

基于目标出生强度在线估计的多目标跟踪算法

闫小喜¹ 韩崇昭¹

摘要 针对多目标跟踪中未知的目标出生强度, 提出了基于 Dirichlet 分布的目标出生强度在线估计算法, 来改进概率假设密度滤波器在多目标跟踪中的性能. 算法采用有限混合模型来描述未知目标出生强度, 使用仅依赖于混合权重的负指数 Dirichlet 分布作为混合模型参数的先验分布. 利用拉格朗日乘子法推导了混合权重在极大后验意义下的在线估计公式; 混合权重在线估计过程利用了负指数 Dirichlet 分布的不稳定性, 驱使与目标出生数据不相关分量的消亡. 以随机近似过程为分量均值和方差的在线估计策略, 推导了基于缺失数据的分量均值与方差的在线估计公式. 在无法获得初始步出生目标先验分布的约束下, 提出了在混合模型上增加均匀分量的初始化方法. 以当前时刻的多目标状态估计值为出发点, 提出了利用概率假设密度滤波器消弱杂波影响的出生目标数据获取方法. 仿真结果表明, 提出的目标出生强度在线估计算法改进了概率假设密度滤波器在多目标跟踪中的性能.

关键词 多目标跟踪, 概率假设密度, 目标出生强度, 在线估计, 极大后验, Dirichlet 分布

DOI 10.3724/SP.J.1004.2011.00963

Multiple Target Tracking Algorithm Based on Online Estimation of Target Birth Intensity

YAN Xiao-Xi¹ HAN Chong-Zhao¹

Abstract As far as the unknown target birth intensity in multiple target tracking is concerned, an online estimation algorithm of target birth intensity is proposed to improve the performance of probability hypothesis density filter in multiple target tracking. The finite mixture model is adopted to model the unknown intensity of target birth. Dirichlet distribution with negative exponent parameters, which only depends on the mixing weights, is used as the prior distribution of parameters in the mixture model. The online estimation formulation of mixing weight is derived by Lagrange multiplier in the sense of maximum a posteriori. The instability of Dirichlet distribution with negative exponent parameters is applied in driving the components irrelevant with birth targets to extinction during the online estimation procedure of mixing weights. Stochastic approximation procedure is regarded as the strategy of online estimation of component mean and covariance. The online estimation formulations of component mean and covariance are derived based on missing data. An initialization method is developed by adding a uniform distribution into the mixing model, under the constraint that no prior distribution of target birth is obtained in initialization. From the standpoint of current estimates of multiple target states, the method of achieving the data of birth targets, which makes full use of the ability of probability hypothesis density filter to reduce the effect of clutter, is presented. Simulation results show that the proposed online estimation algorithm of target birth intensity can improve the performance of probability hypothesis density filter in multiple target tracking.

Key words Multiple target tracking, probability hypothesis density (PHD), target birth intensity, online estimation, maximum a posteriori (MAP), Dirichlet distribution

多目标跟踪是研究从目标量测和杂波中估计目标数目与各个目标状态的方法. 经过几十年

的发展, 人们已经提出了众多的多目标跟踪算法, 关于这些算法的最新综述可以参考文献 [1]. 到目前为止, 已有的多目标跟踪算法大都是基于数据关联的, 需要建立量测和目标的对应关系^[2]. 基于数据关联的多目标跟踪算法, 从分散的角度看待多目标跟踪问题, 以建立的目标与量测的关系为基础, 把多目标跟踪问题转化为多个单目标跟踪问题. 然而, 数据关联本身是一个很复杂的问题, 导致基于数据关联的多目标跟踪算法更加困难. 从算法逻辑的角度看, 数据关联对于多目标跟踪来说可能是不必要的, 因为我们在解决一个困难的问题时, 没有必要再引入一个更加困难的问题. 从集值估计的角度重新认识多目标跟踪问题, 为我们提供了一种在无需数据关联的情况下解决多

收稿日期 2010-09-29 录用日期 2010-12-27
Manuscript received September 29, 2010; accepted December 27, 2010

国家重点基础研究发展计划 (973 计划) (2007CB311006), 国家自然科学基金创新研究群体科学基金 (60921003) 资助

Supported by National Basic Research Program of China (973 Program) (2007CB311006) and Foundation for Innovative Research Groups of National Natural Science Foundation of China (60921003)

1. 西安交通大学电子与信息工程学院综合自动化研究所智能网络与网络安全教育部重点实验室、机械制造系统工程国家重点实验室 西安 710049

1. Key Laboratory for Intelligent Networks and Network Security of Ministry of Education and State Key Laboratory for Manufacturing Systems Engineering, Institute of Integrated Automation, School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049

目标跟踪问题的可能. 虽然点过程理论被公认为解决无数据关联情况下多目标跟踪问题的数学基础^[3], 但一直没有形成系统的、严密的算法, 直到基于随机有限集的概率假设密度 (Probability hypothesis density, PHD) 滤波器的出现^[4-6]. PHD 是一种“单密度”, 它把定义在多目标状态空间上的多目标后验密度映射到单目标状态空间上; 在单目标状态空间上的积分值为期望目标数. 从统计量的角度看, PHD 是多目标概率密度的一阶矩, 它在每个真实目标状态附近取得峰值. PHD 滤波器完全实现了无数据关联的多目标跟踪, 把分散观点下的目标起始、目标运动和目标消亡的三个阶段无缝地结合为一个整体, 而不必对跟踪过程的各个阶段进行判断. PHD 滤波器主要有两种实现方式: 一种是序贯蒙特卡罗 (Sequential Monte Carlo, SMC) 实现^[7-9], 另外一种是高斯混合实现^[10-11]; 前者适用于非线性、非高斯的情况, 后者适合于线性高斯的情况; 两种实现方式的收敛性已在文献中^[12-13] 得到证明. 类比卡尔曼滤波器相对于常值卡尔曼滤波器的优势, 势化 PHD (Cardinalized PHD, CPHD) 滤波器相对于 PHD 滤波器也有很大的优势, 因为 CPHD 在传递 PHD 的同时还传递了目标数分布^[14-16]. 然而, 因为它的计算量很大, 所以目前只有在线性高斯简化假设条件下的高斯混合实现形式^[17-18]. PHD 和 CPHD 所具有的优点, 使其在多目标跟踪的多个领域得到了初步应用并有着很好的应用前景, 如机动目标跟踪^[19-20]、航迹管理^[21-22]、拓展目标跟踪^[23-24]、图像目标跟踪^[25-27]、声纳跟踪^[28]、微弱信号检测^[29]、发射源定位^[30] 等.

目标出生强度是 PHD 滤波器的重要组成部分, 对多目标跟踪算法性能有较大的影响, 尤其是对出生目标跟踪及时性的影响. 在监视区域内, 出生目标实际上从几个单独可能区域内随机产生. 在实际跟踪算法中, 无法获得关于该目标产生区域的先验信息以及出生目标数目信息, 真实的目标出生强度是未知的. PHD 滤波器对该未知目标出生强度只是进行了很粗略地假设: 假设出生目标在监视区域内均匀分布, 并指定出生目标个数, 强制把目标出生强度作为已知先验. 此粗略强制假设对出生目标的跟踪有较大的影响: 以 PHD 滤波器的 SMC 实现为例, 预测步关于出生目标的大部分粒子是在目标产生区域外的区域抽取的, 而不是在目标出生区域内抽取的, 所以只有少量的粒子能够反映出出生目标; 再经过 PHD 更新步中的重采样, 能够反映出出生目标的粒子就更少了. 这就造成新出生目标不能及时地被跟踪上, 增加了错误目标数估计出现的次数, 从而影响了多目标跟踪算法的性能.

针对未知的目标出生强度, 本文提出了基于

Dirichlet 分布的目标出生强度极大后验在线估计算法, 来改进 PHD 滤波器在多目标跟踪中的性能. 该目标出生强度估计算法是在线估计算法而非批处理算法, 它随着每个时刻出生目标数据的获得而对目标出生强度进行在线估计. 算法利用负指数 Dirichlet 分布的不稳定性来驱使与目标出生强度不相关的分量消亡. 随着时间步的增加, 预测步中关于目标出生强度的粒子抽样越来越多地集中在目标产生区域, 所以增加了新出生目标被跟踪上的几率, 减少了目标出生时错误目标数估计出现的几率, 从而改进了 PHD 滤波器在多目标跟踪中的性能.

1 问题描述

多目标 Bayes 滤波器的预测步与更新步分别为

$$f_{k|k-1}(X|Z_{1:k-1}) = \int f_{k|k-1}(X|W) \times f_{k-1|k-1}(W|Z_{1:k-1}) \delta W \quad (1)$$

和

$$f_{k|k}(X|Z_{1:k}) = K^{-1} f_{k|k-1}(Z_k|X) \times f_{k|k-1}(X|Z_{1:k-1}) \quad (2)$$

其中, X 是多目标状态集合, Z_k 是时刻 k 的多目标量测集合, $Z_{1:k}$ 是从时刻 1 到时刻 k 的多目标量测集合, $f_{k|k}(X|Z_{1:k})$ 是多目标后验密度, $f_{k|k-1}(X|Z_{1:k-1})$ 是多目标预测密度, $f_{k|k-1}(X|W)$ 是多目标状态转移密度, $G_{k|k-1}(Z_k|X)$ 是多目标似然函数, $K = \int f_{k|k-1}(Z_k|X) f_{k|k-1}(X|Z_{1:k-1}) \delta X$ 是 Bayes 正规化因子. 利用随机有限集统计量中的随机积分和随机导数推导出多目标后验密度的一阶矩近似, 得到 PHD 滤波器的预测步和更新步分别为

$$D_{k|k-1}(x_k|Z_{1:k-1}) = \gamma_k(x_k) + \int [\beta_{k|k-1}(x_k|x_{k-1}) + e_{k|k-1}(x_{k-1}) f_{k|k-1}(x_k|x_{k-1})] \times D_{k-1|k-1}(x_{k-1}|Z_{1:k-1}) dx_{k-1} \quad (3)$$

和

$$D_{k|k}(x_k|Z_{1:k}) = (1 - P_D(x_k)) D_{k|k-1}(x_k|Z_{1:k-1}) + \sum_{z \in Z_k} \frac{\varphi_{k,z}(x_k)}{D_k(z)} D_{k|k-1}(x_k|Z_{1:k-1}) \quad (4)$$

其中, $D(\cdot)$ 表示强度, $\gamma_k(x_k)$ 是出生强度, $\beta_{k|k-1}(x_k|x_{k-1})$ 是源自状态 x_{k-1} 的衍生强度, $D_k(z) = \kappa_k(z) + C_k(z)$ 是量测

z 的强度, $\kappa_k(z)$ 是杂波强度, $e_{k|k-1}(x_k)$ 是存活概率, $f_{k|k-1}(x_k|x_{k-1})$ 是状态转移密度, $\varphi_{k,z}(x_k) = P_D(x_k)g_{k|k}(z|x_k)$, $C_k(z) = \int \varphi_{k,z}(x_k)D_{k|k-1}(x_k|Z_{1:k-1})dx$, $g_{k|k}(z|x_k)$ 是单目标似然函数, $P_D(x_k)$ 是检测概率^[4, 6].

PHD 滤波器 SMC 实现的基本思想: 以随机有限集统计量与概率密度函数的关系为基础, 利用 SMC 方法近似 PHD 滤波器中的积分运算环节^[7]. 该实现方式用大量加权粒子所构成的粒子集合来表示 PHD, 加权粒子通过重要性采样和重采样步骤在时间上进行传播, 从而实现 PHD 在时间上的传播. 不同于一般的粒子滤波器, 此实现中加权粒子的权重和不再是基本粒子滤波器中的 1 而是期望目标数, 因为 PHD 在目标状态空间上的积分值是期望目标数目而非 1. PHD 滤波器 SMC 实现的主要步骤总结如下:

步骤 1. 预测

对 $k-1$ 时刻存活目标的粒子集合进行重要性采样 $\tilde{x}_k^{(i)} \sim q_k(\cdot|x_{k-1}^{(i)}, Z_k)$, 并计算其相应的预测权重

$$\tilde{w}_{k|k-1}^{(i)} = \frac{\phi_{k|k-1}(\tilde{x}_k^{(i)}, x_{k-1}^{(i)})}{q_k(\tilde{x}_k^{(i)}|x_{k-1}^{(i)}, Z_k)} w_{k-1}^{(i)} \quad (5)$$

其中, $i = 1, \dots, L_{k-1}$, L_{k-1} 表示时刻 $k-1$ 的粒子数目, $\phi(x_k, x_{k-1}) = e_{k|k-1}(x_{k-1})f_{k|k-1}(x_k|x_{k-1}) + \beta(x_k|x_{k-1})$.

对 k 时刻出生目标进行粒子采样 $\tilde{x}_k^{(i)} \sim p_k(\cdot|Z_k)$ 并计算相应粒子的权重

$$\tilde{w}_{k|k-1}^{(i)} = \frac{1}{J_k} \frac{\gamma_k(\tilde{x}_k^{(i)})}{p_k(\tilde{x}_k^{(i)}|Z_k)} \quad (6)$$

其中, $i = L_{k-1} + 1, \dots, L_{k-1} + J_k$, J_k 表示赋给出生目标的粒子数目.

步骤 2. 更新

对 k 时刻量测集合的每个量测 $z \in Z_k$, 计算

$$C_k(z) = \sum_{j=1}^{L_{k-1}+J_k} \varphi_{k,z}(\tilde{x}_k^{(j)}) \tilde{w}_{k|k-1}^{(j)} \quad (7)$$

然后, 更新步骤 1 中粒子的权重

$$\tilde{w}_k^{(i)} = \left(1 - P_D(\tilde{x}_k^{(i)})\right) \tilde{w}_{k|k-1}^{(i)} + \sum_{z \in Z_k} \frac{\varphi_{k,z}(\tilde{x}_k^{(i)})}{\kappa_k(z) + C_k(z)} \tilde{w}_{k|k-1}^{(i)} \quad (8)$$

其中, $i = 1, \dots, L_{k-1} + J_k$.

步骤 3. 重采样

首先, 计算经过更新步后所有粒子的权重和 $\hat{N}_{k|k} = \sum_{j=1}^{L_{k-1}+J_k} \tilde{w}_k^{(j)}$; 然后, 对正规化后的粒子集合 $\left\{\left(\tilde{w}_k^{(i)}/\hat{N}_{k|k}\right), \tilde{x}_k^{(i)}\right\}$ 进行重采样得到归一化的重采样粒子集合 $\left\{\left(w_k^{(i)}/\hat{N}_{k|k}\right), x_k^{(i)}\right\}_{i=1}^{L_k}$; 最后, 乘以正规化因子 $\hat{N}_{k|k}$ 得到 k 时刻的 PHD 近似 $\left\{w_k^{(i)}, x_k^{(i)}\right\}_{i=1}^{L_k}$. 因为 PHD 在状态空间上的积分值是期望目标数, 所以 $\hat{N}_{k|k}$ 就是 k 时刻目标数估计值.

目标出生强度 $\gamma_k(x_k)$ 是式 (3) 和式 (6) 中 k 时刻预测强度的重要组成部分, 它在多目标跟踪算法中是未知的. 目标出生强度对多目标跟踪算法性能的重要影响主要体现在对新生目标的跟踪上. 本文研究目标出生强度 $\gamma(x)$ 在线估计算法, 通过对未知目标出生强度进行在线估计以提高跟踪上出生目标的几率, 进而改进 PHD 滤波器在多目标跟踪应用中的性能. 下节将详细描述基于 Dirichlet 分布的目标出生强度极大后验在线估计算法的推导过程.

2 目标出生强度在线估计算法

正如问题描述部分所论述的, 我们的目的是在线估计目标出生强度以改进多目标跟踪算法的性能. 在算法中, 使用泊松随机有限集对目标出生过程进行建模, 因此, 目标出生强度为

$$\gamma(x) = \eta p(x) \quad (9)$$

其中, η 是出生目标个数, $p(x)$ 是出生目标分布, $p(x)$ 描述的是出生目标在整个监视区域内的概率分布. 对于 k 时刻 η_k 的估计, 算法采用从时刻 1 到时刻 $k-1$ 的出生目标个数的平均值作为 η_k 的估计值 $\hat{\eta}_k$

$$\hat{\eta}_k = \frac{\hat{\eta}_1 + \dots + \hat{\eta}_{k-1}}{k-1} \quad (10)$$

出于表述简单的目的, 在以下公式中省略了时刻标注 k . 在多目标跟踪场景中, 出生目标会在监视区域内的几个可能区域内随机产生, 因此, 我们采用有限混合模型来描述出生目标分布^[31]

$$p(x|\theta) = \sum_{m=1}^M \pi_m p(x|\theta_m) \quad (11)$$

其中, M 是混合分量个数, $\theta_m = \{\mu_m, \phi_m\}$ 表示由均值 μ_m 和方差 ϕ_m 构成的关于分量 m 的参数集合, $\theta = \{\theta_1, \dots, \theta_M, \pi_1, \dots, \pi_M\}$ 表示混合模型的

参数集合, 分量的混合权重满足

$$\sum_{m=1}^M \pi_m = 1 \quad (12)$$

具有 n 个目标的出生目标集合 $\mathcal{X}^{(n)} = \{x^{(1)}, \dots, x^{(n)}\}$ 在式 (11) 有限混合模型 $p(x|\theta)$ 下的对数似然为

$$\log p(\mathcal{X}^{(n)}|\theta) = \sum_{i=1}^n \log \sum_{m=1}^M \pi_m p(x^{(i)}|\theta_m) \quad (13)$$

估计目标出生强度时, 只能逐个时刻获得出生目标数据 (即多目标状态中的出生目标状态集合), 而不能一次性得到所有时刻的出生目标数据. 因此, 目标出生强度估计算法应当是在线估计算法而非批处理估计算法, 它应当随着每个时刻出生目标数据的获得而在线地估计目标出生强度. 目标出生强度 $\gamma(x)$ 的在线估计包括出生目标数目 η 、混合权重 π_m 、分量均值 μ_m 和分量方差 ϕ_m 的在线估计. 下面首先推导了基于负指数 Dirichlet 分布的混合权重 π_m 的在线估计公式; 其次, 推导了基于缺失数据的分量均值 μ_m 与分量方差 ϕ_m 的在线估计公式; 最后, 给出了算法初始化方法和每个时刻出生目标数据的获取方法.

2.1 混合权重在线估计

Dirichlet 分布 $Dir(\alpha)$ 是一类由正实数矢量 $\alpha = (\alpha_1, \dots, \alpha_M)$ 参数化的连续多变量概率分布, 其中, α_m 表示变量 m 的证据^[32]. 因为 Dirichlet 分布的多变量与有限混合模型的混合权重都满足式 (12) 的约束, 所以算法采用 Dirichlet 分布描述混合权重矢量的分布, 则混合权重矢量的概率密度函数为

$$p(\pi_1, \dots, \pi_M; \alpha) = \frac{1}{B(\alpha)} \prod_{m=1}^M \pi_m^{\alpha_m - 1} \quad (14)$$

其中, 正规化因子 $B(\alpha)$ 是多项式 β 分布

$$B(\alpha) = \frac{\prod_{m=1}^M \Gamma(\alpha_m)}{\Gamma\left(\sum_{m=1}^M \alpha_m\right)} \quad (15)$$

分量 m 的混合权重 π_m 的期望为

$$E(\pi_m) = \frac{\alpha_m}{\alpha_0} \quad (16)$$

其中, $\alpha_0 = \sum_{m=1}^M \alpha_m$ 表示所有分量的证据和. 两个不同混合分量 i 和 j 的混合权重协方差为

$$\text{cov}(\pi_i, \pi_j) = \frac{-\alpha_i \alpha_j}{\alpha_0^2 (\alpha_0 + 1)} \quad (17)$$

由此可见, 不同的两两分量的关系是负的.

式 (11) 混合模型参数集合 θ 的先验分布取为负指数 Dirichlet 分布

$$p(\theta) \propto \exp\left(c_m \sum_{m=1}^M \log \pi_m\right) \quad (18)$$

其中, $c_m = -N/2$ 是分量 m 的证据, N 是描述每个分量的元素数目^[33]. 此处混合模型参数集合 θ 的先验分布 $p(\theta)$ 仅仅依赖于混合权重矢量 π ; 先验分布中负指数参数 $c_m = -N/2$ 的选择使得分量 m 只有在充分的证据下才能确保存在. 算法利用了负指数 Dirichlet 分布的这种不稳定性, 在在线估计的过程中驱使与目标出生强度不相关或相关很小的分量消亡.

在线估计算法采用极大后验 (Maximum a posterior, MAP) 准则估计混合模型的参数 θ . 对于目标出生数据集合 $\mathcal{X}^{(n)} = \{x^{(1)}, \dots, x^{(n)}\}$, 混合模型参数集合 θ 的 MAP 估计为

$$\hat{\theta} = \arg \max_{\theta} \{\log p(\mathcal{X}^{(n)}|\theta) + \log p(\theta)\} \quad (19)$$

对于 MAP 解, 令混合参数后验密度 $p(\theta|\mathcal{X}^{(n)})$ 的对数关于混合权重 π_m 的导数为零

$$\frac{\partial}{\partial \pi_m} (\log p(\mathcal{X}^{(n)}|\theta) + \log p(\theta)) = 0 \quad (20)$$

利用拉格朗日乘子法把式 (12) 对混合分量权重约束代入到式 (20) 中

$$\frac{\partial}{\partial \pi_m} \left(\log p(\theta|\mathcal{X}^{(n)}) + \lambda \left(\sum_{m=1}^M \pi_m - 1 \right) \right) = 0 \quad (21)$$

其中, λ 是拉格朗日乘子. 然后, 消去乘子 λ , 可得混合权重 π_m 的 MAP 估计为

$$\pi_m^{(n)} = \frac{\frac{1}{n} \sum_{i=1}^n \omega_m^{(n)}(x^{(i)}) - \frac{N}{2n}}{1 - \frac{MN}{2n}} \quad (22)$$

其中, $\omega_m^{(n)}(x)$ 表示出生目标 x 隶属于分量 m 的程度

$$\omega_m^{(n)}(x) = \frac{\pi_m^{(n)} p(x|\theta_m^{(n)})}{\sum_{m=1}^M \pi_m^{(n)} p(x|\theta_m^{(n)})} \quad (23)$$

类似的, 对于具有 $n+1$ 个目标的出生目标集合 $\mathcal{X}^{(n+1)} = \{\mathcal{X}^{(n)}, x^{(n+1)}\}$, 混合权重 π_m 的 MAP 估

计值为

$$\pi_m^{(n+1)} = \frac{\frac{1}{n+1} \sum_{i=1}^{n+1} \omega_m^{(n+1)}(x^{(i)}) - \frac{N}{2(n+1)}}{1 - \frac{MN}{2(n+1)}} \quad (24)$$

其中

$$\omega_m^{(n+1)}(x) = \frac{\pi_m^{(n+1)} p(x|\theta_m^{(n+1)})}{\sum_{m=1}^M \pi_m^{(n+1)} p(x|\theta_m^{(n+1)})} \quad (25)$$

对比式 (23) 的 $\omega_m^{(n)}(x)$ 与式 (25) 的 $\omega_m^{(n+1)}(x)$, 二者是在仅相差一个出生目标数据 $x^{(n+1)}$ 的两个数据集下的隶属度. 假设出生目标数据更新混合模型参数是以渐进方式进行的, 即当增加一个新的出生目标数据时, 混合参数的估计值不会有太大的变化, 则 $\mathcal{X}^{(n+1)} = \{\mathcal{X}^{(n)}, x^{(n+1)}\}$ 下的隶属度 $\omega_m^{(n+1)}(x)$ 可以由 $\mathcal{X}^{(n)} = \{x^{(1)}, \dots, x^{(n)}\}$ 下的隶属度 $\omega_m^{(n)}(x)$ 来近似

$$\omega_m^{(n+1)}(x) \approx \omega_m^{(n)}(x) \quad (26)$$

在估计中该渐近假设是合理的, 因为当使用大量观测数据估计某一统计量时, 一个样本点对统计量的估计所做的贡献会很小. 除此之外, 为避免在线估计算法在初始阶段的波动, 我们通过 $N/2(n+1) \approx N/(2n) = N/(2c)$ 来固定 Dirichlet 分布作为先验在估计算法中的作用. 根据式 (26) 对于隶属度的近似, 式 (24) 可以重写为

$$\pi_m^{(n+1)} = \frac{\frac{1}{n+1} \sum_{i=1}^{n+1} \omega_m^{(n)}(x^{(i)}) - \frac{N}{2c}}{1 - \frac{MN}{2c}} \quad (27)$$

将式 (22) 和式 (23) 代入到式 (27), 可得混合权重 π_m 的在线估计公式

$$\pi_m^{(n+1)} = \frac{n}{n+1} \pi_m^{(n)} + \frac{\omega_m^{(n)}(x^{(n+1)})}{(n+1) \left(1 - \frac{MN}{2c}\right)} - \frac{\frac{N}{2c}}{(n+1) \left(1 - \frac{MN}{2c}\right)} \quad (28)$$

负指数 Dirichlet 分布作为先验的作用主要体现在式 (28) 最后一项. 对于从出生目标数据集合中获得很少证据的分量 (很少出生目标数据支撑的分

量), 在线估计的过程中, 其混合权重不断减小; 而且有式 (12) 对混合权重的约束, 获得较多数据支撑的分量的混合权重不断增大. 算法通过该方式实现与出生目标数据不相关分量的删减, 并实现证据在分量间的调配. 在混合权重的在线估计过程中, 如果某一分量的混合权重的估计值为负, 则需要把该分量从混合模型中删除; 此删减操作通过把相应混合权重置零来实现. 删减分量后, 通过正规化把被删减分量的证据分配给其他存活分量.

2.2 分量均值和方差在线估计

对于经过式 (28) 更新后的非零权重分量的均值和方差, 采用随机近似过程来推导它们的在线估计公式. 随机近似过程的基本式为

$$\theta^{(n+1)} = \theta^{(n)} + \{(n+1)I(\theta^{(n)})\}^{-1} S(x^{(n+1)}, \theta^{(n)}) \quad (29)$$

其中, $I(\theta)$ 是混合参数集合 θ 的 Fisher 信息阵, $S(x, \theta)$ 是 x 的 Score 函数. 因为无法得到出生目标数据与混合分量间的对应关系, 所以式 (29) 中的 Fisher 信息阵是无法求取的, 随机近似过程的基本式在此是不适用的. 我们把出生目标数据与混合分量的关系作为出生目标分布的缺失数据, 利用完全 Fisher 信息阵 $I_c(\theta)$ 替代式 (29) 中的 Fisher 信息阵 $I(\theta)$

$$\theta^{(n+1)} = \theta^{(n)} + \{(n+1)I_c(\theta^{(n)})\}^{-1} S(x^{(n+1)}, \theta^{(n)}) \quad (30)$$

对于出生目标集合 $\mathcal{X}^{(n)} = \{x^{(1)}, \dots, x^{(n)}\}$, 其缺失数据为 $Z = \{z^{(1)}, \dots, z^{(n)}\}$, 表明 n 个出生目标在混合分量中的来源, 每个出生目标 $x^{(i)}$ 的缺失数据为二进制矢量 $z^{(i)} = [z_1^{(i)}, \dots, z_M^{(i)}]$. 出生目标 $\mathcal{X}^{(n)}$ 的完全对数似然为

$$\log p(\mathcal{X}^{(n)}, Z|\theta) = \sum_{i=1}^n \sum_{m=1}^M z_m^{(i)} \log(\pi_m p(x^{(i)}|\theta_m)) \quad (31)$$

混合模型中所有分量均假设服从高斯分布. 对于分量 m 的均值 μ_m , $\mathcal{X}^{(n)}$ 的 Score 函数为

$$S(\mathcal{X}^{(n)}, \mu_m) = \frac{\partial}{\partial \mu_m} \log p(\mathcal{X}^{(n)}|\theta) \quad (32)$$

那么, 式 (30) 中出生目标数据 $x^{(n+1)}$ 关于分量均值 μ_m 的 Score 函数为

$$S(x^{(n+1)}, \mu_m) = \omega_m^{(n)}(x^{(n+1)}) \frac{x^{(n+1)} - \mu_m}{\phi_m} \quad (33)$$

混合模型参数集合 θ 的完全 Fisher 信息阵为

$$I_c(\theta^{(n)}) = E_{\theta} \left(-\frac{\partial^2}{\partial \theta^2} (\log p(\mathcal{X}^{(n)}, Z|\theta^{(n)})) \right) \quad (34)$$

对于一个完全出生目标数据 $(x^{(n+1)}, z^{(n+1)})$, 分量均值 μ_m 的完全 Fisher 信息阵为

$$I_c(\mu_m) = E_{\mu_m} \left\{ -\frac{\partial^2}{\partial \mu_m^2} \log(x^{(n+1)}, z_m^{(n+1)}|\theta^{(n)}) \right\} \quad (35)$$

因为缺失数据的元素 $z_m^{(i)}$ 是二进制的, 所以完全对数似然关于缺失部分元素是线性的. 因此, 分量均值期望的计算可以简化为缺失元素期望的计算. 据此, 式 (35) 为

$$I_c(\mu_m) = \frac{\pi_m}{\phi_m} \quad (36)$$

对于分量均值 μ_m , 式 (33) 与式 (36) 代入到式 (30) 中得分量均值 μ_m 的在线估计公式

$$\mu_m^{(n+1)} = \{(n+1)\pi_m^{(n)}\}^{-1} \omega_m^{(n)}(x^{(n+1)}) d_m^{(n+1)} + \mu_m^{(n)} \quad (37)$$

其中, $d_m^{(n+1)} = x^{(n+1)} - \mu_m^{(n)}$.

类似于分量均值 μ_m 的推导过程, 分量方差 ϕ_m 的 Score 函数为

$$S(x^{(n+1)}, \phi_m) = \omega_m^{(n)}(x^{(n+1)}) \frac{(d_m^{(n+1)})^2 - \phi_m^{(n)}}{2(\phi_m^{(n)})^2} \quad (38)$$

分量方差 ϕ_m 的完全 Fisher 信息阵为

$$I_c(\phi_m) = \frac{\pi_m}{2\phi_m^2} \quad (39)$$

式 (38) 与式 (39) 代入到式 (30) 得分量方差 ϕ_m 的在线估计公式

$$\phi_m^{(n+1)} = \{(n+1)\pi_m^{(n)}\}^{-1} \omega_m^{(n)}(x^{(n+1)}) V_m^{(n+1)} + \phi_m^{(n)} \quad (40)$$

其中, $V_m^{(n+1)} = (d_m^{(n+1)})^2 - \phi_m^{(n)}$.

2.3 算法初始化

在算法的初始化步, 我们无法获得有关目标出生的任何信息, 所以只能有把整个监视区域作为可能的目标出生区域. 一般情况下, 初始化时需要大量的混合分量来等分监视区域以覆盖整个监视区域. 为了使算法的估计过程更加平稳且减少初始化步的

分量数目, 在出生目标强度的混合模型描述中增加一个均匀分量

$$p^{(0)}(x) = \pi_0 U(x) + \sum_{m=1}^{M_{\max}} \pi_m p(x|\theta_m) \quad (41)$$

其中, $U(x)$ 是在整个监视区域内的均匀分布, 混合权重和为 1

$$\pi_0 + \sum_{m=1}^{M_{\max}} \pi_m = 1 \quad (42)$$

增加的均匀分布 $U(x)$ 有如下几个作用: 1) 在算法初始步及后续几个时刻, 均匀分量起描述目标出生强度的作用, 该作用通过设置均匀分布 $U(x)$ 的较大初始混合权重 π_0 来实现; 2) 均匀分布 $U(x)$ 的存在可以减少初始化步混合分量的数目 M_{\max} , 只需相对较少的初始分量与均匀分量组合就可实现对监视区域的稀疏覆盖; 3) 为了避免混合分量拟合稀疏目标出生数据时过大方差的出现, 均匀分布 $U(x)$ 一直保持存在用来拟合这些数据.

2.4 出生目标数据的获取

在式 (6) 计算 k 时刻预测强度 $D_{k|k-1}(x)$ 时, 算法利用 $k-1$ 时刻的目标出生强度估计值 $\hat{\gamma}_{k-1}(x)$ 来近似 k 时刻的目标出生强度 $\gamma_k(x)$ 以得到 k 时刻多目标状态估计 \hat{X}_k , 即 PHD 滤波器实现多目标跟踪时用到的目标出生强度 $\gamma(x)$ 要延迟一个时刻. 在已知 $k-1$ 时刻目标出生强度估计值 $\hat{\gamma}_{k-1}(x)$ 和 k 时刻量测集合 Z_k 的条件下, 算法经过 PHD 滤波器的预测步和更新步得到 k 时刻多目标状态估计值 \hat{X}_k ; 对比 $k-1$ 时刻多目标状态估计 \hat{X}_{k-1} 在 k 时刻的一步预测 $\hat{X}_{k|k-1}$ 与 k 时刻多目标状态估计 \hat{X}_k , 依据位置状态的距离判断得到 k 时刻的出生目标数据集合 $\mathcal{X}^{(n)}$.

以目标状态估计值而非量测为出发点, 先估计 k 时刻多目标状态 \hat{X}_k 后判断出生目标数据 $\mathcal{X}^{(n)}$ 的方法, 充分发挥了 PHD 滤波器消弱杂波量测影响的作用, 从而减少了杂波量测对出生目标数据判断的负面影响.

3 出生强度在线估计的多目标跟踪算法

出于算法完整性的考虑, 对基于目标出生强度在线估计的多目标跟踪算法主要步骤进行总结.

算法的输入: k 时刻的量测 Z_k , $k-1$ 时刻的出生目标强度估计 $\hat{\gamma}_{k-1}(x)$, $k-1$ 时刻的多目标状态估计 \hat{X}_{k-1} .

算法的基本流程:

1) $k-1$ 时刻的粒子经过式 (5) 进行预测, $k-1$ 时刻的 $\hat{\gamma}_{k-1}(x)$ 作为 k 时刻的目标出生强度 $\gamma_k(x)$ 代入式 (6) 对出生目标进行预测;

2) 利用式 (7) 和式 (8) 更新及重采样, 得 k 时刻 PHD 近似 $\left\{w_k^{(i)}, x_k^{(i)}\right\}_{i=1}^{L_k}$ 及目标数估计 $\hat{N}_{k|k}$;

3) 利用 k - d 树分割 $\left\{w_k^{(i)}, x_k^{(i)}\right\}_{i=1}^{L_k}$ 得候选状态集合, 采用增量式极大似然方法从一个目标状态递增估计到 $\hat{N}_{k|k}$ 个目标状态 \hat{X}_k . 其中, 估计每步目标状态和从候选集合中选择增加的目标状态都按照极大似然准则;

4) 以目标状态的位置分量距离为判据, 对比 \hat{X}_{k-1} 的一步预测 $\hat{X}_{k|k-1}$ 与 \hat{X}_k , 得到 k 时刻的出生目标数据集 $\mathcal{X}^{(n)} = \{x^{(1)}, \dots, x^{(n)}\}$;

5) 根据式 (10) 计算 k 时刻的出生目标个数的估计值 $\hat{\eta}_k$;

6) 令 $i = 1$;

7) 对于出生目标数据 $x^{(i)}$, 利用式 (28) 更新混合权重 π_m , $m = 1, \dots, M$;

8) 判断更新后的混合权重 π_m 是否小于零, 如果小于零, 混合权重置为零并且从混合模型中删减该混合分量; 令 M_d 表示混合权重为零的分量个数, 权重更新后的混合分量个数为 $M = M - M_d$;

9) 正规化步骤 8) 中的 M 个非零混合权重以重新分配分量的证据;

10) 对于步骤 8) 中具有非零混合权重的分量, 按照式 (37) 和式 (40), 利用出生目标数据 $x^{(i)}$ 分别更新分量均值 μ_m 与分量方差 ϕ_m ;

11) 判断 i 是否等于出生目标个数 n , 如果不相等, $i = i + 1$, 转至步骤 7);

12) 得到 k 时刻的目标出生强度估计 $\hat{\gamma}_k(x)$;

13) 令 $k = k + 1$, 为下个时刻做准备.

算法的输出: k 时刻的目标出生强度估计 $\hat{\gamma}_k(x)$ 与多目标状态估计 \hat{X}_k .

4 仿真研究

以二维目标跟踪场景为例, 通过仿真实验证明目标出生强度在线估计对 PHD 多目标跟踪算法的改进作用. 监视区域为 $[-100, 100] \text{ m} \times [-100, 100] \text{ m}$. 在跟踪过程中, 区域内目标数目是未知的、变化的. 目标状态由目标位置和目標速度构成, 观测到的是目标位置. 目标运动模型为

$$x_k = F \cdot x_{k-1} + G \cdot v_k$$

其中

$$F = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$G = \begin{bmatrix} \frac{T^2}{2} & 0 \\ 0 & \frac{T^2}{2} \\ T & 0 \\ 0 & T \end{bmatrix}$$

$x_k = [x_{1,k}, x_{2,k}, x_{3,k}, x_{4,k}]^T$ 是目标状态, $[x_{1,k}, x_{2,k}]^T$ 和 $[x_{3,k}, x_{4,k}]^T$ 分别为目标位置和目標速度. 采样周期 $T = 1 \text{ s}$, 场景设计 40 个周期. $v_k = [v_{1,k}, v_{2,k}]^T$ 是过程噪声, $\{v_{1,k}\}$ 和 $\{v_{2,k}\}$ 是相互独立的零均值高斯白噪声, 标准差分别为 $\sigma_{v_1} = 1 \text{ m/s}^2$ 和 $\sigma_{v_2} = 1 \text{ m/s}^2$.

在 40 个周期内, 目标出生的时间区间设置为 $[3, 33]$; 在式 (9) 中目标出生强度的真实参数 $\eta = 1$, 即, 平均每个时刻有一个目标出生; 每个出生目标持续 5 s 后消亡. 新生目标在以 $[-10, 50]$, $[-50, -50]$ 与 $[50, -10]$ 为中心的 3 个区域内随机产生. 目标量测方程为

$$y_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} x_k + \begin{bmatrix} w_{1,k} \\ w_{2,k} \end{bmatrix}$$

其中, $\{w_{1,k}\}$ 和 $\{w_{2,k}\}$ 是相互独立的零均值高斯白噪声并具有相同标准差 $\sigma_{w_1} = \sigma_{w_2} = 2.5 \text{ m}$, 而且与过程噪声相互独立. 目标的检测概率 $P_D(x)$ 设定为 1.

杂波过程假设为在监视区域上均匀分布的泊松随机有限集, 则杂波强度为 $\kappa_k(z_k) = \xi \cdot c_k(z_k)$, 其中, ξ 是平均每个周期的杂波个数, $c(z) = U(z)$ 是均匀分布. 在实验中, 参数 ξ 取为 5.

在 PHD 滤波器的 SMC 实现中, 每个期望目标对应 500 个粒子, 每个新生目标对应 100 个粒子; 在 40 个周期上, 粒子数目随着估计目标数的变化而变化. 在 PHD 滤波器的预测步, 目标存活概率设为 $e_{k|k-1} = 0.95$, 存活目标在式 (5) 中的重要性采样密度 $q_k(\cdot|x_{k-1}^{(i)}, Z_k)$ 取为目标状态转移密度 $f_{k|k-1}(x_k|x_{k-1})$; 出生目标在式 (6) 中的重要性采样密度 $p_k(\cdot|Z_k)$ 取为式 (9) 中 $k-1$ 时刻的出生目标分布 $p_{k-1}(x)$, 采样时先随机选择分量, 然后在所选择的分量上进行抽样.

在式 (41) 目标出生强度在线估计算法的初始化阶段, 均匀分量 $U(x)$ 的混合权重 π_0 取为 0.8, 混合模型的最大分量数目 M_{\max} 取为 30. 高斯混合分量 $p(x|\theta_m)$ 的方差 ϕ_m 取为自由矩阵, 则描述每个混合分量的参数个数 $N = 14$. 在式 (28) 中混合权重 π_m 在线估计时, 常数 c 取为 20.

图 1 和图 2 显示了改进算法单次蒙特卡罗仿真

的 X 坐标与 Y 坐标多目标跟踪效果. 从图中可以看到, 改进算法能够正确估计多目标状态, 而且可以跟踪上新出生的目标.

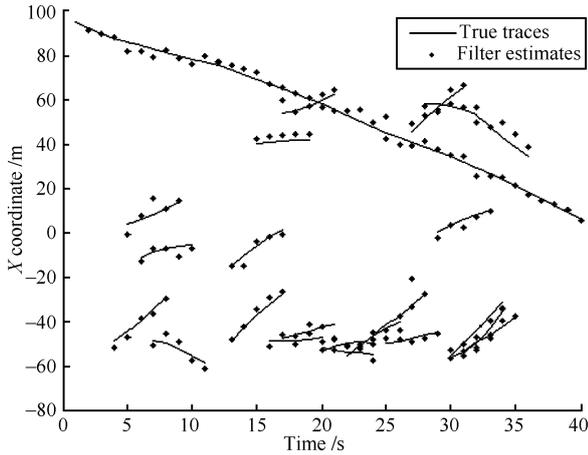


图 1 X 坐标的真实轨迹与估计值

Fig. 1 True traces and estimates of X coordinate

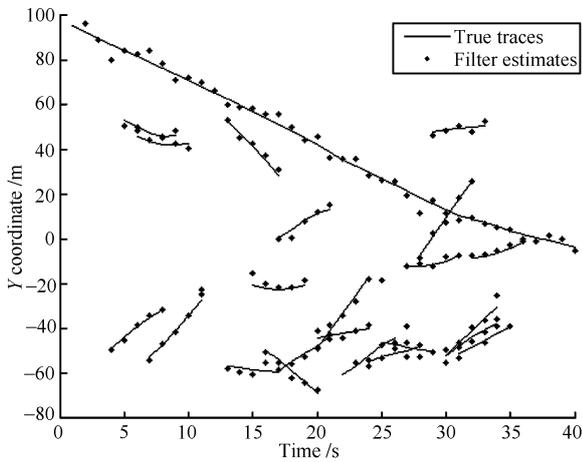


图 2 Y 坐标的真实轨迹与估计值

Fig. 2 True traces and estimates of Y coordinate

因为目标数估计也是 PHD 滤波器估计的一部分, 所以 PHD 滤波器输出的多目标状态估计集合的势与真实集合的势有可能不相等, 因此, 一般衡量多目标跟踪性能的均方根误差不再适用. 算法采用 Wasserstein 距离评价多目标跟踪的性能,

$$d_p(\hat{X}, X) = \min_C \sqrt[p]{\sum_{i=1}^{|\hat{X}|} \sum_{j=1}^{|X|} C^{ij} \|\hat{x}^i - x^j\|^p}$$

其中, \hat{X} 和 X 分别是多目标状态的估计值和真实值^[34]. 它在所有可能中间矩阵 C 上取最小值 (元素 C^{ij} 是正实数, 且 $\sum_{j=1}^{|\hat{X}|} C^{ij} = 1/|\hat{X}|$, $\sum_{i=1}^{|\hat{X}|} C^{ij} = 1/|X|$, 元素 C^{ij} 的取值与多目标真实状态集合的势 $|X|$ 和估计状态集合的势 $|\hat{X}|$ 有关, 对于不同的 $|X|$ 和 $|\hat{X}|$ 组合, C^{ij} 取不同的值); 当 \hat{X} 和 X 为空时,

此距离没有定义; p 取为 2. 图 3 展示了经过 200 次蒙特卡罗仿真后, 改进算法与基本 PHD 多目标跟踪算法的 Wasserstein 距离. 改进算法的 Wasserstein 距离明显小于基本 PHD 算法, 说明改进算法优于基本 PHD 算法.

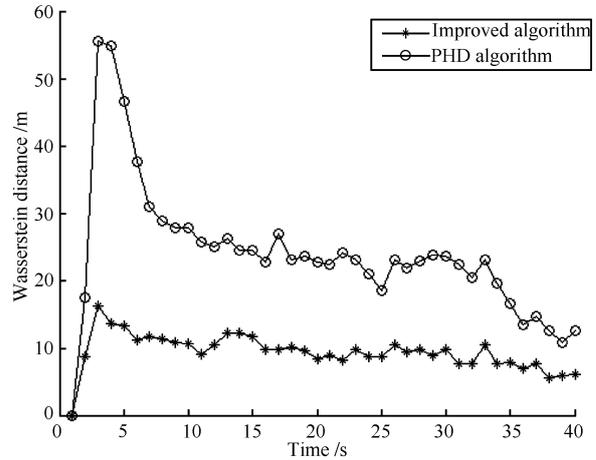


图 3 200 次蒙特卡罗仿真的 Wasserstein 距离

Fig. 3 The Wasserstein distances of 200 Monte Carlo simulations

目标数目作为多目标跟踪的重要组成部分可以作为对比多目标跟踪算法性能的指标. 图 4 展示了两种算法经过 200 次蒙特卡罗仿真的目标数目估计效果. 显然, 改进算法对目标数目的估计值比基本算法更接近真实目标数目.

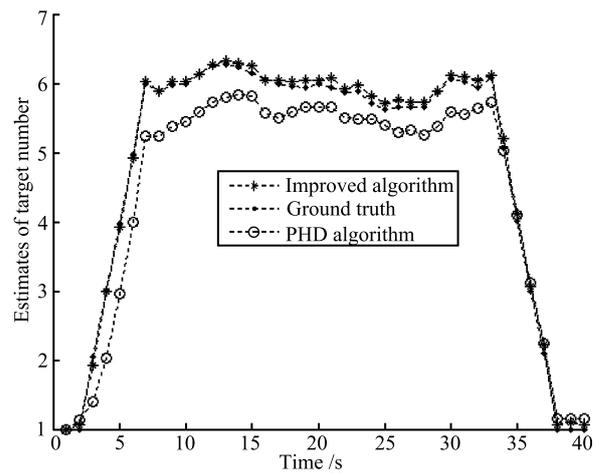


图 4 200 次蒙特卡罗仿真的目标数估计

Fig. 4 The estimates of target number of 200 Monte Carlo simulations

出生目标跟踪的及时性也是评价多目标跟踪算法性能的重要指标. 下面说明在线估计算法在该评价指标上的改进效果. 因为在仿真中目标出生的可能时间区间设为 $[3, 33]$, 所以在 200 次蒙特卡罗仿真中共有 6200 个可能的目标出生时刻, 实际的有

目标出生的时刻数目为 3894. 改进算法未能跟踪上出生目标的次数为 901, 出生目标跟踪的丢失率为 23.1%; PHD 算法未能跟踪上出生目标的次数为 2412, 出生目标跟踪的丢失率为 61.9%; 可见改进算法能够更好地跟踪上新出生的目标, 从而提高了多目标跟踪算法的性能.

对基于目标出生强度在线估计的 PHD 多目标跟踪算法与基本的 PHD 多目标跟踪算法, 在算法复杂性及时间开销上进行比较. 改进算法与基本算法相比, 在算法复杂性上只是多了一个目标出生强度在线估计算法的复杂度, 所增加的目标出生强度在线估计算法的复杂度为 $(M + 2(M - M_d))|\mathcal{X}| = O(M|\mathcal{X}|)$. 改进算法的平均每步时间开销为 2.08 s, 基本算法的平均每步时间开销为 1.85 s, 目标出生强度在线估计算法增加了基本 PHD 多目标跟踪算法时间开销的 12.43 % (Matlab 7.1 环境, Intel, Pentium, D CPU 2.80 GHz 2.79 GHz, 504 MB 内存).

5 结论

以未知的目标出生强度为研究对象, 提出了基于 Dirichlet 分布的目标出生强度在线估计算法. 该算法在多分量初始化的有限混合模型基础上, 利用负指数 Dirichlet 分布的不稳定性驱使与目标出生强度不相关的分量消亡, 从而实现目标出生强度的在线估计. 算法能够使 PHD 预测步中的粒子更多地集中在目标出生区域, 增大了出生目标被及时跟踪上的几率, 从而减少了错误目标数估计出现的几率. 仿真结果表明, 提出的目标出生强度在线估计算法改进了 PHD 滤波器在多目标跟踪中的性能.

References

- Pulford G E. Taxonomy of multiple target tracking methods. *IEE Proceedings of Radar, Sonar and Navigation*, 2005, **152**(5): 291–304
- Blackman S, Popoli R. *Design and Analysis of Modern Tracking Systems*. Norwood: Artech House, 1999
- Daley D, Vere-jones D. *An Introduction to the Theory of Point Processes*. Second Edition. New York: Springer-Verlag, 2002
- Mahler R P S. Multitarget Bayes filtering via first-order multitarget moments. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, **39**(4): 1152–1178
- Mahler R P S. *Statistical Multisource-Multitarget Information Fusion*. Norwood: Artech House, 2007
- Erdinc O, Willett P, Bar-shalom Y. The bin-occupancy filter and its connection to the PHD filters. *IEEE Transactions on Signal Processing*, 2009, **57**(11): 4232–4246
- 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
- Whiteley N, Singh S, Godsill S. Auxiliary particle implementation of probability hypothesis density filter. *IEEE Transactions on Aerospace and Electronic Systems*, 2010, **46**(3): 1437–1454
- Liu W F, Han C Z, Lian F, Zhu H Y. Multitarget state extraction for the PHD filter using MCMC approach. *IEEE Transactions on Aerospace and Electronic Systems*, 2010, **46**(2): 864–883
- Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter. *IEEE Transactions on Signal Processing*, 2006, **54**(11): 4091–4104
- Pasha S A, Vo B N, Tuan H D, Ma W K. A Gaussian mixture PHD filter for jump Markov system models. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, **45**(3): 919–936
- Clark D E, Bell J. Convergence results for the particle PHD filter. *IEEE Transactions on Signal Processing*, 2006, **54**(7): 2652–2661
- Clark D E, Vo B N. Convergence analysis of the Gaussian mixture PHD filter. *IEEE Transactions on Signal Processing*, 2007, **55**(4): 1204–1212
- Mahler R P S. PHD filters of higher order in target number. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, **43**(4): 1523–1543
- 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
- Franken D, Schmidt M, Ulmke M. “Spooky action at a distance” in the cardinalized probability hypothesis density filter. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, **45**(4): 1657–1664
- Vo B T, Vo B N, Cantoni A. Analytic implementations of the cardinalized probability hypothesis density filter. *IEEE Transactions on Signal Processing*, 2007, **55**(7): 3553–3567
- Zhang H J, Jing Z L, Hu S Q. Gaussian mixture CPHD filter with gating technique. *Signal Processing*, 2009, **89**(8): 1521–1530
- Punithakumar K, Kirubarajan T, Sinha A. Multiple-model probability hypothesis density filter for tracking maneuvering targets. *IEEE Transactions on Aerospace and Electronic Systems*, 2008, **44**(1): 87–98
- Lian Feng, Han Chong-Zhao, Liu Wei-Feng, Yuan Xiang-Hui. Multiple-model probability hypothesis density smoother. *Acta Automatica Sinica*, 2010, **36**(7): 939–950 (连峰, 韩崇昭, 刘伟峰, 元向辉. 多模型概率假设密度平滑器. 自动化学报, 2010, **36**(7): 939–950)
- Clark D E, Bell J. Multi-target state estimation and track continuity for the particle PHD filter. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, **43**(4): 1441–1453

- 22 Panta K, Clark D, Vo B N. Data association and track management for the Gaussian mixture probability hypothesis density filter. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, **45**(3): 1003–1016
- 23 Vo B T, Vo B N, Cantoni A. Bayesian filtering with random finite set observations. *IEEE Transactions on Signal Processing*, 2008, **56**(4): 1313–1326
- 24 Rezaeian M, Vo B N. Error bounds for joint detection and estimation of a single object with random finite set observation. *IEEE Transactions on Signal Processing*, 2010, **58**(3): 1493–1506
- 25 Wang Y D, Wu J K, Kassim A A, Huang W M. Data-driven probability hypothesis density filter for visual tracking. *IEEE Transactions on Circuits and Systems for Video Technology*, 2008, **18**(8): 1085–1095
- 26 Maggio E, Taj M, Cavallaro A. Efficient multitarget visual tracking using random finite sets. *IEEE Transactions on Circuits and Systems for Video Technology*, 2008, **18**(8): 1016–1027
- 27 Maggio E, Cavallaro A. Learning scene context for multiple object tracking. *IEEE Transactions on Image Processing*, 2009, **18**(8): 1873–1884
- 28 Clark D, Ruiz I T, Petilot Y, Bell J. Particle PHD filter multiple target tracking in sonar images. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, **43**(1): 409–416
- 29 Clark D, Ristic B, Vo B N, Vo B T. Bayesian multi-object filtering with amplitude feature likelihood for unknown object SNR. *IEEE Transactions on Signal Processing*, 2010, **58**(1): 26–37
- 30 Zhang H J, Jing Z L, Hu S Q. Localization of multiple emitters based on the sequential PHD filter. *Signal Processing*, 2010, **90**(1): 34–43
- 31 McLachlan G, Peel D. *Finite Mixture Models*. New York: John Wiley and Sons, 2000
- 32 Davy M, Tournieret J Y. Generative supervised classification using Dirichlet process priors. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, **32**(10): 1781–1794
- 33 Figueiredo M A F, Jain A K. Unsupervised learning of finite mixture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, **24**(3): 381–396
- 34 Hoffman J R, Mahler R P S. Multitarget miss distance via optimal assignment. *IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans*, 2004, **34**(3): 327–336



闫小喜 西安交通大学电子与信息工程学院综合自动化研究所博士研究生。主要研究方向为多源信息融合, 多目标跟踪和随机有限集。本文通信作者。

E-mail: yanxiaoxi1981@gmail.com

(YAN Xiao-Xi Ph.D. candidate at the Institute of Integrated Automation, School of Electronic and Information

Engineering, Xi'an Jiaotong University. His research interest covers multisource information fusion, multiple target tracking, and random finite set. Corresponding author of this paper.)



韩崇昭 西安交通大学电子与信息工程学院自动化系教授。主要研究方向为多源信息融合、随机控制与自适应控制、非线性频谱分析。

E-mail: czhan@mail.xjtu.edu.cn

(HAN Chong-Zhao Professor in the Department of Automation, School of Electronic and Information Engineering,

Xi'an Jiaotong University. His research interest covers multisource information fusion, stochastic control and adaptive control, and nonlinear spectral analysis.)