

基于相对熵的概率假设密度滤波器序贯蒙特卡罗实现方式

李威¹, 韩崇昭¹, 闫小喜²

(1. 西安交通大学 a. 智能网络与网络安全教育部重点实验室, b. 电信学院
西安 710049; 2. 江苏大学 电气信息工程学院, 江苏 镇江 212013)

摘要: 概率假设密度滤波器的典型序贯蒙特卡罗实现方式与粒子滤波类似, 均是利用大量加权粒子估计多目标状态, 典型实现方式是为每个期望目标分配固定数目的粒子, 这导致较大的算法时间开销。鉴于此, 建立了基于相对熵的序贯蒙特卡罗实现方式, 首先计算两个不同规模粒子集合的相对熵, 与预设阈值进行比较以确定粒子数目, 从而动态调整粒子数目。仿真结果表明, 所提出的实现方式提高了跟踪效率, 在大部分时间步上优于典型实现方式。

关键词: 多目标跟踪; 概率假设密度; 序贯蒙特卡罗; 相对熵

中图分类号: TP273

文献标志码: A

Sequential Monte Carlo implementation of PHD filter based on Kullback-Leibler divergence

LI Wei¹, HAN Chong-zhao¹, YAN Xiao-xi²

(1a. Ministry of Education Key Lab For Intelligent Networks and Network Security, 1b. School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China. Correspondent: LI Wei, E-mail: liweizhangye@gmail.com)

Abstract: The typical sequential Monte Carlo(SMC) implementation of probability hypothesis density(PHD) filter is similar with the particle filter. Both of them make use of a large number of particles to estimate the multiple target states. The fixed number of particles is assigned for each expected target in typical SMC implementation, which will result in larger time cost of the algorithm. Therefore, the SMC implementation based on Kullback-Leibler divergence(KLD) is proposed. The KLD is computed for the two particle sets in different sizes. Then, the KLD is compared with the pre-threshold to obtain the number. The number of particles can be adaptively adjusted in the proposed implementation. Simulation results show that, the proposed implementation can improve the tracking efficiency, which is superior to the typical implementation in most time steps.

Key words: multi-target tracking; probability hypothesis density filter; sequential Monte Carlo implementation; Kullback-Leibler divergence

0 引言

概率假设密度(PHD)滤波算法的提出为多目标跟踪这一动态集值估计问题的解决提供了全新的思路。通过引入随机有限集和有限集统计等数学工具, PHD滤波器避免了数据关联过程, 与传统方法相比, 提供了一类更易处理的多目标滤波算法^[1-2]。为了提高PHD滤波器对目标个数估计的准确度, 提出了势化的概率假设密度(CPHD)滤波算法^[3]。经过近几年的发展, 基于PHD的方法吸引了越来越多研究人员

的注意力^[4]。同时, 为了避免随机有限集和有限集统计等复杂的数学工具的引入, PHD的两种替代的推导方式也相继出现: 一种是从泊松点过程角度分析^[5]; 另一种是利用物理空间方式进行描述^[6]。

结合具体的应用算法, PHD滤波器能够将目标的初始、跟踪、终止整个过程组合为一个过程。PHD滤波器主要有两种实现方式: 序贯蒙特卡罗实现方式(SMC)^[7-8]和高斯混合实现方式(GM)^[9-10]。其中: GM方式提供了PHD递推过程的解析形式, 同时依赖一

收稿日期: 2013-04-26; 修回日期: 2013-07-16.

基金项目: 国家自然科学基金创新研究群体项目(61221063); 国家自然科学基金面上项目(61074176); 江苏大学高级人才科研启动基金项目(12JDG076).

作者简介: 李威(1988-), 男, 博士生, 从事多目标跟踪及多源信息融合的研究; 韩崇昭(1943-), 男, 教授, 博士生导师, 从事信息融合、随机过程理论等研究.

些条件,如单目标转移密度和似然函数是高斯的;SMC方式不受这些条件限制,具体内容见文献[11].

对于PHD的SMC实现方式,其思想是通过粒子滤波手段对滤波过程中的集合积分进行近似.PHD通过加权粒子进行表示,粒子的权重和为观测区域内的期望目标个数.SMC实现方式的粒子传递过程通常可以归纳为预测步、更新步和后续进行的多目标状态提取.从具体的应用角度分析,SMC实现方式的性能受很多因素影响,从而出现了一些改进算法^[12-15],然而粒子数目作为一个影响算法的精度和效率的重要因素却很少被考虑到.同等情况下,使用较多的粒子可以提高算法的精度,同时,大量的粒子会增加粒子传递和状态提取过程的计算负担.已有的SMC实现方式在整个过程中为每个估计的目标分配了固定数目的粒子,这是低效的.由于不同时刻的概率分布复杂程度变化是很大的,不加区分地应用同等数目的粒子势必带来额外的时间开销.

针对典型算法的粒子数目问题,建立了一种多目标场景下更易于处理的PHD粒子滤波算法.动态修正每个时间步中使用的粒子数目,进而提高多目标跟踪算法的效率.参考已有的粒子数修正手段^[16-18],提出了基于相对熵的PHD滤波器的SMC实现方式.其核心思想是:通过滤波过程产生状态估计的粒子集合,计算这一集合体与从中提取的较小规模粒子集合之间的相对熵,如果这一结果不超过一个预先设定的阈值,则可以应用较少的点集进行重采样.通过所提出策略实现多目标跟踪过程粒子滤波实现方式中粒子数目的动态修正.

1 问题背景

1.1 SMC实现方式

根据文献[7]的描述对PHD的SMC实现方式进行简要总结.为了简化具体描述形式,对下述公式进行相应的缩写处理:

$$\begin{aligned} D_{k|k-1}(\xi) &= D_{k|k-1}(x_k|Z^{(k-1)}), \\ D_{k-1|k-1}(\zeta) &= D_{k-1|k-1}(x_{k-1}|Z^{(k-1)}), \\ D_{k|k}(\varsigma) &= D_{k|k}(x_k|Z^{(k)}). \end{aligned}$$

概率假设密度滤波器预测步如下:

$$\begin{aligned} D_{k|k-1}(\xi) &= \\ &\int [p_S(x_{k-1})f_{k|k-1}(x_k|x_{k-1})+ \\ &\beta_{k|k-1}(x_k|x_{k-1})]D_{k-1|k-1}(\zeta)dx_{k-1} + \gamma_k(x_k). \end{aligned} \quad (1)$$

其中: $p_S(x_{k-1})$ 为存活概率, $\beta_{k|k-1}(x_k|x_{k-1})$ 为从已有目标衍生的概率, $\gamma_k(x_k)$ 为目标新生强度, $f_{k|k-1}(x_k|x_{k-1})$ 为马尔可夫状态转移密度函数.

概率假设密度滤波器更新步如下:

$$\begin{aligned} D_{k|k}(\varsigma) &= [1 - p_D(x_k)]D_{k|k-1}(\xi) + \\ &\sum_{z \in Z_k} \frac{\varphi_{k,z}(x_k)}{\kappa_k(z) + C_k(z)} D_{k|k-1}(\xi). \end{aligned} \quad (2)$$

其中: $\varphi_{k,z}(x_k) = p_D(x_k)g(z|x_k)$, $p_D(x_k)$ 为检测概率, $g(z|x_k)$ 为关于量测 z 的单目标似然; $\kappa_k(z)$ 为杂波, $C_k(z) = \int p_D(x)g(z|x)D_{k|k-1}(x|Z^{(k-1)})dx$ 为量测强度.

针对上述PHD滤波过程,简要给出典型的SMC实现方式,该方法同样存在预测步和更新步.

1) 预测步.在时刻 $k-1$,已有粒子点的预测过程从建议分布中采样获得,有

$$\tilde{x}_k^{(i)} \sim q_k(\cdot|x_{k-1}^{(i)}, Z_k), \quad i = 1, 2, \dots, L_{k-1}, \quad (3)$$

其中 $q_k(\cdot|x_{k-1}^{(i)}, Z_k)$ 经常选取 $f_{k|k-1}(x_k|x_{k-1})$ 作为重要性函数.相应的粒子权重为

$$\tilde{w}_{k|k-1}^{(i)} = \frac{\phi_{k|k-1}(\tilde{x}_k^{(i)}, x_{k-1}^{(i)})}{q_k(\tilde{x}_k^{(i)}|x_{k-1}^{(i)}, Z_k)} w_{k-1}^{(i)}, \quad (4)$$

其中 L_{k-1} 为 $k-1$ 时刻的粒子数目.式(4)中的转移密度为

$$\begin{aligned} \phi(x_k, x_{k-1}) &= \\ p_S(x_{k-1})f_{k|k-1}(x_k|x_{k-1}) + \beta(x_k|x_{k-1}). \end{aligned} \quad (5)$$

对于新生目标,需要额外的 J_k 个粒子,区别于上面的重要性函数,有

$$\begin{aligned} \tilde{x}_k^{(i)} &\sim p_k(\cdot|Z_k), \\ i &= L_{k-1} + 1, L_{k-1} + 2, \dots, L_{k-1} + J_k, \end{aligned} \quad (6)$$

其中 $p_k(\cdot|Z_k)$ 为新生目标的建议分布,相应的粒子权重通过下式计算得到:

$$\tilde{w}_{k|k-1}^{(i)} = \frac{1}{J_k} \frac{\gamma_k(\tilde{x}_k^{(i)})}{p_k(\tilde{x}_k^{(i)}|Z_k)}. \quad (7)$$

2) 更新步.在时刻 k ,对于每个 $z \in Z_k$,量测强度通过下式进行近似:

$$C_k(z) = \sum_{j=1}^{L_{k-1}+J_k} \varphi_{k,z}(\tilde{x}_k^{(j)})\tilde{w}_{k|k-1}^{(j)}. \quad (8)$$

重要性权重通过下式进行更新:

$$\begin{aligned} \tilde{w}_k^{(i)} &= [1 - p_D(\tilde{x}_k^{(i)})]\tilde{w}_{k|k-1}^{(i)} + \\ &\sum_{z \in Z_k} \frac{\varphi_{k,z}(\tilde{x}_k^{(i)})}{\kappa_k(z) + C_k(z)} \tilde{w}_{k|k-1}^{(j)}. \end{aligned} \quad (9)$$

在多目标跟踪领域,还需要目标状态提取过程.

1.2 问题描述

在PHD滤波器典型的SMC实现方式中,粒子数目的选择往往存在跟踪精度与算法效率之间的权衡,为了获得较高精度,算法倾向于采用较多的粒子点.同时,多数已有算法在整个滤波过程中,对每个目标使用固定的粒子个数,这样会在粒子传递和状态提取过程中引入相对较多的粒子,这种粒子点的冗余将带

来较大的时间开销. 为了解决该低效问题, 建立了一种更高效的PHD滤波器SMC实现方式, 具体算法下一节给出.

2 基于相对熵的序贯蒙特卡罗实现方式

2.1 算法思想

针对典型实现方式引入的额外计算量, 建立了基于相对熵的序贯蒙特卡罗实现方式. 区别于典型实现方式对粒子数目的忽视, 这种方法重点关注滤波过程中粒子数目的选取. 其核心思想是通过相对熵的计算提取出相对较小规模的重采样粒子集合, 从而在保证一定精度的条件下为下次递推节省时间开销. 具体过程为从原始滤波获得到的粒子集合中抽取一个子集合, 计算原始粒子集合与抽取粒子集合二者对应的多目标概率密度函数之间的相对熵; 然后将这一计算结果同预先指定好的阈值进行比较, 如果小于这一阈值, 则表示可以在下一时刻的滤波过程中选取相对较少的粒子数目, 反之, 则增加粒子数目. 通过这种自适应的方式, 为下面的重采样过程确定粒子集的规模.

2.2 算法公式

2.2.1 经验概率密度

考虑一个多目标问题, PHD滤波器得到的是未进行重采样的粒子集合 $\{\bar{w}_k^{(i)}, \bar{x}_k^{(i)}\}_{i=1}^L$, 从中抽取 $\hat{L} = aL$ 个粒子构成一个新的粒子集合 $\{\hat{w}_k^{(i)}, \hat{x}_k^{(i)}\}_{i=1}^{\hat{L}}$. 相对熵的计算实际上是比较两个概率密度之间的差异, 这里需要计算两个粒子集合各自的经验概率密度函数, 有

$$\hat{P}(X|Z) = \sum_{i=1}^N w_k^{(i)} \delta(x_k - x_k^{(i)}), \quad (10)$$

其中 $\delta(\cdot)$ 为 Dirac delta 函数. 进而得到两个经验概率分布, 二者是针对同一状态空间的两种描述, 即

$$\begin{aligned} \hat{P}_L(X|Z) &= \sum_{i=1}^L \bar{w}_k^{(i)} \delta(x_k - \bar{x}_k^{(i)}), \\ \hat{P}_{\hat{L}}(X|Z) &= \sum_{i=1}^{\hat{L}} \hat{w}_k^{(i)} \delta(x_k - \hat{x}_k^{(i)}). \end{aligned}$$

2.2.2 多目标相对熵

在概率论和信息论中, 相对熵是关于两个概率分布之间差异的度量, 具体的相对熵(KLD)^[19]公式为

$$K(p, q) = \sum_x p(x) \log \frac{p(x)}{q(x)}. \quad (11)$$

KLD的值是非负的, 当且仅当两个概率分布相同时为零.

在跟踪领域, 通常应用如下KLD公式:

$$K(f_{\text{Grnd}}; f) = \int f_{\text{Grnd}}(x) \log \frac{f_{\text{Grnd}}(x)}{f(x)} dx. \quad (12)$$

其中: f 为与滤波输出相关的概率分布, f_{Grnd} 为与真

实分布对应的概率分布. 显然, $K(f_{\text{Grnd}}; f)$ 的值越大, 滤波器输出的信息越少.

本算法应用于多目标情况, 故需要使用多目标场景下的相对熵度量. 应用有限集统计量这一工具, 研究人员建立了类似于单目标情况的计算公式^[20-21]如下:

$$K_L(\hat{P}_L; \hat{P}_{\hat{L}}) = \int \hat{P}_L(X) \log \frac{\hat{P}_L(X)}{\hat{P}_{\hat{L}}(X)} dX. \quad (13)$$

其中积分为集合积分. 这里的KLD用来度量相对于原始粒子集合、后抽取粒子集的近似性能. 当这一值较小时, 表示两个粒子点集都对多目标状态进行了较好的表征.

2.3 阈值选取

上面计算得到的KLD需要与一个预先设定好的阈值 δ 进行比较, 从而确定重采样需要的粒子数目. 为了避免采用经验值面临的不稳定性和量纲差异, 这一阈值同样通过计算两个粒子集合的KLD进行确定. 具体过程为, 在算法的初始化时, 采用两个不同粒子数的滤波器进行多目标跟踪, 滤波结果为两个粒子集合 $\{\bar{w}_k^{(i)}, \bar{x}_k^{(i)}\}_{i=1}^{L_0}$ 和 $\{\bar{w}_k^{(i)}, \bar{x}_k^{(i)}\}_{i=1}^{L_{\text{max}}}$. 其中: L_0 为多目标场景的初始分配粒子数; L_{max} 为足够大的粒子数, 即后一粒子集合可以理解为真实分布. 由式(10)和(13)计算二者的KLD, 将这一结果设定为阈值, 从而确定 δ 的数值. 因此, 对于不同的应用场景, 阈值的具体数值是通过这一过程动态确定的. 对于算法中的尺度因子, 根据经验方式进行选取. 下面对算法进行详细的描述和说明.

2.4 算法描述

算法的主要流程如下.

初始化.

Step 1: $k = 0$,

Step 2: for $i = 1$ to L_0 do,

Step 3: $x_0^{(i)} \sim q_0(x)$,

Step 4: $w_0^{(i)} = q_0/N_0$,

Step 5: end for.

递推.

Step 6: $k = k + 1$.

PHD 预测步.

Step 7: for $i = 1$ to $L_{k-1} + J_k$ do,

Step 8: 计算 $\{\tilde{w}_{k|k-1}^{(i)}, \tilde{x}_{k|k-1}^{(i)}\}$,

Step 9: end for.

PHD 更新步.

Step 10: input $z_k^j \in Z_k$,

Step 11: for $i = 1$ to $L_{k-1} + J_k$ do,

Step 12: 计算 $\{\tilde{w}_{k|k}^{(i)}, \tilde{x}_{k|k}^{(i)}\}$,

Step 13: end for.

正则化.

Step 14: 计算 $\hat{N}_{k|k} = \sum_{j=1}^{L_{k-1}+J_k} \tilde{w}_k^{(j)}$,

Step 15: 替换 $L = L_{k-1} + J_k$,

Step 16: 得到 $\{\tilde{w}_k^{(i)} / \hat{N}_{k|k}, \tilde{x}_k^{(i)}\}_{i=1}^L$,

Step 17: output $\{\bar{w}_k^{(i)}, \bar{x}_k^{(i)}\}_{i=1}^L$.

状态提取.

Step 18: input $\{\bar{w}_k^{(i)}, \bar{x}_k^{(i)}\}_{i=1}^L$,

Step 19: 聚类,

Step 20: output $\hat{X} = \{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_{\hat{N}}\}$.

基于相对熵的粒子选取算法.

Step 21: input 正则化后粒子集合 $\{\bar{w}_k^{(i)}, \bar{x}_k^{(i)}\}_{i=1}^L$,

Step 22: set 阈值 δ , 参数 a, b, c ,

Step 23: 抽取 $\hat{L} = aL$ 个粒子, 得 $\{\hat{w}_k^{(i)}, \hat{x}_k^{(i)}\}_{i=1}^{\hat{L}}$,

Step 24: 计算经验概率密度 $\hat{P}_L(\cdot)$ 和 $\hat{P}_{\hat{L}}(\cdot)$,

Step 25: 计算相对熵 $D = K_L(\hat{P}_L(\cdot); \hat{P}_{\hat{L}}(\cdot))$,

Step 26: if $D \leq \delta$ then $L_k = bL$,

Step 27: else $L_k = cL$,

Step 28: output L_k .

重采样.

Step 29: input 正则化后粒子集合 $\{\bar{w}_k^{(i)}, \bar{x}_k^{(i)}\}_{i=1}^L$,

Step 30: 重采样 L_k 个粒子,

Step 31: output $\{w_k^{(i)}, x_k^{(i)}\}_{i=1}^{L_k}$,

Step 32: 转至 Step 6.

首先, 进行算法的初始化. L_0 为初始粒子点数, $q_0(x)$ 为初始的重要性采样函数. 当 $k \geq 1$ 时, 进行概率假设密度的粒子递推过程. PHD 预测步开始进行 Step 8, 见式 (3)~(7). 其中: L_{k-1} 为已有的粒子点数, J_k 为新生粒子点数. 从而得到预测后的粒子集合. 通过引入新的量测, 由式 (8) 和 (9) 对粒子集合进行更新后得到更新后的粒子集合. 在正则化环节, 算法得到正则化后的粒子集合 $\{\bar{w}_k^{(i)}, \bar{x}_k^{(i)}\}_{i=1}^L$, 其中 L 为一个中间变量. 应用聚类算法对多目标状态进行提取, 基于相对熵运算对粒子进行修正, 其中尺度因子 $0 < a < 1$, $0 < b < 1$, $c > 1$. 如果采用保守方式, 则可以将 3 个值取在 1 附近, 阈值 δ 和尺度因子都依据模型而改变, 即不同场景不同的参数. 最后, 为下一次迭代确定进行重采样的粒子集合 $\{w_k^{(i)}, x_k^{(i)}\}_{i=1}^{L_k}$.

3 仿真实验

3.1 仿真场景

为了表明所提出算法的有效性, 设计一个单传感多目标跟踪场景. 目标个数和状态均未知, 且在一个 $[-1000, 1000] \times [-1000, 1000]$ (m) 的二维空间内

运动. 每个目标按照如下的运动模型进行:

$$x_k = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} x_{k-1} + \begin{bmatrix} T^2/2 & 0 \\ 0 & T^2/2 \\ T & 0 \\ 0 & T \end{bmatrix} \begin{bmatrix} v_{1,k} \\ v_{2,k} \end{bmatrix}.$$

其中: x_k 为目标状态, 由位置 $[x_{1,k}, x_{2,k}]^T$ 和速度 $[x_{3,k}, x_{4,k}]^T$ 两部分组成; 采样周期 $T = 1$ s; 过程噪声 $\{v_{1,k}\}$ 和 $\{v_{2,k}\}$ 假设为相互独立的高斯白噪声, 对应的标准差为 $\sigma_{v_1} = 2$ m/s², $\sigma_{v_2} = 0.5$ m/s².

对于新生目标, 根据泊松点过程, 对应的强度函数为 $\gamma = 0.5\mathcal{N}(\cdot; \bar{x}, Q)$. 其中

$$\bar{x} = \begin{bmatrix} 0 \\ 0 \\ 2 \\ -2 \end{bmatrix}, \quad Q = \begin{bmatrix} 10 & 0 & 0 & 0 \\ 0 & 10 & 0 & 0 \\ 0 & 0 & 2.5 & 0 \\ 0 & 0 & 0 & 2.5 \end{bmatrix},$$

强度函数中的 $\mathcal{N}(\cdot; \bar{x}, Q)$ 表示一个均值为 \bar{x} 、方差为 Q 的正态分布.

目标的初始量测为

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

其中 $\{w_{1,k}\}$, $\{w_{2,k}\}$ 为相互独立的高斯白噪声, 相应的标准差为 $\sigma_{w_1} = \sigma_{w_2} = 2.5$ m/s². 按照通常的假设, 过程噪声和量测噪声相互独立.

对于杂波过程, 假设其在整个监控区域是均匀分布的, 并且用一个泊松随机有限集进行建模. 杂波强度为 $\kappa_k(z_k) = \lambda c_k(z_k)$. 其中: λ 为每次扫描的平均杂波量测, $c(z)$ 为均匀分布.

出于简化考虑, 仿真中没有衍生目标. 同时, 新生目标在一个已知的范围内出现. 实验中需要跟踪 4 个目标, 共进行 100 个时间步. 目标 1 和目标 2 存活于整个过程, 目标 3 在第 10 时间步出生, 目标 4 在倒数第 10 时间步消亡. 每个目标的存活概率取为 $e_{k|k-1} = 0.95$, 每个目标的检测概率 $P_D(x)$ 假设为 1, 仿真过程中 λ 取值为 20.

初始化时, 已有目标分配的粒子数为 1000, 新生目标分配的粒子数为 500. 由基于相对熵的改进算法可知, 这一数目会在跟踪过程中发生变化. 具体到算法中, 参数取为 $a = 0.8$, $b = 0.8$, $c = 1.25$. 重要性采样函数取为多目标的转移密度.

3.2 性能评估

图 1 为 X 方向和 Y 方向上目标的真实航迹和所提实现方式的估计结果. 由图 1 可见, 所提出实现方式在简单的多目标场景中能够进行较好的跟踪.

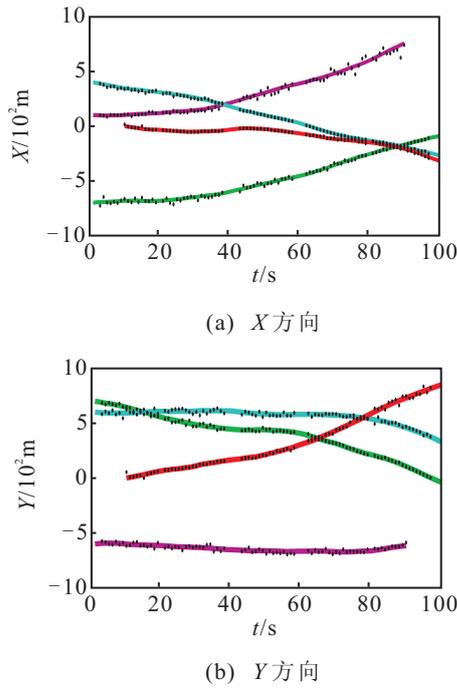


图1 目标真实航迹与估计结果

考虑到单次实验的随机性, 共进行 100 次蒙特卡罗仿真. 图 2 为 100 次蒙特卡罗仿真后所提实现方式对目标个数的估计取平均后的结果. 由图 2 可见, 所提实现方式能够正确估计目标数目.

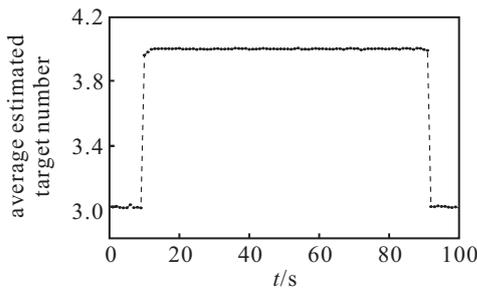


图2 目标个数的估计平均值

利用 OSPA(optimal sub-pattern assignment)^[22]衡量多目标跟踪算法性能, 其中 OSPA 参数选取为 $p = 2, c = 20$. 将所提出实现方式与典型实现方式^[7]进行比较, 对比结果如图 3 所示. 由图 3 可见, 所提出实现方式 (ASMC-PHD) 的 OSPA 结果在大部分时间步内小于典型实现方式 (SMC-PHD), 即所提出实现方式在大部分时间步内优于典型实现方式.

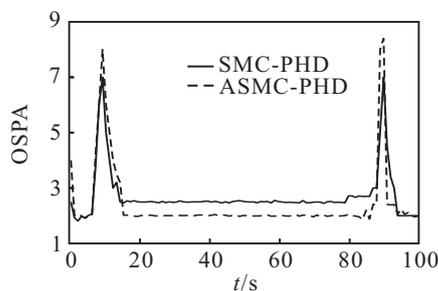


图3 OSPA 性能评价结果

算法的时间消耗受初始值影响, 100 步的平均值为: 所提出实现方式为 176.50 s, 典型实现方式为 198.10 s (Matlab R2012a, Intel(R), Core(R), Duo CPU 2.33 GHz, 2.00 GB), 表明所提出实现方式优于典型实现方式的跟踪效率.

实验中简化了新生目标的出现范围, 对于未知情况, 可采用在粒子集中区域内进行抽取或者针对新生目标抽取全部的粒子的方式. 仿真过程中, 红色目标在第 10 步出现, 紫色目标在第 90 步消失. 因此图 3 中对应时刻的 OSPA 距离出现较大的尖峰. 对于前 18 步, 所提出实现方式与典型实现方式相当. 从 20 步开始, 目标个数和状态趋于稳定, 所提出实现方式优于典型实现方式. 在 90 步附近, 由于多个目标在 X 方向的状态相对集中, 基于相对熵的实现方式抽取的粒子集合与原始粒子集合相比, 粒子数的减少影响了对多目标状态的描述, 因此出现了 OSPA 距离略大于典型实现方式的情况.

4 结 论

本文通过多目标相对熵的引入, 建立了一种基于相对熵的 PHD 滤波器 SMC 实现方式. 该方式改变了典型方式中使用固定比例粒子数目的情况, 在滤波过程的不同时刻能够动态修正粒子数目. 仿真结果表明, 综合算法效率和跟踪精度, 基于相对熵的实现方式在大部分时间步优于典型实现方式. 同时, 所提出方法与现存的改进方法是互补的, 对于目标出生未知等复杂情况有待进一步研究.

参考文献(References)

- [1] Bar-Shalom Y, Li X R. Multitarget-multisensor tracking: Principle and techniques[M]. Storrs: YBS Publishing, 1995: 307-372.
- [2] Mahler R. Multitarget Bayes filtering via first-order multitarget moments[J]. IEEE Trans on Aerospace and Electronic Systems. 2003, 39(4): 1152-1178.
- [3] Mahler R. PHD filters of higher order in target number[J]. IEEE Trans on Aerospace and Electronic Systems, 2007, 43(4): 1523-1543.
- [4] Mahler R. A survey of PHD filter and CPHD filter implementations[C]. Proc of the SPIE Conf on Signal Processing, Sensor Fusion and Target Recognition XVI. Orlando: SPIE, 2007, 6567: 1-12.
- [5] Streit R L, Stone L D. Bayes derivation of multitarget intensity filters[C]. Proc of the 11th Int Conf on Information Fusion. Cologne: IEEE Press, 2008: 1-8.
- [6] Erdinc O, Willett P, Bar-Shalom Y. The Bin-occupancy filter and its connection to the PHD filters[J]. IEEE Trans on Signal Processing, 2009, 57(11): 4232-4246.

- [7] Vo B N, Singh S, Doucet A. Sequential monte carlo methods for multi-target filtering with random finite sets[J]. IEEE Trans on Aerospace and Electronic Systems, 2005, 41(4): 1224-1245.
- [8] Whiteley N, Singh S, Godsill S. Auxiliary particle implementation of probability hypothesis density filter[J]. IEEE Trans on Aerospace and Electronic Systems, 2010, 46(3): 1437-1454.
- [9] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091-4104.
- [10] Vo B T, Vo B N, and Cantoni A. Analytic implementations of the cardinalized probability hypothesis density filter[J]. IEEE Trans on Aerospace and Electronic Systems, 2007, 55(7): 3553-3567.
- [11] Mahler R. Statistical multisource-multitarget information fusion[M]. Boston: Artech House, 2007: 609-631.
- [12] Ristic B, Clark D, Vo B N. Improved SMC implementation of the PHD filter[C]. Proc of the 13th Int Conf on Information Fusion. Edinburgh: IEEE Press, 2010: 1-8.
- [13] Yan X, Han C, Liu J. State extraction of probability hypothesis density filter based on Dirichlet distribution[C]. Proc of the 13th Int Conf on Information Fusion. Edinburgh: IEEE Press, 2010: 1-6.
- [14] Ristic B, Clark D, Vo B N, et al. Adaptive target birth intensity for PHD and CPHD filters[J]. IEEE Trans on Aerospace and Electronic Systems, 2012, 48(2): 1656-1668.
- [15] Baser E, Efe M. A novel auxiliary particle PHD filter[C]. Proc of the 15th Int Conf on Information Fusion. Singapore: IEEE Press, 2012: 165-172.
- [16] Fox D. Adapting the sample size in particle filters through KLD-sampling[J]. The Int J of Robotics Research, 2003, 22(12): 985-1003.
- [17] Karlsson R, Gustafsson F. Monte Carlo data association for multiple target tracking[J]. Target Tracking: Algorithms and Applications, 2001, 1(1): 1-5.
- [18] 段琢华, 蔡自兴, 于金霞. 移动机器人软故障检测与补偿的自适应粒子滤波算法[J]. 中国科学E辑: 信息科学, 2008, 38(4): 565-578.
(Duan Z H, Cai Z X, Yu J X. The adaptive particle filter algorithm for mobile robot software fault detection and compensation[J]. Science in China Series E: Engineering and Materials Science, 2008, 38(4): 565-578.)
- [19] Kullback S, Leibler R A. On information and sufficiency[J]. The Annals of Mathematical Statistics, 1951, 22(1): 79-86.
- [20] Hoffman J R, Mahler R, Zajic T. User-defined information and scientific performance evaluation[C]. Proc of the SPIE Conference on Signal Processing, Sensor Fusion and Target Recognition X. Orlando: SPIE, 2001, 4380: 300-311.
- [21] El-Fallah A I, Mahler R P, Zajic T, et al. Scientific performance evaluation for sensor management[C]. Proc of the SPIE Conf on Signal Processing, Sensor Fusion and Target Recognition IX. Orlando: SPIE, 2000: 183-194.
- [22] 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: 郑晓蕾)