

基于拟蒙特卡罗的未知杂波 GMP-PHD 滤波器

李翠芸¹, 江舟^{1,2}, 姬红兵¹, 曹潇男¹

(1. 西安电子科技大学 电子工程学院, 西安 710071; 2. 中国人民解放军 95972 部队, 甘肃 酒泉 735018)

摘要: 针对非线性系统模型中未知杂波环境下的多目标跟踪问题, 提出一种基于拟蒙特卡罗方法的未知杂波高斯混合粒子概率假设密度(GMP-PHD)算法. 首先利用有限混合模型拟合未知杂波空间分布, 使其能够在杂波模型未知的情况下稳定跟踪目标; 然后利用低偏差点集在状态空间中分布均匀的特性将拟蒙特卡罗采样方法应用到GMP-PHD中, 使其在解决非线性滤波问题的同时提高目标跟踪精度. 仿真实验表明, 所提出的算法具有良好的跟踪性能.

关键词: 未知杂波; 拟蒙特卡罗; 概率假设密度; 有限混合模型; 低偏差点集

中图分类号: TN953

文献标志码: A

GMP-PHD filter based on quasi-Monte Carlo in unknown clutter

LI Cui-yun¹, JIANG Zhou^{1,2}, JI Hong-bing¹, CAO Xiao-nan¹

(1. School of Electronic Engineering, Xidian University, Xi'an 710071, China; 2. Unit 95972, PLA, Jiuquan 735018, China. Correspondent: JIANG Zhou, E-mail: jiang937@126.com)

Abstract: Aiming at improving the multi-target tracking performance of the nonlinear model in the unknown clutter environment, a Gaussian mixture particle probability hypothesis density(GMP-PHD) algorithm based on quasi-Monte-Carlo sampling is proposed in this paper. First of all, this algorithm can track targets steadily in the unknown clutter model by fitting spatial distribution of the unknown clutter intensity with the finite mixture model and estimating the clutter number. Then, the proposed algorithm can improve the tracking accuracy by applying the quasi-Monte-Carlo sampling which makes the best of the uniform distribution property of the low discrepancy points into the GMP-PHD filtering. Simulation results show that the proposed algorithm performs better than the conventional algorithms in the nonlinear unknown clutter environment.

Key words: unknown clutter; quasi-Monte Carlo; probability hypothesis density; finite mixture model; low discrepancy point

0 引言

在多目标跟踪中, 随机有限集(RFS)统计理论不需要进行数据关联计算, 这引起了工程应用界和学术界的高度重视. 文献[1]提出的概率假设密度(PHD)滤波算法将复杂的多目标状态空间的运算转换为单目标状态空间的运算, 在保证算法实时有效的同时, 提高了多目标的跟踪精度, 具有很高的理论研究价值和应用价值.

在传统的PHD滤波器中, 通常假设在可观测的范围内杂波是均匀分布的^[2], 但实际环境中杂波的空间分布在观测区域是复杂的、未知的. 因此, 当真实的杂波强度与先验的杂波模型不匹配时, 传统PHD滤

波器的跟踪性能会急剧下降^[3]. 针对这个问题, 文献[3]提出了基于有限混合模型的未知杂波GM-PHD滤波算法, 文献[4]提出了一种利用混合状态空间估计未知杂波的GM-PHD滤波算法, 两种算法均能在线性条件下对杂波进行有效估计. 实际中, 非线性滤波问题更为普遍, 而GM-PHD滤波器只适用于线性情况^[5]. 在非线性滤波中常采用SMC-PHD算法^[6], 但该算法在目标状态估计时所采用的聚类方法会导致较大的估计误差, 尤其是在杂波密集的情况下. 文献[7]针对该问题, 将拟蒙特卡罗(QMC)方法引入到GMP-PHD滤波算法中, 提高了目标跟踪性能.

针对未知杂波环境下的非线性PHD滤波, 本文

收稿日期: 2013-07-02; 修回日期: 2013-10-09.

基金项目: 国家自然科学基金项目(61372003); 国家自然科学基金青年基金项目(61101246, 61301289); 中央高校基本科研业务费专项资金项目(K5051202014); 国家留学基金项目(201206965015).

作者简介: 李翠芸(1976—), 女, 副教授, 博士, 从事非线性滤波、数字图像处理、红外图像目标检测与跟踪等研究; 江舟(1979—), 男, 工程师, 硕士生, 从事未知杂波下的多目标跟踪、随机有限集滤波方法的研究.

提出一种基于 QMC 采样的未知杂波高斯混合粒子概率假设密度 (QMC-GMP-PHD) 算法. 该算法利用有限混合模型拟合未知杂波的空间分布并估计杂波个数, 然后将其估计的杂波强度直接运用于 QMC-GMP-PHD 算法中, 并进行多目标的预测、更新. 仿真实验验证了本文所提出算法的有效性.

1 PHD 滤波器

在多目标跟踪中, 当目标数未知且目标状态维数与量测数均是随时间变化的离散随机变量时, 多目标的状态集和量测集可以用以下随机有限集的形式表示^[5]:

$$\mathbf{X}_k = \{x_{k,1}, \dots, x_{k,N_k}\} \in F(\mathbf{X}), \quad (1)$$

$$\mathbf{Z}_k = \{z_{k,1}, \dots, z_{k,M_k}\} \in F(\mathbf{Z}). \quad (2)$$

其中: \mathbf{X}_k 为 k 时刻的目标状态随机集, \mathbf{Z}_k 为 k 时刻的量测随机集, $F(\mathbf{X})$ 和 $F(\mathbf{Z})$ 分别为 \mathbf{X} 和 \mathbf{Z} 上的所有随机有限子集的集合, N_k 为 k 时刻的目标数, M_k 为 k 时刻的量测数.

若 \mathbf{X}_{k-1} 表示 $k-1$ 时刻的状态随机集, 则 \mathbf{X}_k 表示 k 时刻的目标状态随机集^[1].

$$\mathbf{X}_k = \left(\bigcup_{x \in \mathbf{X}_{k-1}} S_{k|k-1}(x) \right) \cup \Gamma_k. \quad (3)$$

其中: Γ_k 表示新生状态随机集, $S_{k|k-1}$ 表示从 $k-1$ 时刻到 k 时刻仍然存活的状态随机集, 本文不考虑目标衍生的情况.

k 时刻的目标量测随机集 \mathbf{Z}_k 可表示为

$$\mathbf{Z}_k = K_k \bigcup \left(\bigcup_{x \in \mathbf{X}_k} \Theta_k(x) \right). \quad (4)$$

其中: Θ_k 表示源于真实目标的量测随机集, K_k 表示 k 时刻源于虚警或杂波的量测随机集.

通过 PHD 函数可以对多目标随机集的概率密度进行近似描述, 并使用贝叶斯递推公式进行计算.

目标 PHD 预测 $D_{k|k-1}(x)$ 为

$$D_{k|k-1}(x) = \int P_S f_{k|k-1}(x|\xi) D_{k-1}(\xi) d\xi + \gamma_k(x). \quad (5)$$

其中: P_S 为 $k-1$ 时刻到 k 时刻目标的存活概率, $f_{k|k-1}$ 为单个目标的状态转移密度, γ_k 为新生目标的 PHD.

目标 PHD 更新 $D_k(x)$ 为

$$D_k(x) = (1 - P_d) D_{k|k-1}(x) + \sum_{z \in \mathbf{Z}_k} \frac{P_d g_k(z|x) D_{k|k-1}(x)}{\kappa_k(z) + \int P_d g_k(z|\xi) D_{k|k-1}(\xi) d\xi}. \quad (6)$$

其中: g_k 为单个目标量测似然函数, P_d 为目标检测概率, κ_k 为杂波量测的强度函数.

2 杂波强度估计

在 PHD 滤波中杂波被模拟为泊松随机有限集合的形式, 它可以完全由强度函数 $\kappa_k(z_k)$ 表示^[8], 即

$$\kappa_k(z_k) = \lambda c(z_k). \quad (7)$$

其中: λ 表示每时刻杂波的平均数目, $c(z_k)$ 表示杂波的空间分布.

在满足 λ 和 $c(z_k)$ 未知且在多目标的检测和跟踪过程中都不随时间变化的情况下, $\kappa_k(z_k)$ 可以通过时间窗 $[1, L]$ 中的累计量测进行预估计. 当窗 $[1, L]$ 的长度足够长时, 估计的 $\kappa_k(z_k)$ 能够很好地近似真实杂波的情况.

2.1 杂波数目估计

集合 $\mathbf{M} = \{m_1, m_2, \dots, m_L\}$ 代表窗 $[1, L]$ 内每一时刻量测的数目, 每一个元素都服从如下泊松分布:

$$f(m_k|\lambda) = \frac{e^{-\lambda} \lambda^{m_k}}{m_k!}, \quad k = 1, 2, \dots, L. \quad (8)$$

其中 λ 表示每时刻杂波的平均数目.

假设集合 \mathbf{M} 中的每一个元素都是相互独立的, 则 λ 的似然表示为

$$f(\mathbf{M}|\lambda) = \prod_{k=1}^L f(m_k|\lambda) = \frac{e^{-\lambda L} \lambda^{\sum_{k=1}^L m_k}}{\prod_{k=1}^L m_k!}. \quad (9)$$

λ 的极大似然估计为

$$\lambda^{ML} = \arg \max \{ \log_\lambda (f(\mathbf{M}|\lambda)) \} = \frac{1}{L} \sum_{k=1}^L m_k = \frac{m}{L}. \quad (10)$$

通过获得 $\partial \log f(\mathbf{M}|\lambda) / \partial \lambda = 0$ 的一个适当根, 可以得到 λ 的极大似然估计. 其中 $m = \sum_{k=1}^L m_k$ 代表累计量测的数目. 此外, 还可证明 m 是 λ 的无偏最小估计^[9].

2.2 杂波空间分布估计

窗 $[1, L]$ 内的累计量测可由 $\mathbf{Z} = \{z^1, z^2, \dots, z^M\}$ 表示. 下面通过 N 维有限混合模型来模拟杂波空间分布.

$$C(z) = f(z|\theta) = \sum_{j=1}^N \omega^j f^j(z|\theta^j), \quad \sum_{j=1}^N \omega^j = 1. \quad (11)$$

其中: $\theta = \{\omega^j, \theta^j\}$ 表示有限混合模型中集合的参数, ω^j 和 θ^j 分别表示混合权重和混合模型中第 j 个组成部分的参数.

假设在可观测范围内杂波的第 1 部分表示由背景噪声产生的稀少杂波, 其空间分布为均匀分布, 其余部分表示由其他原因产生的杂波, 服从高斯分布

$$f^1(z|\theta^1) = u(z|\theta^1), \quad (12)$$

θ^1 是观测区域的均值,

$$f^j(z|\theta^j) = N(z|\theta^j), \quad (13)$$

$\theta^j = \{m^j, P^j\}$, $j = 2, 3, \dots, N$.

假设窗 $[1, L]$ 中累计量测中的元素相互独立, 则参数 θ 的似然表示为

$$f(\mathbf{Z}|\theta) = \sum_{i=1}^M f(z^i|\theta) = \prod_{i=1}^M \sum_{j=1}^N \omega^j f^j(z^i|\theta^j), \quad (14)$$

参数 θ 的极大似然估计表示为

$$\theta^{ML} = \arg \max_{\theta} \{\log_{\theta}(f(\mathbf{Z}|\theta))\}. \quad (15)$$

在估计有限混合模型参数中, 常用的方法有最大期望 (EM) 算法和马尔科夫链蒙特卡罗 (MCMC) 算法. 本文采用 MCMC 算法估计有限混合模型的集合参数 θ 的极大后验估计, 具体算法见文献 [3].

3 基于 QMC 的未知杂波 GMP-PHD 滤波器

在多目标的跟踪问题中, GM-PHD 滤波算法只适用于线性高斯系统, 对于非线性系统, GM-PHD 得不到闭合解析解. 而 GMP-PHD 算法综合了粒子 PHD 算法和 GM-PHD 算法的优点, 既能处理非线性问题, 又避免了重采样. 但是该算法在目标强度递推过程中, 需要通过粒子采样对各高斯项进行积分近似, 传统的 MC 方法采取随机选取的方式选取样本点, 容易形成“空隙和簇”, 从而影响积分近似的精度, 其近似误差数量级为 $O(N^{-1/2})$.

3.1 QMC 采样

QMC 方法的基本思想是用精选的确定性点来替换 MC 积分中的随机样本点, 这些样本点分布均匀, 具有较小的偏差, 因此也被称为“低偏差点”. 文献 [10] 验证了以下结果: 相比于传统 MC 方法, 采用 QMC 方法具有较小的误差. 特别是在最优低偏差序列时, 采用该方法的误差数量级能趋近于 $O(N^{-1})$.

QMC 方法注重样本分布的均匀性, 即样本点分布越均匀, 偏差越小, 误差也越低. 本文利用低偏差序列 Halton 产生均匀分布的样本点, 并将这些样本点转换为服从高斯分布的样本点, 得到比 MC 方法产生的普通高斯样本点分布更为均匀的拟高斯样本点. 具体算法参见文献 [11].

3.2 未知杂波环境下的 QMC-GMP-PHD 滤波器

假定已知 $k-1$ 时刻目标随机集 PHD 参数为 $\{\omega_{k-1}^{(l)}, m_{k-1}^{(l)}, P_{k-1}^{(l)}\}_{l=1}^{J_{k-1}}$, 算法进行下一个时刻的迭代, 具体流程如下.

Step 1 估计杂波强度 $\kappa_k(z_k) = \lambda c(z_k)$.

首先估计出每一时刻杂波的平均数目 λ , 计算过程如 2.1 节所示; 然后利用 MCMC 算法估计杂波的密度函数 $c(z_k)$, 计算过程如 2.2 节所示.

Step 2 随机集 PHD 的预测.

1) 新生目标. 对于 $l = 1, 2, \dots, J_{\gamma, k}$, 有

$$\omega_{k|k-1}^{(l)} = \omega_{\gamma, k}^{(l)}, \quad m_{k|k-1}^{(l)} = m_{\gamma, k}^{(l)}, \quad P_{k|k-1}^{(l)} = P_{\gamma, k}^{(l)}.$$

2) 存活目标. 对于 $l = 1, 2, \dots, J_{k-1}$, 有:

QMC 粒子采样

$$x_{k-1}^{(l)(i)} \sim N(m_{k-1}^{(l)}, P_{k-1}^{(l)}),$$

$$x_{S, k|k-1}^{(l)(i)} \sim f_{k|k-1}(x_{k-1}^{(l)(i)}),$$

$$i = 1, 2, \dots, N;$$

估计参数

$$\omega_{k|k-1}^{(l)} = P_S \omega_{k-1}^{(l)}, \quad (16)$$

$$m_{k|k-1}^{(l)} = \frac{1}{N} \sum_{i=1}^N x_{S, k|k-1}^{(l)(i)}, \quad (17)$$

$$P_{k|k-1}^{(l)} = \frac{\sum_{i=1}^N [m_{k|k-1}^{(l)} - x_{S, k|k-1}^{(l)(i)}][m_{k|k-1}^{(l)} - x_{S, k|k-1}^{(l)(i)}]^T}{N}. \quad (18)$$

Step 3 随机集 PHD 的更新.

$$D_k(x) = (1 - P_d)D_{k|k-1}(x) +$$

$$P_d \sum_{z \in \mathbf{Z}_k} \sum_{l=1}^{J_{k|k-1}} [\omega_{k|k-1}^{(l)} N(h_k(x), R) \times N(m_{k|k-1}^{(l)}, P_{k|k-1}^{(l)})] / [\kappa_k(z) + P_d \sum_{l'=1}^{J_{k|k-1}} \omega_{k|k-1}^{(l')} \times \int N(h_k(\xi), R) N(m_{k|k-1}^{(l')}, P_{k|k-1}^{(l')}) d\xi]. \quad (19)$$

1) 漏检目标. 对于 $x_k^{(l)(i)} \sim N(m_{k|k-1}^{(l)}, P_{k|k-1}^{(l)})$,

有

$$\omega_k^{(l)} = (1 - P_d)\omega_{k|k-1}^{(l)}, \quad m_k^{(l)} = m_{k|k-1}^{(l)},$$

$$P_k^{(l)} = P_{k|k-1}^{(l)}.$$

2) 检测到的目标. 对于 $l = 1, 2, \dots, J_{k|k-1}$, 有:

QMC 粒子采样

$$x_k^{(l)(i)} \sim N(m_{k|k-1}^{(l)}, P_{k|k-1}^{(l)}), \quad i = 1, 2, \dots, N;$$

计算粒子权值

$$\bar{\omega}_k^{(l)(i)}(z) = N(h_k(x_k^{(l)(i)}), R);$$

估计参数

$$\omega_k^{(l)} = \frac{P_d \omega_{k|k-1}^{(l)} \frac{1}{N} \sum_{i=1}^N \bar{\omega}_k^{(l)(i)}(z)}{\kappa_k(z) + P_d \sum_{l'=1}^{J_{k|k-1}} \omega_{k|k-1}^{(l')} \frac{1}{N} \sum_{i=1}^N \bar{\omega}_k^{(l')(i)}(z)}, \quad (20)$$

$$m_k^{(l)} = \frac{\sum_{i=1}^N \bar{\omega}_k^{(l)(i)}(z) x_k^{(l)(i)}}{\sum_{i=1}^N \bar{\omega}_k^{(l)(i)}(z)}, \quad (21)$$

$$P_k^{(l)} = \frac{\sum_{i=1}^N \bar{\omega}_k^{(l)(i)}(z) [m_k^{(l)}(z) - x_k^{(l)(i)}][m_k^{(l)}(z) - x_k^{(l)(i)}]^T}{\sum_{i=1}^N \bar{\omega}_k^{(l)(i)}(z)}. \quad (22)$$

Step 4 修剪与合并高斯分量. 对权值较小的分量进行修剪剔除, 对距离相近的分量进行合并处理.

4 仿真实验与分析

本节对未知杂波环境下 4 种非线性算法进行性能仿真, 使用 OSPA 距离来评价多目标跟踪算法的跟踪精度, 其定义如下^[12]:

$$\bar{d}_p^{(c)}(\mathbf{X}, \mathbf{Z}) = \frac{1}{n} \left\{ \min_{\pi \in \Pi_n} \sum_{i=1}^m [d^{(c)}(x_i, z_{\pi(i)})^p + c^p(n-m)] \right\}^{1/p}. \quad (23)$$

其中: \mathbf{X} 和 \mathbf{Z} 为任意子集, 维数分别为 m 和 n , 且 $m \leq n$, $1 \leq p < \infty$; $d^{(c)}(x, z) = \min\{c, d(x, z)\}$, $c > 0$; Π_k 表示 $\{1, 2, \dots, k\}$ 的所有排列组成的集合. 若 $m > n$, 则有 $\bar{d}_p^{(c)}(\mathbf{X}, \mathbf{Z}) = \bar{d}_p^{(c)}(\mathbf{Z}, \mathbf{X})$. 定位误差和势误差分别定义如下:

$$\bar{d}_{p, \text{loc}}^{(c)}(\mathbf{X}, \mathbf{Z}) = \left(\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m d^{(c)}(x_i, z_{\pi(i)})^p \right) \right)^{1/p}, \quad (24)$$

$$\bar{d}_{p, \text{card}}^{(c)}(\mathbf{X}, \mathbf{Z}) = \left(\frac{c^p(n-m)}{n} \right)^{1/p}. \quad (25)$$

目标运动模型为线性模型, $x_k = [c_{x,k}, \dot{c}_{x,k}, c_{y,k}, \dot{c}_{y,k}]^T$ 为目标的状态向量. 其中: $(c_{x,k}, c_{y,k})$ 表示目标的位置, $(\dot{c}_{x,k}, \dot{c}_{y,k})$ 表示目标的速度, 时间 40 帧, 采样周期 $\Delta = 1$ s. 运动方程为

$$x_k = Fx_{k-1} + w_{k-1}. \quad (26)$$

其中: $F = \begin{bmatrix} 1 & \Delta & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \Delta \\ 0 & 0 & 0 & 1 \end{bmatrix}$; 过程噪声服从高斯分布, 即 $w_k \sim N(0, \sigma_w^2 I)$, $\sigma_w = 0.1$.

观测模型为非线性模型, 通过得到方位角和距离来对目标进行更新, 观测方程如下所示:

$$z_k = \begin{bmatrix} \arctan(c_{y,k}/c_{x,k}) \\ \sqrt{c_{x,k}^2 + c_{y,k}^2} \end{bmatrix} + v_k, \quad (27)$$

其中观测噪声服从 0 均值, 协方差为 R_k 的高斯分布, 即 $v_k \sim N(0, R_k)$, $R_k = \text{diag}([\sigma_\theta^2, \sigma_R^2]^T)$, $\sigma_\theta = \pi/180$, $\sigma_R = 0.1$.

新生目标随机集的 PHD 为

$$\gamma_k(x) = 0.2 \times [N(m_\gamma^{(1)}, P_\gamma) + N(m_\gamma^{(2)}, P_\gamma) + N(m_\gamma^{(3)}, P_\gamma)]. \quad (28)$$

其中: $m_\gamma^{(1)} = [40, 0, -40, 0]^T$, $m_\gamma^{(2)} = [-10, 0, 0, 0]^T$, $m_\gamma^{(3)} = [0, 0, -10, 0]^T$, $P_\gamma = \text{diag}([5 \ 1 \ 5 \ 1])$, 单位为 m.

在本文的仿真实验中, 真实的杂波平均数目为 50, 真实的杂波密度分布情况如下所示:

$$c(z_k) = 0.1u(z_k|\theta^1) + 0.3 \times [N(m_1, P_1) + N(m_2, P_2) + N(m_3, P_3)]. \quad (29)$$

其中: $\theta^1 = [-10, 90] \times [-40, 50]$, $m_1 = [-7, -20]^T$, $m_2 = [5, 40]^T$, $m_3 = [80, 20]^T$, $P_1 = \text{diag}([6 \ 6])$, $P_2 = \text{diag}([6 \ 6])$, $P_3 = \text{diag}([6 \ 6])$, 单位为 m.

目标的存活概率 $P_S = 0.98$, 传感器的检测概率 $P_d = 0.99$, OSPA 的距离参数 $p = 2$, $c = 100$, 高斯项的合并门限为 4, 高斯项的修剪门限为 10^{-3} , SMC-PHD 算法粒子数为 1000, GMP-PHD 算法及 QMC-GMP-PHD 粒子数为 100. 共进行 100 次 Monte Carlo 实验, 图 1 展示了目标的真实运动轨迹.




图 1 目标的真实运动轨迹

从图 1 可以看出, 目标 1 在第 1 s 出现, 在第 31 s 消失; 目标 2 在第 8 s 出现, 在第 31 s 消失; 目标 3 在第 12 s 时出现, 在第 38 s 消失; 目标 4 在第 26 s 出现, 在第 40 s 消失.




图 2 目标数估计

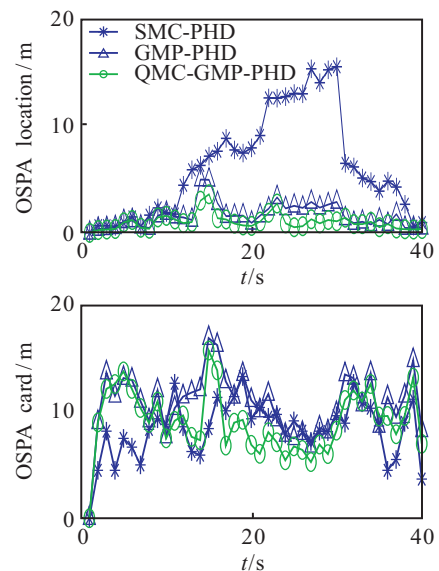


图 3 OSPA 位置误差与势误差

从图 2 可以看出, 在未知杂波环境下, EKF-PHD 算法在跟踪后半段时间里目标估计误差较大, 这是由

于 EKF-PHD 对系统的非线性函数泰勒级数展开式只取其一阶近似, 当其高阶项无法忽略时, 线性化会使系统产生较大的误差, 甚至导致滤波器难以稳定. 其余 3 种算法均能较准确地估计目标数目.

从图 3 可以看出, 在未知杂波环境下, SMC-PHD 算法虽然势误差最小但具有较大的位置误差, SMC-PHD 算法在聚类时所用的 k -means 方法只利用了粒子的空间信息, 因此会出现多个目标在同一类而无法区分的情况, 这导致了较大的目标状态估计误差. 而 QMC-GMP-PHD 算法和 GMP-PHD 算法利用高斯分布对目标强度进行有效的逼近, 避免了使用聚类方法, 因此均具有较小的位置误差和势误差.




图 4 OSPA 距离总误差

从图 4 可以看出, 就 OSPA 距离总体而言, QMC-GMP-PHD 算法比 GMP-PHD 算法性能好. 这是因为 QMC 方法比传统的 MC 方法产生的样本点分布更加均匀, 样本空间利用更加充分, 所以误差较小.

表 1 4 种算法的 OSPA 距离及所耗时间对比

	EKF-PHD	SMC-PHD	GMP-PHD	QMC-GMP-PHD
OSPA/s	19.594 1	12.006 1	10.941 2	8.232 6
T/s	3.419 5	43.536 1	27.963 0	51.514 2

从表 1 可以看出: EKF-PHD 算法所耗时间最少, 但跟踪精度最差; GMP-PHD 算法结合了 SMC-PHD 算法和 GM-PHD 算法的优点, 在保证跟踪精度优于 SMC-PHD 算法的同时, 不需要重采样, 减低了算法的复杂度, 减少了计算时间; QMC-GMP-PHD 算法所需时间最多, 这是因为该算法采用的粒子是拟蒙特卡罗样本点, 而产生这些样本点需占用一定时间, 但该算法可以更均匀地逼近待估计状态的后验概率密度, 因此该算法的跟踪性能优于 GMP-PHD 算法. 通过上面的实验与分析, QMC-GMP-PHD 算法相对于其他算法跟踪性能更稳定.

5 结 论

相对于简单的均匀分布杂波环境, 复杂且未知的杂波环境对滤波器的稳定性有了更高的要求, 常用的滤波器在杂波空间分布为均匀分布的情况下可能有较好的跟踪性能, 但在复杂且未知的杂波环境下, 其缺陷将会放大, 甚至在一定情况下出现发散. 本文提出了一种基于 QMC 的未知杂波环境下的 GMP-PHD 算法, 该算法使用有限混合模型拟合杂波空间分

布, 从而能够得到精确的杂波估计. 同时, 该算法在高斯混合框架下利用 QMC 方法进行积分近似计算, 提高了目标跟踪性能. 但由于该算法在产生 QMC 样本点时需占用一定时间, 所耗时间较长. 仿真实验验证了本文所提出算法的跟踪性能.

参考文献(References)

- [1] Mahler R. Multi-target Bayes filtering via first-order Multi-target moments[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 16(2): 1152-1178.
- [2] Mahler R. Statistical multisource multitarget information fusion[M]. Norwood, MA: Artech House, 2007: 587-595.
- [3] Lian F, Han C Z, Liu W F. Estimating unknown clutter intensity for PHD filter[J]. IEEE Trans on Aerospace and Electronic Systems, 2010, 46(4): 2066-2078.
- [4] Mahler R, Vo B T, Vo B N. CPHD filtering with unknown clutter rate and detection profile[J]. IEEE Trans on Signal Processing, 2011, 59(8): 3497-3513.
- [5] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter[J]. IEEE Trans on Signal Processing, 2006, 54(11): 4091-4104.
- [6] 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.
- [7] 张俊根, 姬红兵. 高斯混合粒子 PHD 滤波被动测角多目标跟踪[J]. 控制与决策, 2011, 26(3): 413-417. (Zhang J G, Ji H B. Gaussian mixture particle probability hypothesis density based passive bearings-only multi-target tracking[J]. Control and Decision, 2011, 26(3): 413-417.)
- [8] Kalyan B, Balasuriya A, Wijesoma S. Multiple targets tracking in underwater sonar images using particle-PHD filter[C]. The 16th IEEE Int Conf on ISAF. Singapore, 2006: 1-5.
- [9] Bartfai P, Tomko J. Point processes and queuing problems[M]. NorthHolland: Amsterdam, 1981: 285-294.
- [10] Legrand X, Xemard A, Fleury G, et al. A quasi-Monte carlo integration method applied to the computation of the pollaczek integral[J]. IEEE Trans on Power Delivery, 2008, 23(3): 1527-1534.
- [11] 张俊根, 姬红兵. 高斯混合粒子 CPHD 滤波被动测角多目标跟踪[J]. 控制理论与应用, 2011, 28(1): 46-52. (Zhang J G, Ji H B. Gaussian mixture particle cardinalized probability hypothesis density based passive bearings-only multi-target tracking[J]. Control Theory & Applications, 2011, 28(1): 46-52.)
- [12] 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: 齐 霖)