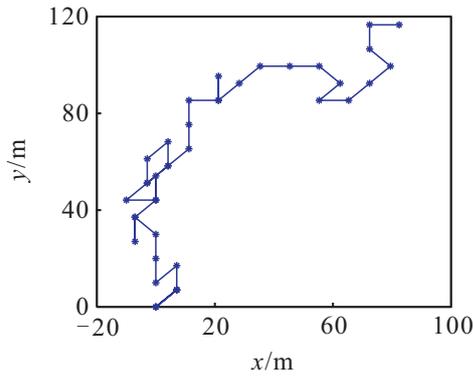


图 4 多目标距离方位跟踪中的传感器轨迹控制

利用 OSPA 距离作为多目标整体跟踪性能的评价指标,对设定场景中的目标进行 100 次 Monte Carlo(MC) 仿真实验.图 5 给出了 5 种控制方案的 OSPA 距离对比,可以看出 5 种控制方案都有相对不错的跟踪性能.本文所提出方案的跟踪效果整体上要优于方案 2,这说明纯方位跟踪更多的是考虑可观因素,故传感器机动能力对其影响较大.本文所提出方案可通过多目标先验概率密度与多目标后验概率密度之间的差异来反映信息量的增益,继而对传感器的运动作出指导以获取更完备的量测信息,最终得到更好的跟踪性能.由图 5 还可以看出,方案 4 和方案 5 的跟踪效果总体上优于前 3 种方案,而方案 5 总体上优于方案 4.目标数估计效果如图 6 所示,由图 6 可看出各控制方案的势估计均值都接近于实际的目标数,经过计算单步目标势估计误差平均值也相差不大.这说明 OSPA 所反映的跟踪效果的差异主要体现在多目标的状态估计.

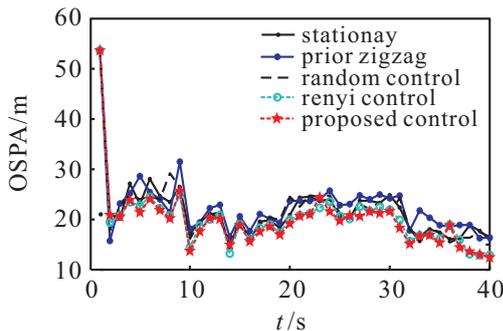


图 5 距离方位跟踪中多目标位置估计 OSPA 的比较

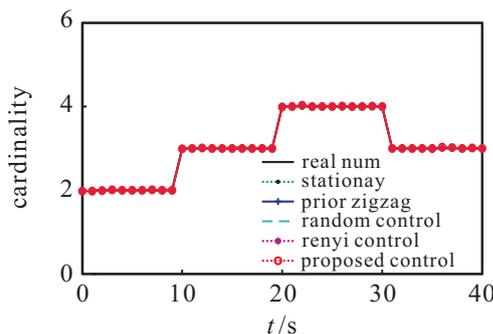


图 6 目标个数估计的均值

图 7 显示了在多目标跟踪中 100 次 MC 仿真实验中所有传感器的控制位置.显然,在 100 次 MC 仿真实验中每次实验传感器的运动轨迹都不一致(受杂波和噪声的影响),但是该轨迹云仍能充分呈现出仿真场景下多目标 RBT 的最优轨迹控制的总体趋势.

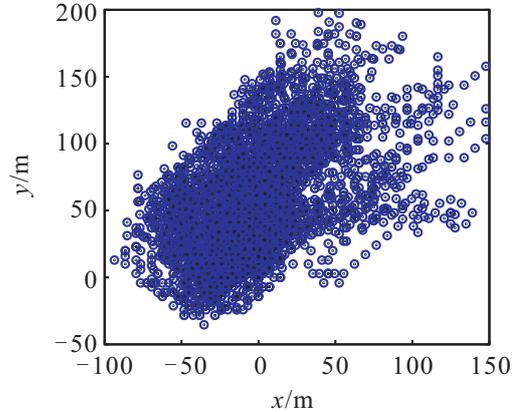


图 7 100 次蒙特卡罗仿真中所有传感器的位置

各方案的单步平均运行时间如表 2 所示.可以看出,方案 1、方案 2 和方案 3 的平均运行时间相差不大,所花费的时间主要是由滤波算法本身引起的,而方案 4、方案 5 相对前 3 种方案要花费更多的时间,原因是它们需根据多目标先验密度函数和后验密度函数计算 Rényi 距离和 CS 距离,进而求解最佳的传感器控制方案,以得到更好的多目标跟踪性能.

表 2 各方案单步平均运行时间

	方案 1	方案 2	方案 3	方案 4	方案 5
时间/s	1.8649	1.8723	1.9402	7.9369	7.8401

4 结 论

本文的重点和创新点是在 POMDP 的理论框架下,提出了一种基于信息论的传感器控制策略,研究利用 CS 距离作为多目标先验概率密度和后验概率密度之间信息增益的度量,将其作为传感器控制的评价函数,进而利用多目标概率密度的近似统计特性去推导 CS 距离的表达形式,结合粒子概率假设密度滤波器的实现形式对最终的传感器控制方案进行求解.实验结果验证了本文所提出算法的有效性.

参考文献 (References)

[1] Mahler R P S. Advances in statistical multisource-multitarget information fusion[M]. Norwood: House, 2014: 825-860.
 [2] Hero A O, Cochran D. Sensor management: Past, present, and future[J]. IEEE Sensors J, 2011, 11(12): 3064-3075.
 [3] Castañón D A, Carin L. Stochastic control theory for sensor management[M]. Foundations and Applications of Sensor Management, 2007: 7-32.

- [4] Reuter S, Vo B T, Vo B N, et al. The labeled multi-Bernoulli filter[J]. IEEE Trans on Signal Processing, 2014, 62(12): 3246-3260.
- [5] Vo B N, Vo B T, Phung D. Labeled random finite sets and the Bayes multi-target tracking filter[J]. IEEE Trans on Signal Processing, 2014, 62(24): 6554-6567.
- [6] Ristic B, Vo B T, Vo B N, et al. A tutorial on bernoulli filters: Theory, implementation and applications[J]. IEEE Trans on Signal Processing, 2013, 61(13): 3406-3430.
- [7] Mahler R P S. Statistical multisource-multitarget information fusion[M]. Norwood: Artech House, 2007: 655-667.
- [8] Mahler R P S. Multitarget bayes filtering via first-order multitarget moments[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.
- [9] Snyder D L, Miller M I. Random point processes in time and space[M]. New York: Springer Science & Business Media, 2012: 41-92.
- [10] Daley D J, Vere-Jones D. An introduction to the theory of point processes, volume II: General theory and structure[M]. New York: Springer Science & Business Media, 2007: 458-526.
- [11] Hoang H G, Vo B T. Sensor management for multi-target tracking via multi-Bernoulli filtering[J]. Automatica, 2014, 50(4): 1135-1142.
- [12] Ristic B, Arulampalam S. Bernoulli particle filter with observer control for bearings-only tracking in clutter[J]. IEEE Trans on Aerospace and Electronic Systems, 2012, 48(3): 2405-2415.
- [13] Ristic B, Vo B N. Sensor control for multi-object state-space estimation using random finite sets[J]. Automatica, 2010, 46(11): 1812-1818.
- [14] Ristic B, Vo B N, Clark D. A note on the reward function for PHD filters with sensor control[J]. IEEE Trans on Aerospace & Electronic Systems, 2011, 47(2): 1521-1529.
- [15] 陈辉, 韩崇昭. 机动多目标跟踪中的传感器控制策略的研究[J]. 自动化学报, 2016, 42(4): 513-522. (Chen H, Han C Z. Sensor control strategy for maneuvering multi-target tracking[J]. Acta Automatica Sinica, 2016, 42(4): 513-522.)
- [16] Kampa K, Hasanbelliu E, Principe J C. Closed-form cauchy-schwarz PDF divergence for mixture of Gaussians[C]. The 2011 Int Joint Conf on Neural Networks(IJCNN). IEEE, 2011, 57(10): 2578-2585.
- [17] Vo B N, Singh S, Doucet A. Sequential Monte Carlo methods for multitarget filtering with random finite sets[J]. IEEE Trans on Aerospace & Electronic Systems, 2005, 41(4): 1224-1245.
- [18] Mahler R P S. Multitarget sensor management of dispersed mobile sensors[C]. Theory and Algorithms for Cooperative Systems. Singapore: World Scientific Publishing Co, 2004: 239-310.
- [19] Schuhmacher D, Vo B T, Vo B N. A consistent metric for performance evaluation of multi-object filters[J]. IEEE Trans on Signal Processing, 2008, 56(8): 3447-3457.

(责任编辑: 孙艺红)

《控制与决策》被评为“2017中国最具国际影响力学术期刊”

本刊讯 2017年11月22日~23日,由中国期刊协会、中国科学技术期刊编辑学会、中国高校科技期刊研究会、全国高等学校文科学报研究会、《中国学术期刊(光盘版)》电子杂志社有限公司等5家单位联合主办、同方知网承办的“2017中国学术期刊未来论坛”在北京会议中心隆重举行.中国学术期刊(光盘版)电子杂志社有限公司和清华大学图书馆在会上联合发布了《2017中国学术期刊国际引证年报》,公布了2017年度“中国最具国际影响力学术期刊”和“中国国际影响力优秀学术期刊”名单.从此次大会上获悉,《控制与决策》在“2017中国学术期刊影响因子年

报”全国3818种自然科学与工程技术类期刊中,国际影响力指数排名TOP5%,被评为“2017中国最具国际影响力学术期刊”;在133种自动化技术、计算机技术类期刊中影响力指数排名第6,位居Q1区.

“国际影响力品牌期刊”的遴选采用更为科学的综合评价指标——期刊影响力指数(CI),该指数同时考虑了期刊影响因子(IF)、总被引频次(TC)两个指标,有效避免了使用影响因子单指标评价期刊的局限性,可综合反映学术期刊的学术影响力和质量水平.“最具”、“优秀”分别选自按CI正排序的TOP5%和TOP5%~TOP10%期刊.