

一种粒子势概率假设密度滤波纯方位多目标跟踪算法

张俊根[†]

(北方民族大学 电气信息工程学院, 宁夏 银川 750021)

摘要: 针对基于势概率假设密度算法(CPHD)的纯方位多目标跟踪, 提出一种新型的多传感器粒子CPHD滤波算法. 该算法通过分析混合线性/非线性状态模型的结构信息, 结合粒子滤波(PF)与卡尔曼滤波(KF)对各个目标的状态进行预测与估计, 运用Mean-Shift方法提取概率假设密度的峰值作为目标状态估计值, 并对算法复杂度进行了分析. 仿真结果表明, 算法可改善目标跟踪效果.

关键词: 纯方位多目标跟踪; 势概率假设密度; 粒子滤波; 多传感器; 均值漂移

引用格式: 张俊根. 一种粒子势概率假设密度滤波纯方位多目标跟踪算法. 控制理论与应用, 2020, 37(6): 1319 – 1325

DOI: 10.7641/CTA.2019.90437

A particle cardinalized probability hypothesis density filtering algorithm for bearings-only multi-target tracking

ZHANG Jun-gen[†]

(School of Electrical and Information Engineering, North Minzu University, Yinchuan Ningxia 750021, China)

Abstract: Aiming at bearings-only multi-target tracking based on cardinalized probability hypothesis density (CPHD) filter and Kalman filter to predict and estimate the states of multiple targets to enhance the estimating performance of the PHD and cardinality distribution. The target state estimates are extracted by utilizing the kernel density estimation theory and mean-shift method. In addition, the complexity of the algorithm is analyzed. Simulation results are presented to demonstrate the improved performance of the proposed filtering algorithms.

Key words: bearings-only multi-target tracking; cardinalized probability hypothesis density; particle filter; multi-sensor; mean-shift

Citation: ZHANG Jun-gen. A particle cardinalized probability hypothesis density filtering algorithm for bearings-only multi-target tracking. *Control Theory & Applications*, 2020, 37(6): 1319 – 1325

1 引言

在纯方位多目标跟踪问题中, 由于目标信息的不确定性, 目标数目每个时刻都会发生变化. 此外, 目标运动建模与量测建模坐标系转换过程中以及被动传感器自身物理特性造成的模型非线性问题, 以及量测信息的不完备性, 均给目标跟踪带来了很大困难. 如何根据纯方位量测信息对多个目标进行实时、有效地跟踪, 一直是学术界和工程应用领域的研究热点和难点问题^[1-2].

相对于其他传统的多目标跟踪算法, 基于随机集理论的概率假设密度 (probability hypothesis density, PHD) 滤波算法, 可以将复杂的多目标状态空间的运算转换为单目标状态空间内的运算, 有效避免了多目

标跟踪中复杂的数据关联组合问题^[3-6]. 而势概率假设密度 (cardinalized probability hypothesis density, CPHD) 滤波算法, 能充分利用多目标密度的信息, 并且不需要限定目标数目服从泊松分布, 受到了更广泛的关注, 许多学者开展了相关的研究^[7-12]. 文献[13]基于著名的Faàdi Bruno行列式, 推导了CPHD模型中的衍生目标广义势分布预测方程, 提出了一种通用势分布预测方程的可处理递推计算方法. 文献[14]研究了基于最适高斯近似和强跟踪的多模型伽马高斯逆威夏特—概率假设密度滤波的群跟踪算法, 能有效处理群目标的合并和衍生情况. 文献[15]针对扩展目标跟踪问题, 提出了一种扩展的标记箱粒子CPHD滤波器, 可以改善目标数目估计的精度, 同时能获得目标

收稿日期: 2019-06-10; 录用日期: 2019-12-31.

[†]通信作者. E-mail: zhang_jungen@sina.com.

本文责任编辑: 潘泉.

学校一般科研项目(2019XYZDX04)资助.

Supported by the General Scientific Research Project of the School (2019XYZDX04).

的轨迹. 文献[16]针对多传感器多目标跟踪中的分布式传感器控制问题, 利用随机有限集进行建模, 提出一种基于多目标战术重要性评估的多传感器控制策略.

本文针对混合线性/非线性目标状态模型, 将CPHD和Rao-Blackwellised的思想^[17]有效结合起来, 提出一种新的混合粒子滤波CPHD实现算法, 将目标状态划分为线性和非线性这两种结构信息, 线性状态信息利用卡尔曼滤波(Kalman filter, KF), 非线性状态信息利用粒子滤波(particle filter, PF), 对多目标的概率假设密度和势分布进行预测与估计, 再运用Mean-Shift方法提取目标状态估计值, 并对算法的复杂度进行了推导和分析, 最后, 将算法应用到多传感器纯方位目标跟踪场景中, 仿真实验结果表明, 所提出的算法能够实现目标数和目标状态的准确估计, 改善目标跟踪精度.

2 问题描述

2.1 随机集纯方位多目标跟踪问题

考虑下面的被动多传感器纯方位多目标跟踪系统:

$$x_{t,k+1} = Fx_{t,k} + Gw_{t,k}, \quad (1)$$

$$z_{m,k}^o = \begin{cases} h^o(x_{t,k}) + v_k^o, & \varsigma_{m,k} = t, \\ \text{杂波}, & \varsigma_{m,k} = 0, \end{cases} \quad (2)$$

其中: $x_{t,k} = [x_t(k) \quad \dot{x}_t(k) \quad y_t(k) \quad \dot{y}_t(k)]^T$ 表示目标 t 在 k 时刻的状态; $w_{t,k}$ 为相互独立的零均值、协方差为 Q_t 的高斯噪声; $\{z_{m,k}^o, m = 1, \dots, M_k\}$ 为传感器 o 在 k 时刻测得的目标方位角集合, 其中包含有 C_k 个杂波; $h^o(x_{t,k}) = \arctan \frac{y_t(k) - y^o}{x_t(k) - x^o}$, (x^o, y^o) 是传感器 o 的位置; $\varsigma_{m,k}$ 表示与量测 m 关联的目标指示数; 量测噪声 v_k^o 为零均值、协方差为 R^o 的高斯噪声, 并且 v_k^o 与 $w_{t,k}$ 互不相关. 本文利用集中式融合策略^[9], 通过增加量测向量的维数, 将多传感器测得的目标方位角直接进行合并处理.

在随机集多目标跟踪问题中, 多目标的状态和传感器量测可以建模为随机有限集的形式^[3], 即 $X_k = \{x_{k,1}, \dots, x_{k,N_k}\} \in \mathbf{F}(X)$ 为目标状态集, $Z_k = \{z_{k,1}, \dots, z_{k,M_k}\} \in \mathbf{F}(Z)$ 为量测集, 其中: $\mathbf{F}(X)$ 和 $\mathbf{F}(Z)$ 分别是 X 和 Z 上的所有有限子集的集合; N_k 及 M_k 分别表示 k 时刻目标个数及量测个数, 其中某些量测可来源于杂波.

若 $k-1$ 时刻状态随机集为 X_{k-1} , 则 k 时刻的状态随机集 X_k 可表示为

$$X_k = \left\{ \bigcup_{x \in X_{k-1}} S_{k|k-1}(x) \right\} \cup \left(\bigcup_{x \in X_{k-1}} B_{k|k-1}(x) \right) \cup \Gamma_k, \quad (3)$$

其中: Γ_k 表示 k 时刻新生目标状态随机集; $B_{k|k-1}(x)$

表示 k 时刻从目标 x 衍生分裂出来的目标状态随机集; $S_{k|k-1}(x)$ 表示从 $k-1$ 时刻到 k 时刻仍然存活的目标状态随机集.

目标的量测随机集 Z_k 可表示为

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

其中: K_k 表示虚警或杂波量测随机集; $\Theta_k(x)$ 表示源于真实目标的量测随机集.

2.2 CPHD滤波

相比于PHD滤波, CPHD滤波联合估计目标强度和势分布(即目标数 n 的概率分布), 可以改善状态估计性能^[7].

令 $D_{k|k-1}$ 和 $p_{k|k-1}$ 分别表示 $k-1$ 时刻预测多目标强度和势分布, D_k 和 p_k 表示 k 时刻后验多目标强度和势分布, 则CPHD迭代公式为

$$p_{k|k-1}(n) = \sum_{j=0}^n p_{\Gamma,k}(n-j) \prod_{k|k-1} [D_{k-1}, p_{k-1}](j), \quad (5)$$

$$D_{k|k-1}(x) = \int P_{S,k}(\zeta) \varphi_{k|k-1}(x|\zeta) D_{k-1}(\zeta) d\zeta + \gamma_k(x), \quad (6)$$

$$p_k(n) = \frac{\gamma_k^0[D_{k|k-1}, Z_k](n) p_{k|k-1}(n)}{\langle \gamma_k^0[D_{k|k-1}, Z_k], p_{k|k-1} \rangle}, \quad (7)$$

$$D_k(x) = [1 - P_{D,k}(x)] \frac{\langle \gamma_k^1[D_{k|k-1}, Z_k], p_{k|k-1} \rangle}{\langle \gamma_k^0[D_{k|k-1}, Z_k], p_{k|k-1} \rangle} D_{k|k-1}(x) + \sum_{z \in Z_k} \Psi_{k,z}(x) \frac{\langle \gamma_k^1[D_{k|k-1}, Z_k/\{z\}], p_{k|k-1} \rangle D_{k|k-1}(x)}{\langle \gamma_k^0[D_{k|k-1}, Z_k], p_{k|k-1} \rangle}, \quad (8)$$

其中:

$$\Pi_{k|k-1}[D, p](j) = \sum_{l=j}^{\infty} C_j^l \frac{\langle P_{S,k}, D \rangle^j \langle 1 - P_{S,k}, D \rangle^{l-j}}{\langle 1, D \rangle^l} p(l), \quad (9)$$

C_j^l 是二项式系数, $\langle \cdot, \cdot \rangle$ 表示内积运算, $p_{\Gamma,k}(\cdot)$ 是新生目标集的势分布, $\gamma_k(\cdot)$ 是新生目标集的数量, $P_{S,k}(\zeta)$ 是目标存活概率,

$$\gamma_k^u[D, Z](n) = \sum_{j=0}^{\min(|Z|, n)} (|Z| - j)! p_{K,k}(|Z| - j) \times P_{j+u}^n \frac{\langle 1 - P_{D,k}, D \rangle^{n-(j+u)}}{\langle 1, D \rangle^n} e_j(\Xi_k(D, Z)), \quad (10)$$

P_j^n 是排列系数, $\Psi_{k,z}(x) = \frac{\langle 1, \kappa_k \rangle}{\kappa_k(z)} g_k(z|x) P_{D,k}(x)$, $\Xi(D, Z) = \{\langle D, \Psi_{k,z} \rangle : z \in Z\}$, $e_j(\cdot)$ 是初等对称函数, Z_k 是量测集, $p_{K,k}(\cdot)$ 表示杂波的势分布, $\kappa_k(\cdot)$ 为杂波量测的强度函数, $P_{D,k}(x)$ 为目标检测概率, $\varphi_{k|k-1}(x|\zeta)$ 和 $g_k(z|x)$ 分别表示目标转移密度和量测

似然, 假定每个目标系统模型都为高斯的, 并且目标状态转移函数及量测函数分别用 $f_{k-1}(\cdot)$ 及 $h_k(\cdot)$ 表示, 则

$$\begin{aligned} \varphi_{k|k-1}(x|\zeta) &= N(x; f_{k-1}(\zeta), Q_{k-1}), \\ g_k(z|x) &= N(z; h_k(x), R_k), \end{aligned} \quad (11)$$

其中: $N(x; m, P)$ 表示均值为 m 、协方差为 P 的高斯密度, Q_{k-1} 是过程噪声协方差, R_k 是量测噪声协方差.

3 多目标跟踪粒子CPHD滤波

在很多应用中, 目标状态空间包含线性和非线性两部分, 针对这类混合线性/非线性状态模型, 利用贝叶斯原理将线性状态从系统模型中分离出来, 并结合卡尔曼滤波器和粒子滤波器对目标的线性状态和非线性状态分别进行估计^[17], 本文结合RBPf的思想, 估计出多目标PHD和势分布, 由于多目标跟踪的复杂性, 使得迭代估计所得的PHD形状很不规则, 运用Mean-Shift方法, 可以提取出精确的密度函数峰值位置^[18], 可以提高目标跟踪精度, 减小估计方差.

3.1 算法描述

假定目标不发生衍生, 各个目标的动态系统同时存在线性和非线性的状态, 且噪声是加性的, 那么目标滤波模型可以表示为线性和非线性的形式:

$$x_k^{\text{nl}} = f_{k-1}(x_{k-1}^{\text{nl}}) + A_{k-1}^{\text{nl}} x_{k-1}^{\text{l}} + B_{k-1}^{\text{nl}} w_{k-1}^{\text{nl}}, \quad (12)$$

$$x_k^{\text{l}} = A_{k-1}^{\text{l}} x_{k-1}^{\text{l}} + B_{k-1}^{\text{l}} w_{k-1}^{\text{l}}, \quad (13)$$

$$z_k = h_k(x_k^{\text{nl}}) + v_k, \quad (14)$$

其中: x_k^{nl} 和 x_k^{l} 分别表示目标在 k 时刻的非线性和线性状态, 且 $x_k = [x_k^{\text{nl}} \ x_k^{\text{l}}]^{\text{T}}$; 过程噪声 w_k 与量测噪声 v_k 分别满足如下关系:

$$w_k = \begin{bmatrix} w_k^{\text{nl}} \\ w_k^{\text{l}} \end{bmatrix} \sim N \left(0, \begin{pmatrix} Q_k^{\text{nl}} & S_k \\ S_k^{\text{T}} & Q_k^{\text{l}} \end{pmatrix} \right), \quad (15)$$

$$v_k \sim N(0, R_k), \quad (16)$$

且 w_k 与 v_k 相互独立.

假设 $x_0^{\text{l}} \sim N(x_{0|0-1}^{\text{l}}, P_{0|0-1}^{\text{l}})$, 且 x_0^{nl} 的分布已知, 则式(12)–(14)所描述的模型可以写为

$$x_k^{\text{l}} = A_{k-1}^{\text{l}} x_{k-1}^{\text{l}} + B_{k-1}^{\text{l}} w_{k-1}^{\text{l}}, \quad (17)$$

$$\bar{z}_k = A_{k-1}^{\text{nl}} x_{k-1}^{\text{l}} + B_{k-1}^{\text{nl}} w_{k-1}^{\text{nl}}, \quad (18)$$

其中 $\bar{z}_k = z_k - h_k(x_k^{\text{nl}})$. 如果把 \bar{z}_k 当成是量测值, 而 x_k^{l} 看做为状态, 式(17)和式(18)所描述的系统是线性高斯的, 可以利用KF对 x_k^{l} 进行最优估计.

对于非线性状态 x_k^{nl} , 则运用粒子滤波的方法进行估计. 由式(12)可以看出, 从 $k-1$ 时刻预测到 k 时刻的

粒子服从高斯分布, 即

$$p(x_k^{\text{nl}} | x_{k-1}^{\text{nl}}) = N(f_{k-1}(x_{k-1}^{\text{nl}}) + A_{k-1}^{\text{nl}} \hat{x}_{k-1|k-2}^{\text{l}}, R^{\text{nl}}), \quad (19)$$

其中:

$$R^{\text{nl}} = A_{k-1}^{\text{nl}} P_{k-1|k-2}^{\text{l}} (A_{k-1}^{\text{nl}})^{\text{T}} + B_{k-1}^{\text{nl}} Q_{k-1}^{\text{nl}} (B_{k-1}^{\text{nl}})^{\text{T}}, \quad (20)$$

$\hat{x}_{k-1|k-2}^{\text{l}}$ 和 $P_{k-1|k-2}^{\text{l}}$ 分别表示线性状态的一步预测值及其协方差.

算法由预测和更新两部分构成:

预测: 假定已知 $k-1$ 时刻的多目标后验概率假设密度 D_{k-1} 和势分布 p_{k-1} , 并且 D_{k-1} 可以用一组带权值的粒子 $\{\omega_{k-1}^{(i)}, x_{k-1}^{(i)}\}_{i=1}^{L_{k-1}}$ 来表达:

$$D_{k-1}(x) = \sum_{i=1}^{L_{k-1}} \omega_{k-1}^{(i)} \delta(x - x_{k-1}^{(i)}). \quad (21)$$

目标状态包含非线性和线性两部分, 即 $x_{k-1}^{(i)} = [x_{k-1}^{\text{nl},(i)} \ \hat{x}_{k-1|k-2}^{\text{l},(i)}]^{\text{T}}$. 多目标随机集的预测PHD为

$$\begin{aligned} D_{k|k-1}(x) &= \\ &\sum_{i=1}^{L_{k-1}} P_S \omega_{k-1}^{(i)} f_{k|k-1}(x | x_{k-1}^{\text{nl},(i)}, \hat{x}_{k-1|k-2}^{\text{l},(i)}) + \gamma_k(x). \end{aligned} \quad (22)$$

为了得到 $D_{k|k-1}$ 的粒子近似, 对式(22)中的每一项都运用Rao-Blackwellised方法进行混合滤波. 首先, 对于存活目标, 由式(19)预测非线性状态粒子

$$\begin{aligned} x_k^{\text{nl},(i)} &\sim N(f_{k-1}(x_{k-1}^{\text{nl},(i)}) + A_{k-1}^{\text{nl}} \hat{x}_{k-1|k-2}^{\text{l},(i)}, R^{\text{nl},(i)}), \\ &i = 1, \dots, L_{k-1}. \end{aligned} \quad (23)$$

线性状态粒子可由KF方程获得

$$\begin{aligned} \hat{x}_{k|k-1}^{\text{l},(i)} &= A_{k-1}^{\text{l}} [\hat{x}_{k-1|k-2}^{\text{l},(i)} + G_{k-1}^{(i)} (x_k^{\text{nl},(i)} - \\ &f_{k-1}(x_{k-1}^{\text{nl},(i)} - A_{k-1}^{\text{nl}} \hat{x}_{k-1|k-2}^{\text{l},(i)})], \end{aligned} \quad (24)$$

其中

$$\begin{aligned} G_{k-1}^{(i)} &= P_{k-1|k-2}^{\text{l},(i)} (A_{k-1}^{\text{l}})^{\text{T}} [A_{k-1}^{\text{l}} P_{k-1|k-2}^{\text{l},(i)} (A_{k-1}^{\text{l}})^{\text{T}} + \\ &B_{k-1}^{\text{l}} Q_{k-1}^{\text{l}} (B_{k-1}^{\text{l}})^{\text{T}}]^{-1}. \end{aligned} \quad (25)$$

粒子 $\hat{x}_{k|k-1}^{\text{l},(i)}$ 的协方差为

$$\begin{aligned} P_{k|k-1}^{\text{l},(i)} &= \\ &A_{k-1}^{\text{l}} (P_{k-1|k-2}^{\text{l},(i)} - G_{k-1}^{(i)} A_{k-1}^{\text{l}} P_{k-1|k-2}^{\text{l},(i)}) (A_{k-1}^{\text{l}})^{\text{T}} + \\ &B_{k-1}^{\text{l}} Q_{k-1}^{\text{l}} (B_{k-1}^{\text{l}})^{\text{T}}. \end{aligned} \quad (26)$$

其次, 对于新生目标, 假设 $\gamma_k(x) = \gamma_k^{\text{nl}}(x_k^{\text{nl}}) \gamma_k^{\text{l}}(x_k^{\text{l}})$, 选取 $\gamma_k^{\text{nl}}(x_k^{\text{nl}})$ 为重要性密度函数, 并抽取粒子 $x_k^{\text{nl},(i)}$, $i = L_{k-1} + 1, \dots, L_{k-1} + J_k$, KF的初始值设为 $\{\hat{x}_{k|k-1}^{\text{l},(i)}, P_{k|k-1}^{\text{l},(i)}\}_{i=L_{k-1}+1}^{L_{k-1}+J_k} = \{\hat{x}_{0|0-1}^{\text{l}}, \bar{P}_{0|0-1}^{\text{l}}\}$.

计算粒子的权值

$$\omega_{k|k-1}^{(i)} = \begin{cases} P_{S,k} \omega_{k-1}^{(i)}, & i = 1, \dots, L_{k-1}, \\ \frac{1}{J_k}, & i = L_{k-1} + 1, \dots, L_{k-1} + J_k. \end{cases} \quad (27)$$

势分布 $p_{k|k-1}(n)$ 通过式(5)来计算.

更新: 已知 $k-1$ 时刻的多目标预测概率假设密度 $D_{k|k-1}$ 和势分布 $p_{k|k-1}$, 并且 $D_{k|k-1}$ 可由粒子 $\{\omega_{k|k-1}^{(i)}, x_k^{(i)}\}_{i=1}^{L_{k-1}+J_k}$ 来描述. 运用KDE理论^[19]可得多目标随机集的更新PHD:

$$D_k(x) = \sum_{i=1}^{L_{k-1}+J_k} \omega_k^{(i)} K_{\sigma_d}^x(x - x_k^{(i)}), \quad (28)$$

其中: $x_k^{(i)} = [x_k^{nl(i)} \hat{x}_{k|k-1}^{1(i)}]^T$, $K_{\sigma_d}^x$ 是Parzen-Rosenblatt核函数^[20], σ_d 是核宽.

在式(28)中, 权值 $\omega_k^{(i)}$ 计算如下:

$$\begin{aligned} \omega_k^{(i)} = & \frac{(1 - P_d) \langle \gamma_k^1 [D_{k|k-1} Z_k], p_{k|k-1} \rangle}{\langle \gamma_k^0 [D_{k|k-1} Z_k], p_{k|k-1} \rangle} \omega_{k|k-1}^{(i)} + \\ & \sum_{z \in Z_k} \Psi_{k,z}(x_k^{(i)}) \frac{\langle \gamma_k^1 [D_{k|k-1} Z_k / \{z\}], p_{k|k-1} \rangle}{\langle \gamma_k^0 [D_{k|k-1} Z_k], p_{k|k-1} \rangle} \omega_{k|k-1}^{(i)}. \end{aligned} \quad (29)$$

从式(14)可以看出, 在给定 x_k^{nl} 的情况下, 量测 z_k 与 x_k^1 是相互独立的, 因此, 式(29)中的 $\Psi_{k,z}(x_k^{(i)})$ 计算式可以简化为

$$\begin{aligned} \Psi_{k,z}(x_k^{(i)}) = & \frac{P_d \langle 1, \kappa_k \rangle}{\kappa_k(z)} g_k(z | x_k^{nl(i)}, x_k^{1(i)}) = \\ & \frac{P_d \langle 1, \kappa_k \rangle}{\kappa_k(z)} g_k(z | x_k^{nl(i)}). \end{aligned} \quad (30)$$

势分布 $p_k(n)$ 利用式(7)计算.

目标数的估计为

$$n_k = \sum_{j=1}^{\infty} j p_k(j). \quad (31)$$

利用Mean-Shift算法, 提取密度函数所有的峰值位置. 对于粒子 $x_k^{(i)}$, 其Mean-Shift向量为

$$m(x_k^{(i)}) = \frac{\sum_{j=1}^{L_{k-1}+J_k} \omega_k^{(j)} K_{\sigma_d}^x(x_k^{(i)} - x_k^{(j)}) x_k^{(j)}}{\sum_{j=1}^{L_{k-1}+J_k} \omega_k^{(j)} K_{\sigma_d}^x(x_k^{(i)} - x_k^{(j)})} - x_k^{(i)}. \quad (32)$$

式(32)表明, 向量 $m(x_k^{(i)})$ 指向最大一致变化的点, 即梯度的方向. 算法是以 $x_k^{(i)}$ 为起始点, 然后移动到粒子最密集的位置, 即 $x_k^{(i)} \rightarrow x_k^{(i)} + m(x_k^{(i)})$, 经过几步迭代后, 可以得到 $D_k(x)$ 的峰值位置, 并选取其中 n_k 个较大的作为目标状态估计值.

本文所提算法:

1) 给定 D_{k-1} 和 p_{k-1} , $\{x_{k-1}^{nl(i)}\}_{i=1}^{L_{k-1}}$, $\{\hat{x}_{k-1}^{1(i)}\}_{i=1}^{L_{k-1}}$, $P_{k|k-1}^{1(i)} = \{\bar{x}_{k|k-1}^1, \bar{P}_{k|k-1}^1\}$;

预测:

2) 对于 $i = 1, \dots, L_{k-1}$, 利用式(23)计算 $x_k^{nl(i)}$;

3) 利用式(25)计算增益参数 $G_{k-1}^{(i)}$;

4) 利用式(24)(26)计算 $\hat{x}_{k|k-1}^{1(i)}$ 及其协方差 $P_{k|k-1}^{1(i)}$;

5) 抽取 $\{x_k^{nl(i)}\}_{i=L_{k-1}+1}^{L_{k-1}+J_k} \sim \gamma_k^{nl}(x_k^{nl})$, 并初始化 $\{x_{k|k-1}^1, P_{k|k-1}^1\}_{i=L_{k-1}+1}^{L_{k-1}+J_k} = \{\bar{x}_{0|-1}^1, \bar{P}_{0|-1}^1\}$;

6) 利用式(27)计算预测权值 $\omega_{k|k-1}^{(i)}$;

7) 根据式(5)预测势分布 $p_{k|k-1}$.

更新:

8) 利用式(29)计算权值 $\omega_k^{(i)}$;

9) 根据式(28)估计目标强度函数 D_k ;

10) 利用式(7)更新势分布 p_k , 并利用式(31)估计目标数 n_k ;

11) 利用式(32)计算Mean-Shift向量 $m(x_k^{(i)})$;

12) 移动粒子 $x_k^{(i)} \rightarrow x_k^{(i)} + m(x_k^{(i)})$, 使得所有粒子收敛到 D_k 的局部极大值处, 并选取 n_k 个权值较大的峰值作为目标状态估计值;

13) 对粒子集 $\{x_k^{nl(i)}, \omega_k^{(i)} / n_k\}_{i=1}^{L_{k-1}+J_k}$ 进行重采样, 获得新粒子 $\{x_k^{nl(i)}, \omega_k^{(i)}\}_{i=1}^{L_k}$.

3.2 算法复杂度分析

这一小节引入等效浮点运算(equivalent flop, EF)测度来分析算法的复杂度^[21], 一个运算的EF复杂度定义为浮点运算(flops)的数量, 这里一次浮点运算表示两个浮点数的一个加、减、乘或除. 从算法描述看出, 算法的计算量主要体现在更新步骤, 其中包括漏检目标和检测目标的粒子似然比的计算^[8]、粒子Mean-Shift向量的计算以及重采样的计算, 对于每次时间迭代, 算法更新步骤总的加法或乘法次数可以表示为量测数 M_k 的一个多项式

$$\begin{aligned} \text{EF}_{\text{update}} = & M_k^3 + \frac{11}{2} M_k^2 + \left[\frac{1}{2} L_k^2 + (c_1 + \frac{5}{2}) L_k\right] M_k + \\ & (N_{\max} + 1) \left(\frac{4}{3} N_{\max}^2 + \frac{25}{6} N_{\max} - 10\right) + \\ & (c_2 L_k + c_3) L_k = \\ & O(M_k^3 + L_k^2 M_k + N_{\max}^3), \end{aligned} \quad (33)$$

其中: L_k 表示 k 时刻的粒子数, N_{\max} 为最大目标数, 系数 c_1, c_2, c_3 分别用来等效高斯似然、Mean-Shift向量以及重采样的计算复杂度.

从式(33)可以看出, 在给定最大目标数 N_{\max} 的情况下: 1) 随着量测数的增大, 算法复杂度呈三次方增长; 2) 随着粒子数的增大, 算法复杂度呈二次方增长.

利用门选技术, 删除一些不相关的量测, 可以减小算法的计算量.

量测的影响, 响应较快.

4 仿真实验与分析

对所提算法进行性能仿真实验, 利用目标数估计的统计值和OSPA距离评价算法的性能, 并与PF-CPHD, RBPF-PHD这两种滤波算法作对比.

系统模型如式(1)–(2), 其中目标数随时间变化, 假设有3个被动传感器对目标进行纯方位跟踪, 假定各传感器的量测数据已完成配准及关联. 系统具体参数设置如下:

采样周期 $T_s = 1\text{ s}$; 目标系统矩阵

$$F = \text{diag}\{\{\tilde{F} \ \tilde{F}\}\}, \tilde{F} = \begin{pmatrix} 1 & T_s \\ 0 & 1 \end{pmatrix},$$

$$G = \begin{pmatrix} T_s^2/2 & T_s & 0 & 0 \\ 0 & 0 & T_s^2/2 & T_s \end{pmatrix}^T;$$

过程噪声 $Q = \text{diag}\{[0.01 \ 0.01]\}$; 3个传感器位置分别为 $(-8, -10)\text{ km}$, $(8, -10)\text{ km}$ 和 $(8, 13.86)\text{ km}$.

被动传感器对目标只能测得方位角, 量测函数

$$h(x_{t,k}) = \arctan \frac{y_t(k) - y^o}{x_t(k) - x^o},$$

其中: (x^o, y^o) 是传感器位置, 量测噪声标准差都设为 $\sigma_\beta = 0.01$, 目标存活概率 $P_s = 0.99$, 检测概率 $P_d = 0.98$.

新生目标随机集**的强度函数为**

$$\gamma_k(x) = 0.2 \times [N(m_\gamma^{(1)}, P_\gamma) + N(m_\gamma^{(2)}, P_\gamma) + N(m_\gamma^{(3)}, P_\gamma) + N(m_\gamma^{(4)}, P_\gamma)], \quad (34)$$

其中:

$$\begin{aligned} m_\gamma^{(1)} &= [-3.5 \ 0 \ -2 \ 0]^T, \quad m_\gamma^{(2)} = [3 \ 0 \ 0 \ 0]^T, \\ m_\gamma^{(3)} &= [-3.5 \ 0 \ 2 \ 0]^T, \quad m_\gamma^{(4)} = [-5 \ 0 \ 5 \ 0]^T, \\ P_\gamma &= \{[4 \ 2 \ 4 \ 2]\}. \end{aligned}$$

杂波均匀分布于量测空间, 数目服从参数为 $\lambda = 3$ 的泊松分布; OSPA距离参数 $p = 2, c = 100$; 粒子数500, 仿真次数为100.

图1为多目标在 x 和 y 方向上的运动轨迹, 图2为各算法目标数估计均值, 图3给出了各算法目标数估计标准差. 可以看到, PF-CPHD, RBPF-PHD和本文算法的目标数估计都能收敛到真实值, RBPF-PHD滤波算法对目标数的估计能较快收敛; 本文算法对目标数估计的方差最小, 表明所提算法的目标数估计要更加可靠. 另外, 从图2可知, 当目标数发生变化时, PF-CPHD和本文算法对目标数的估计具有较大的延时, 而RBPF-PHD滤波算法的目标数估计延时较小, 原因主要在于RBPF-PHD滤波算法的目标数估计方差较大, 估计的结果不可靠, 导致滤波器更容易受新来




图 1 实际的目标运动轨迹

Fig. 1 The true target tracks in x and y -coordinates

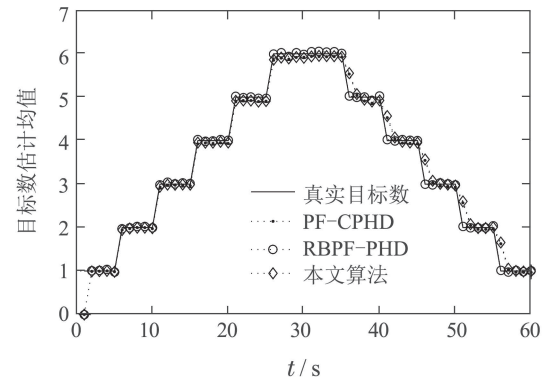


图 2 目标数估计均值

Fig. 2 The estimated mean of cardinality




图 3 目标数估计标准差

Fig. 3 The estimated STD of cardinality

图4给出了3种算法目标跟踪的OSPA距离. 可以看出, 在多数时刻, 本文算法的跟踪误差比PF-CPHD和RBPF-PHD滤波算法都要小; 在目标数发生变化时, RBPF-PHD算法的跟踪精度要好于另外两种算法, 主要原因是PF-CPHD和本文算法在目标数发生变化时, 对目标数的估计存在较大的延时, OSPA距离惩罚的程度比RBPF-PHD滤波算法要大; 而在目标数稳定以后, 本文算法的OSPA距离相对较小.




图4 目标跟踪的OSPA距离

Fig. 4 100 MC average OSPA distance

图5给出了这3种算法的平均OSPA距离随粒子数变化的对比.可以看出,本文算法的平均OSPA距离比PF-CPHD和RBPF-PHD算法都要小;当粒子数由300增大到500时,RBPF-PHD滤波算法的平均OSPA距离有较大的改善,当粒子数继续增大时,性能改善不明显;PF-CPHD和本文算法随着粒子数的增大,平均OSPA距离都将减小.当然,随着粒子数的增多,各算法的运算时间也将增大.图6给出了3种算法平均运算时间对比,本文算法由于要联合估计目标强度及目标数的概率分布,并且运用了Mean-Shift算法进行状态提取,运算量较大.

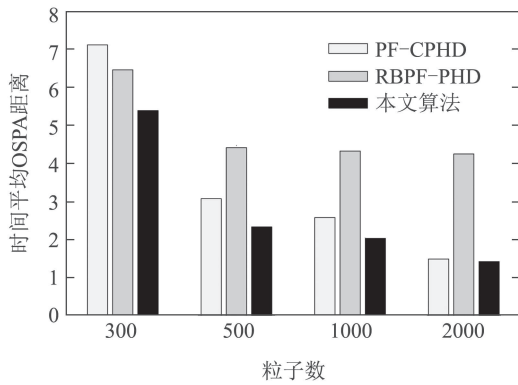


图5 各算法的平均OSPA距离对比

Fig. 5 Comparison of the mean of MC average OSPA distance

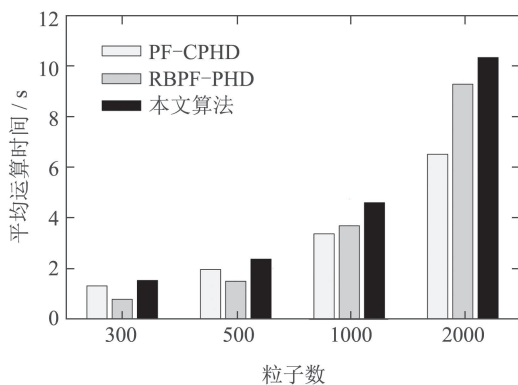


图6 各算法的平均运算时间对比

Fig. 6 Comparison of average operation time

为了验证本文算法的复杂度与量测数的关系,对仿真实验重新设计,假定目标数不随时间变化,通过增大目标数来增大量测数,杂波强度设为3,粒子数为500,其他仿真参数不变,算法复杂度用运算时间来代表.图7给出了本文算法的平均运算时间与量测数的关系,为便于对比分析,图中画出了一个关于量测数的三次方曲线方程.可以看出,本文算法复杂度由于与多个参量有关系,与量测数近似满足随着量测数的增大复杂度呈三次方增长的关系.




图7 本文算法平均运算时间与量测数的关系

Fig. 7 The relationship between the average operation time and the number of measurements

5 结语

本文针对混合线性/非线性目标状态空间跟踪模型,提出了一种多传感器纯方位多目标跟踪粒子CPHD滤波算法,通过挖掘混合线性/非线性状态模型的结构信息,结合PF与KF对各个目标的状态进行预测与估计,以便更好地估计目标强度函数及势分布,运用Mean-Shift算法提取多目标密度函数的峰值作为目标状态估计值,并分析了算法的复杂度,仿真结果验证了算法的有效性.算法虽然提升了跟踪精度,但带来的计算复杂度较高,如何利用被动传感器的分布式计算来减小算法的运行时间,将是后续研究的方向.

参考文献:

- [1] MAHLER R. *Statistical Multisource Multitarget Information Fusion*. Norwood, MA: Artech House, 2007.
- [2] ZHANG Jungen. *Research on particle filter and its application to target tracking*. Xi'an: Xidian University, 2011. (张俊根. 粒子滤波及其在目标跟踪中的应用研究. 西安: 西安电子科技大学, 2011.)
- [3] MAHLER R. Multitarget Bayes filtering via first-order multitarget moments. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1152 – 1178.
- [4] VO B, MA W. The Gaussian mixture probability hypothesis density filter. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4091 – 4104.
- [5] CLARK D, VO B. Convergence analysis of the Gaussian mixture PHD filter. *IEEE Transactions on Signal Processing*, 2007, 55(4): 1204 – 1212.

- [6] ZHU Zongbin, TAO Jianfeng, GE Huiliang, et al. A bearings-only multi-targets tracking method based on GM-PHD filtering. *Technical Acoustics*, 2016, 35(4): 478 – 483.
(朱宗斌, 陶剑锋, 葛辉良, 等. 一种基于GM-PHD滤波的纯方位多目标跟踪方法研究. *声学技术*, 2016, 35(4): 478 – 483.)
- [7] MAHLER R. PHD filters of higher order in target number. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(4): 1523 – 1543.
- [8] ULMKE M, ERDINC O, WILLET P. Gaussian mixture cardinalized PHD filter for ground moving target tracking. *Proceedings of the 10th International Conference on Information Fusion*. Quebec, QC, Canada: IEEE, 2007: 1040 – 1047.
- [9] LIAN F, HAN C Z, LIU W F, et al. Unified cardinalized probability hypothesis density filters for extended targets and unresolved targets. *Signal Processing*, 2012, 92(7): 1729 – 1744.
- [10] QIN Ling, HUANG Xinhan. Adaptive target birth intensity for SMC-PHD/CPHD filtering. *Control and Decision*, 2016, 31(8): 1461 – 1467.
(秦岭, 黄心汉. 自适应目标新生强度的SMC-PHD/CPHD滤波. *控制与决策*, 2016, 31(8): 1461 – 1467.)
- [11] FENG Xinxin, WEI Shuai, LU Chuanguo. Track-before-detect algorithm based on Gaussian particle cardinalized probability hypothesis density. *Control and Decision*, 2017, 32(11): 1991 – 1996.
(冯新喜, 魏帅, 鹿传国. 基于高斯粒子CPHD滤波的多目标检测前跟踪算法. *控制与决策*, 2017, 32(11): 1991 – 1996.)
- [12] CHEN Xiao, LI Ya'an, LI Yuxing, et al. Active sonar target tracking based on the GM-CPHD filter algorithm. *Journal of Northwestern Polytechnical University*, 2018, 36(4): 656 – 663.
(陈晓, 李亚安, 李余兴, 等. 基于GM-CPHD滤波算法的主动声呐目标跟踪. *西北工业大学学报*, 2018, 36(4): 656 – 663.)
- [13] JING P L, ZOU J W, DUAN Y, et al. Generalized CPHD filter modeling spawning targets. *Signal Processing*, 2016, 128: 48 – 56.
- [14] WANG Yun, HU Guoping, GAN Linhai. Group targets tracking algorithm using a multiple models Gaussian inverse wishart CPHD filter. *Journal of Huazhong University of science and technology (Natural Science Edition)*, 2017, 45(2): 89 – 94.
(汪云, 胡国平, 甘林海. 基于多模型GGIW-CPHD滤波的群目标跟踪算法. *华中科技大学学报(自然科学版)*, 2017, 45(2): 89 – 94.)
- [15] ZOU Z B, SONG L P, CHENG X. Labeled box-particle CPHD filter for multiple extended targets tracking. *Journal of Systems Engineering and Electronics*, 2019, 30(1): 57 – 67.
- [16] CHEN Hui, DENG Dongming, HAN Chongzhao. Multi-sensor distributed control strategy for multi-target tracking. *Control Theory & Applications*, 2019, 36(10): 1585 – 1598.
(陈辉, 邓东明, 韩崇昭. 多目标跟踪中多传感器分布式控制策略. *控制理论与应用*, 2019, 36(10): 1585 – 1598.)
- [17] VIHOLA M. Rao-blackwellised particle filtering in random set multi-target tracking. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(2): 689 – 705.
- [18] ZHUANG Zesen, ZHANG Jianqiu, YIN Jianjun. A kernel particle probability hypothesis density filter for multi-target tracking. *Acta Aeronautica et Astronautica Sinica*, 2009, 30(7): 1264 – 1270.
(庄泽森, 张建秋, 尹建君. 多目标跟踪的核粒子概率假设密度滤波算法. *航空学报*, 2009, 30(7): 1264 – 1270.)
- [19] HAN B, COMANICIU D, ZHU Y, et al. Sequential kernel density approximation and its application to real-time visual tracking. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008, 30(7): 1186 – 1197.
- [20] CAMPILLO F, ROSSI V. Convolution particle filter for parameter estimation in general state-space models. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, 45(3): 1063 – 1072.
- [21] KARLSSON R, SCHON T, GUSTAFSSON F. Complexity analysis of the marginalized particle filter. *IEEE Transactions on Signal Processing*, 2005, 53(11): 4408 – 4411.

作者简介:

张俊根 博士, 讲师, 主要从事信号处理、粒子滤波及目标跟踪等方面的研究, E-mail: zhang_jungen@sina.com.