

一种多模型贝努利粒子滤波机动目标跟踪算法

杨峰 张婉莹*

(西北工业大学 自动化学院 西安 710129)

(信息融合技术教育部重点实验室 西安 710129)

摘要: 交互式多模型贝努利粒子滤波器(Interacting Multiple Model Bernoulli Particle Filter, IMMBPF)适用于杂波环境下的机动目标跟踪。但是 IMMBPF 将模型信息引入粒子采样过程中会导致用于逼近当前时刻真实状态与模型的粒子数减少, 而且每次递推各模型间的粒子都要进行交互, 存在计算量过大的缺点。为提升 IMMBPF 中单个采样粒子对于真实目标状态和模型逼近的有效性, 该文提出一种改进的多模型贝努利粒子滤波器(Multiple Model Bernoulli Particle Filter, MMBPF)。预先选定每一个模型的粒子数, 且模型间的粒子不需要进行交互, 减少了计算负荷。模型概率由模型似然函数计算得到, 在不改变模型的马尔科夫性质的条件下避免了小概率模型的粒子退化现象。仿真实验结果表明, 所提出的 MMBPF 与 IMMBPF 相比, 用较少的粒子数就可获得更优的跟踪性能。

关键词: 机动目标跟踪; 贝努利滤波; 粒子滤波; 多模型

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2017)03-0634-06

DOI: 10.11999/JEIT160467

Multiple Model Bernoulli Particle Filter for Maneuvering Target Tracking

YANG Feng ZHANG Wanying

(School of Automation, Northwestern Polytechnical University, Xi'an 710129, China)

(Key Laboratory of Information Fusion Technology, Ministry of Education, Xi'an 710129, China)

Abstract: Interacting Multiple Model Bernoulli Particle Filter (IMMBPF) is suitable for maneuvering target tracking under cluttered environment. However, when model information is introduced into particle sampling process in IMMBPF, it will lead to the number decline of particles which are applied to approaching the real state and model, and the computation load is heavy because of the interacting stage of particles in the recursion. An enhanced Multiple Model Bernoulli Particle Filter (MMBPF) is proposed to improve the effectiveness of single particle to approximate the real target state and model. The number of particles of each model is given in advance, and the posterior probability of each model is updated with the associate likelihood function, which avoids particle degeneracy without distorting the Markov property. Simulation results show that the proposed MMBPF achieves better tracking performance with fewer particles than IMMBPF.

Key words: Maneuvering target tracking; Bernoulli filter; Particle filter; Multiple model

1 引言

贝努利滤波器(Bernoulli Filter, BF)是随机有限集(Random Finite Set, RFS)框架下的一类最优

序贯贝叶斯滤波器^[1]。当考虑目标存在概率时, 目标状态可建模为贝努利 RFS。随机集统计学理论为统计描述和数学处理 RFS 随机变量提供了现实依据。目前, 贝努利滤波主要应用于目标跟踪, 传感器网络, 虚拟跟踪和雷达监控等方面^[2-5]。

对于机动目标跟踪, 文献[6]提出的交互式多模型 (Interacting Multiple Model, IMM) 算法得到了广泛的应用, 然而 IMM 算法在系统模型高度非线性时滤波效果较差。粒子滤波(Particle Filter, PF)因其不受非高斯、非线性问题的限制而被众多学者研究推广。文献[7]将 PF 与 IMM 方法相结合, 提出

收稿日期: 2016-05-09; 改回日期: 2016-11-28; 网络出版: 2017-01-11

*通信作者: 张婉莹 zhangwanying0418@163.com

基金项目: 国家自然科学基金(61135001, 61374159, 61374023), 西北工业大学研究生创新创业种子基金(Z2016149)

Foundation Items: The National Natural Science Foundation of China (61135001, 61374159, 61374023), Seed Foundation of Innovation and Creation of Graduate Students in Northwestern Polytechnical University (Z2016149)

IMMPF 算法, 在非线性、非高斯系统中可获得良好的跟踪性能, 文献[8]和文献[9]提出的 IMMPF 算法中粒子数没有参与模型切换, 但是每次递推各模型间的粒子都需要进行交互, 存在计算量过大的缺点, 文献[10]提出用各模型的粒子权值总和去更新模型后验概率, 在模型粒子数量差别较大时会使模型切换难以实现。

现有的针对机动目标跟踪的交互式多模型贝努利粒子滤波(IMMBPF)算法^[11,12], 只是简单地结合 IMM 和 BF 的粒子实现方式, 并为每一个模型分配大量的粒子, 也能通过粒子的传播估计出目标状态, 但对于线性、机动性较弱的模型来说, 大量的粒子是不必要的, 通常也会影响滤波性能, 带来额外的计算负担。一般来说, 我们更加关注非线性、机动性较强的模型, 对于此类模型可适当地采用较多的粒子; 而对线性、非机动的模型可以适当地减少粒子数。文献[13]指出在 IMMPF 算法中, 为了有效逼近真实系统状态, 应对主要模型分配较多的粒子数; 文献[14]给出解决此类问题的一种新思路, 即各模型的粒子数根据模型特性预先选定, 并在递推过程中保持不变, 且模型间的粒子不进行交互, 减少了计算量。针对上述问题, 本文提出一种改进的多模型贝努利粒子滤波(MMBPF)算法。

2 问题描述

给定如式(1)所示系统:

$$\mathbf{x}_k = \mathbf{F}(\theta_k)\mathbf{x}_{k-1} + \mathbf{v}_k(\theta_k) \quad (1)$$

其中, $\mathbf{x}_k = [x_k \ \dot{x}_k \ y_k \ \dot{y}_k]^\top$ 表示状态向量, 包含 k 时刻 x, y 方向的位置信息 (x_k, y_k) 和速度信息 (\dot{x}_k, \dot{y}_k) ; $\theta_k = 1, 2, \dots, M$ 为目标运动模型变量, $\mathbf{F}(\theta_k)$ 表示对应模型的状态转移矩阵; $\mathbf{v}_k(\theta_k)$ 表示均值为零, 方差为 $\mathbf{Q}_k(\theta_k)$ 的高斯过程噪声。

系统模型从 $k-1$ 时刻跳变到 k 时刻的转移过程可用一阶马尔科夫链表示为 $M \times M$ 维转移概率矩阵 $\boldsymbol{\pi}$, 其元素为

$$\pi_{ij} = P(\theta_k = j | \theta_{k-1} = i) \quad (2)$$

其中, $i, j \in M$ 并且 $\sum_{j=1}^M \pi_{ij} = 1$ 。

k 时刻的量测集 \mathbf{Z}_k 由目标量测 \mathbf{z}_k 和杂波量测集 \mathbf{C} 构成:

$$\mathbf{Z}_k = \mathbf{z}_k \cup \mathbf{C} \quad (3)$$

传感器提供目标的径向距离和方位角信息:

$$\mathbf{z}_k = \begin{bmatrix} \sqrt{x_k^2 + y_k^2} \\ \arctan(y_k/x_k) \end{bmatrix} + \mathbf{w}_k \quad (4)$$

其中, \mathbf{w}_k 是均值为零, 协方差为 $\mathbf{R}_k = \text{diag}([\sigma_r^2 \ \sigma_\theta^2])$

的高斯量测噪声, σ_r 和 σ_θ 分别表示径向距离和方位角的误差标准差。

每一时刻的虚警杂波量测集 \mathbf{C} 可建模为泊松 RFS, 强度函数为 $\kappa(\cdot) = \lambda_k V u(\cdot)$, 其中 $u(\cdot)$ 为杂波位置测量的均匀概率密度分布函数, V 为观测空域体积, λ_k 为杂波个数的期望值。

3 改进的多模型贝努利粒子滤波算法

3.1 改进的 MMBF 算法

多模型贝努利滤波算法适用于跟踪机动目标, 它是将贝努利滤波与 MM 算法相结合。统计目标的可能运动模型, 并为每种模型分配一个滤波器, 各个滤波器并行工作, 通过计算模型概率来评估模型的权重, 综合输出来估计目标状态。

假设 $k-1$ 时刻的目标后验概率密度分布已知, 有式(5)形式:

$$f_{k-1}(\mathbf{X}_{k-1}) = \begin{cases} 1 - q_{k-1}, \mathbf{X}_{k-1} = \emptyset \\ q_{k-1} \mu_{k-1}(\theta_{k-1}) s_{\theta_{k-1}, k-1}(\mathbf{x}_{k-1}), \\ \mathbf{X}_{k-1} = \left\{ [\mathbf{x}_{k-1}^\top, \theta_k]^\top \right\} \end{cases} \quad (5)$$

其中, $\mu_{k-1}(\cdot) \geq 0$ 表示目标的运动模型概率函数, 满足 $\sum_{\theta_{k-1}} \mu_{k-1}(\theta_{k-1}) = 1$, q_{k-1} 表示 $k-1$ 时刻的目标存在概率, $s_{\theta_{k-1}, k-1}(\mathbf{x}_{k-1})$ 表示运动模型为 θ_{k-1} 时目标状态的概率密度函数。

当 $k-1$ 时刻不存在目标时, k 时刻新生目标出现的概率为 p_b 且运动模型概率函数为 $\gamma_k(\cdot) > 0$, 满足 $\sum_{\theta_k} \gamma_k(\theta_k) = 1$ 。运动模型 θ_k 条件下的新生目标状态概率密度函数为 $b_{\theta_k, k|k-1}(\cdot)$, 由此可得目标转移密度函数为

$$\phi_{k|k-1}(\mathbf{X}_k | \emptyset) = \begin{cases} 1 - p_b, \mathbf{X}_k = \emptyset, \\ p_b \gamma_k(\theta_k) b_{\theta_k, k|k-1}(\mathbf{x}_k), \\ \mathbf{X}_k = \left\{ [\mathbf{x}_k^\top, \theta_k]^\top \right\} \end{cases} \quad (6)$$

假设目标存活概率 p_s 与目标状态独立, 当 $k-1$ 时刻存在目标, 并且存活到 k 时刻时, 目标转移密度函数为

$$\phi_{k|k-1}(\mathbf{X}_k | \mathbf{x}_k, \theta_k) = \begin{cases} 1 - p_s, \mathbf{X}_k = \emptyset \\ p_s f_{k|k-1}(\mathbf{x}_k, \theta_k | \mathbf{x}_{k-1}, \theta_k), \\ \mathbf{X}_k = \left\{ [\mathbf{x}_k^\top, \theta_k]^\top \right\} \end{cases} \quad (7)$$

其中, $f_{k|k-1}(\cdot)$ 是状态分布的转移密度函数。

在上述模型假设条件下, 推导可得 k 时刻的预测目标概率密度分布:

$$f_{k|k-1}(\mathbf{X}_k) = \begin{cases} 1 - q_{k|k-1}, & \mathbf{X}_k = \emptyset \\ q_{k|k-1} \mu_{k|k-1}(\theta_k) s_{\theta_k, k|k-1}(\mathbf{x}_k), & \mathbf{X}_k = \left\{ \left[\mathbf{x}_k^T, \theta_k \right]^T \right\} \end{cases} \quad (8)$$

其中,

$$q_{k|k-1} = p_b(1 - q_{k-1}) + p_s q_{k-1} \quad (9)$$

$$\mu_{k|k-1}(\theta_k) = \frac{p_b \gamma_k(\theta_k)(1 - q_{k-1}) + p_s q_{k-1}}{q_{k|k-1}} \quad (10)$$

$$s_{\theta_k, k|k-1}(\mathbf{x}_k) = \frac{p_b \gamma_k(\theta_k) b_{\theta_k, k|k-1}(\mathbf{x}_k)(1 - q_{k-1})}{q_{k|k-1} \mu_{k|k-1}(\theta_k)} + \left[p_s q_{k-1} \mu_{k-1}(\theta_k) \int f_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1}, \theta_k) \cdot s_{\theta_{k-1}, k-1}(\mathbf{x}_{k-1}) d\mathbf{x}_{k-1} \right] / (q_{k|k-1} \mu_{k|k-1}(\theta_k)) \quad (11)$$

假设目标检测概率 p_d 与状态独立, k 时刻量测集 \mathbf{Z}_k 更新后的目标后验概率密度分布如式(12)所示。

$$f_k(\mathbf{X}_k) = \begin{cases} 1 - q_k, & \mathbf{X}_k = \emptyset \\ q_k \mu_k(\theta_k) s_{\theta_k, k}(\mathbf{x}_k), & \mathbf{X}_k = \left\{ \left[\mathbf{x}_k^T, \theta_k \right]^T \right\} \end{cases} \quad (12)$$

其中,

$$q_k = \frac{\sum_{\theta_k} \mu_{k|k-1}(\theta_k)(1 - \Delta_k) q_{k|k-1}}{1 - q_{k|k-1} + \sum_{\theta_k} \mu_{k|k-1}(\theta_k)(1 - \Delta_k) q_{k|k-1}} \quad (13)$$

$$s_{\theta_k, k|k}(\mathbf{x}_k) = \frac{1}{q_{k|k} \mu_{k|k}(\theta_k)} \cdot \frac{\ell(\mathbf{x}_k) q_{k|k-1} \mu_{k|k-1}(\theta_k)}{1 - q_{k|k-1} + q_{k|k-1} \sum_{\theta_k} \mu_{k|k-1}(\theta_k)(1 - \Delta_k)} \cdot s_{\theta_k, k|k-1}(\mathbf{x}_k) \quad (14)$$

$$\Delta_k = p_d \left(1 - \sum_{z \in \mathbf{Z}_k} \frac{\int g_{\theta_k, k}(z | \mathbf{x}_k) s_{\theta_k, k|k-1}(\mathbf{x}_k)}{\lambda c(z)} \right) \quad (15)$$

$$\ell(\mathbf{x}_k) = 1 - p_d + p_d \sum_{z \in \mathbf{Z}_k} \frac{g_{\theta_k, k}(z | \mathbf{x}_k)}{\lambda c(z)} \quad (16)$$

$$\mu_k(\theta_k) = \frac{\mu_{k|k-1}(\theta_k)(1 - \Delta_k)}{\sum_{\theta_k} \mu_{k|k-1}(\theta_k)(1 - \Delta_k)} \quad (17)$$

其中, $g_{\theta_k, k}(z | \mathbf{x}_k)$ 是似然函数。

3.2 MMBF 粒子实现方式

本文所提 MMBPF 算法与标准交互式多模型粒子贝努利滤波(IMMBPF)算法的不同之处是首先根据模型的机动性大小选择每个模型的粒子数。对于不同模型的固定粒子数目该如何确定, 由于粒子数量不参与模型切换, 模型概率由似然函数进行更新, 可以独立控制各个模型的粒子数量, 不影响模型的

正常切换。本文采用一个较简单的方式选取各模型的粒子数: 对非线性较强的模型, 为了保证跟踪精度, 用较多的粒子, 以便更好地近似其状态后验概率密度; 而对线性、机动小的模型采用较少的粒子, 不影响跟踪精度, 同时可以减少计算量。

下面将具体描述 MMBPF 算法的递归过程。

步骤 1 计算各模型预测概率和混合概率:

$$\begin{aligned} \mu_{k|k-1}(\theta_k) &= P(\theta_k | \mathbf{Z}_{k-1}) \\ &= \sum_{\theta_{k-1}=1}^M P(\theta_k | \theta_{k-1}) P(\theta_{k-1} | \mathbf{Z}_{k-1}) \end{aligned} \quad (18)$$

$$P(\theta_{k-1} | \theta_k, \mathbf{Z}_{k-1}) = \frac{P(\theta_k | \theta_{k-1}) P(\theta_{k-1} | \mathbf{Z}_{k-1})}{P(\theta_k | \mathbf{Z}_{k-1})} \quad (19)$$

步骤 2 初始化粒子群: 本文算法在混合阶段不像传统 IMMBPF 那样对各模型的粒子进行交互计算, 也不通过马尔科夫转移概率对各模型粒子进行重新分配。而是按照模型混合概率在上一时刻各模型滤波得到的后验粒子群中进行重采样, 重建当前时刻模型 θ_k 的初始粒子群。本文采用类似于 bootstrap 滤波器中重采样的方法^[10], 根据式(19)计算得到模型混合概率, 通过概率采样确定 N_{θ_k} 个粒子上时刻的模型索引, 即它们分别来自上一时刻哪个模型的粒子群, 然后按照模型索引在对应后验粒子群中随机抽取状态粒子给模型 θ_k , 获得 k 时刻模型 θ_k 的初始化粒子群 $\{\mathbf{x}_{k-1}^{(1)}, \mathbf{x}_{k-1}^{(2)}, \dots, \mathbf{x}_{k-1}^{(N_{\theta_k})}\}$, 其中 N_{θ_k} 代表模型 θ_k 的粒子数目。

步骤 3 模型条件贝努利粒子滤波:

(1) 预测: 假设 $k-1$ 时刻的目标存在概率为 q_{k-1} , 模型 θ_{k-1} 的目标状态后验概率密度由粒子集表示为

$$\begin{aligned} s_{\theta_{k-1}, k-1}(\mathbf{x}_{k-1}) \\ = \sum_{n=1}^{N_{\theta_{k-1}}} \omega_{\theta_{k-1}, k-1}^{(n)} \delta(\mathbf{x}_{k-1} - \mathbf{x}_{k-1}^{(n)}, \theta_{k-1} - \theta_{k-1}^{(n)}) \end{aligned} \quad (20)$$

其中, $\omega_{\theta_{k-1}, k-1}^{(n)}$ 是粒子权值。则 k 时刻的预测目标存在概率 $q_{k|k-1}$ 可通过式(9)计算。

预测目标状态概率密度包括存活目标和新生目标两部分

$$\begin{aligned} s_{\theta_k, k|k-1}(\mathbf{x}_k) \\ = \sum_{n=1}^{N_{\theta_k} + N_{\theta_k}^{\Gamma}} \omega_{\theta_k, k|k-1}^{(n)} \delta(\mathbf{x}_{k|k-1} - \mathbf{x}_{k|k-1}^{(n)}, \theta_k - \theta_k^{(n)}) \end{aligned} \quad (21)$$

其中, $\delta(\cdot)$ 为 Dirac delta 函数。

粒子从式(22)中两个建议分布密度函数中采样:

$$\mathbf{x}_{k|k-1}^{(n)} \sim \begin{cases} q_k(\cdot | \mathbf{x}_{k-1}^{(n)}, \theta_{k-1}^{(n)}, \mathbf{Z}_k), & n = 1, 2, \dots, N_{\theta_k} \\ q_b(\cdot | \mathbf{Z}_k), & n = N_{\theta_k} + 1, N_{\theta_k} + 2, \dots, N_{\theta_k} + N_{\theta_k}^{\Gamma} \end{cases} \quad (22)$$

对应粒子权值为

$$\tilde{\omega}_{\theta_k, k|k-1}^{(n)} = \begin{cases} \frac{p_s q_{k-1|k-1} \omega_{\theta_k, k-1}^{(n)}}{q_{k|k-1}}, & n = 1, 2, \dots, N_{\theta_k} \\ \frac{p_b (1 - q_{k-1|k-1}) b_{\Gamma, k}(\mathbf{x}_{\Gamma, k}^{(n)} | \theta_k)}{q_{k|k-1} \gamma_k(\mathbf{x}_{\Gamma, k}^{(n)} | \theta_k, Z_k)} \frac{1}{N_{\theta_k}^{\Gamma}}, & n = N_{\theta_k} + 1, N_{\theta_k} + 2, \dots, N_{\theta_k} + N_{\theta_k}^{\Gamma} \end{cases} \quad (23)$$

其中, $b_{\Gamma, k}(\cdot)$ 是新生目标概率密度, $\gamma_k(\cdot)$ 表示模型条件下的运动状态采样建议密度函数, $N_{\theta_k}^{\Gamma}$ 是新生目标模型 θ_k 的粒子数。

权值归一化:

$$\omega_{\theta_k, k|k-1}^{(n)} = \frac{\tilde{\omega}_{\theta_k, k|k-1}^{(n)}}{\sum_{n=1}^{N'_{\theta_k}} \tilde{\omega}_{\theta_k, k|k-1}^{(n)}}, \quad n = 1, 2, \dots, N'_{\theta_k} \quad (24)$$

其中, $N'_{\theta_k} = N_{\theta_k} + N_{\theta_k}^{\Gamma}$ 。

(2)更新: 将式(21)代入式(15), 可得

$$\Delta_k = p_d \left(1 - \sum_{z \in Z_k} \sum_{n=1}^{N'_{\theta_k}} \frac{g_{\theta_k, k}(z | \mathbf{x}_{k|k-1}^{(n)}) \omega_{\theta_k, k|k-1}^{(n)}}{\lambda c(z)} \right) \quad (25)$$

将式(25)分别代入式(13)和式(17)可得更新的目标存在概率 $q_{k|k}$ 和更新的模型概率 $\mu_k(\theta_k)$ 。

将式(21)代入式(14), 可得

$$\omega_{\theta_k, k|k}^{(n)} = \frac{1}{q_{k|k} \mu_{k|k}(\theta_k)} \cdot \frac{q_{k|k-1} \mu_{k|k-1}(\theta_k) \ell(\mathbf{x}_k^{(n)}) \delta(\mathbf{x}_k - \mathbf{x}_{k|k}^{(n)}, \theta_k - \theta_{k|k}^{(n)})}{1 - q_{k|k-1} + q_{k|k-1} \sum_{\theta_k} \mu_{k|k-1}(\theta_k) (1 - \Delta_k)} \cdot \omega_{\theta_k, k|k-1}^{(n)} \quad (26)$$

则目标状态后验概率密度 $s_{\theta_k, k|k}(\mathbf{x}_k)$ 如式(27)所示,

$$s_{\theta_k, k|k}(\mathbf{x}_k) = \sum_{n=1}^{N'_{\theta_k}} \hat{\omega}_{\theta_k, k|k}^{(n)} \delta(\mathbf{x}_k - \mathbf{x}_{k|k}^{(n)}, \theta_k - \theta_{k|k}^{(n)}) \quad (27)$$

其中, $\hat{\omega}_{\theta_k, k|k}^{(n)}$ 是归一化的粒子权值。

(3)重采样: 根据归一化的粒子权值 $\hat{\omega}_{\theta_k, k|k}^{(n)}$ 对各模型的粒子集 $\{\mathbf{x}_{\theta_k, k|k-1}^1, \mathbf{x}_{\theta_k, k|k-1}^2, \dots, \mathbf{x}_{\theta_k, k|k-1}^{N'_{\theta_k}}\}$ 进行 N_{θ_k} 次重采样, 得到 k 时刻的后验粒子集 $\{\hat{\mathbf{x}}_{\theta_k, k|k}^1, \hat{\mathbf{x}}_{\theta_k, k|k}^2, \dots, \hat{\mathbf{x}}_{\theta_k, k|k}^{N_j}\}$, 权值均为 $1/N_{\theta_k}$ 。

重采样后权重大的粒子, 即对于目标真实状态逼近程度高的粒子被有效复制, 小权值粒子被删减, 重采样过程不仅实现了预测粒子的更新, 同时有效改善了粒子退化现象的影响。

步骤 4 输出状态估计

若更新后的目标存在概率 $q_{k|k} > \tau$ ($\tau \in (0, 1)$) 表

示判决门限, 常取 0.5), 则表示目标存在, 输出目标状态估计:

$$\hat{\mathbf{x}}_{k|k} = \sum_{\theta_k=1}^M \mu_k(\theta_k) \hat{\mathbf{x}}_{\theta_k, k|k} \quad (28)$$

其中, $\hat{\mathbf{x}}_{\theta_k, k|k}$ 是模型为 θ_k 的状态估计值。

4 仿真实证

一个高速机动目标在 2 维场景 $[0, \pi] \times [0, 25000]$ (rad·m) 中运动 100 s, 起始位置为 [11689, 20840] m, 目标开始时以 $[-8.3, -399.9]$ m/s 的速度做 20 s 匀速直线运动, 随后以 0.1 rad/s 角速率做 20 s 顺时针转弯运动, 在转弯后接着做 20 s 的匀速直线运动, 随后又以 0.07 rad/s 角速率做 20 s 逆时针转弯运动, 最后再做 20 s 的匀速直线运动。图 1 给出了笛卡尔坐标系下目标的真实运动轨迹。

采用 CV 模型和 CT 模型对目标运动进行描述。

(1)CV 模型:

$$\mathbf{F}(\text{CV}) = \mathbf{I}_2 \otimes \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}; \quad \mathbf{v}_k(\text{CV}) \sim N(\cdot; 0, \sigma_{\text{CV}}^2)$$

其中, \mathbf{I}_2 是 2×2 的单位矩阵, T 为采样间隔, σ_{CV}^2 为 CV 模型过程噪声协方差, $\sigma_{\text{CV}} = 5$ m/s²。

(2)CT 模型:

$$\mathbf{F}(\text{CT}) = \begin{bmatrix} 1 & \frac{\sin(\omega T)}{\omega} & 0 & -\frac{1 - \cos(\omega T)}{\omega} \\ 0 & \cos(\omega T) & 0 & -\sin(\omega T) \\ 0 & \frac{1 - \cos(\omega T)}{\omega} & 1 & \frac{\sin(\omega T)}{\omega} \\ 0 & \sin(\omega T) & 0 & \cos(\omega T) \end{bmatrix}$$

$$\mathbf{v}_k(\text{CT}) \sim N(\cdot; 0, \sigma_{\text{CT}}^2)$$

其中, ω 为转弯角速度, σ_{CT}^2 为 CT 模型过程噪声协方差, 顺时针转弯 $\sigma_{\text{CT1}} = 7.5$ m/s², 逆时针转弯 $\sigma_{\text{CT2}} = 40$ m/s²。




图 1 目标真实运动轨迹 (●表示起点, ■表示终点)

$$\text{模型切换概率矩阵 } \boldsymbol{\pi} = \begin{bmatrix} 0.96 & 0.02 & 0.02 \\ 0.02 & 0.96 & 0.02 \\ 0.02 & 0.02 & 0.96 \end{bmatrix}, \text{ 初始}$$

化模型概率分布为 $[0.96 \ 0.02 \ 0.02]$ 。

采样周期 $T = 1 \text{ s}$, 目标存活概率 $p_s = 0.99$, 目标新生概率 $p_b = 0.01$, 新生目标密度 $b_{k|k-1}(\mathbf{x}, \theta_k) = \mathcal{N}(\mathbf{x}; \mathbf{m}_b, \mathbf{Q}_b)$, 其中 $\mathbf{m}_b = [21690 \text{ m} - 8 \text{ m/s} \ 10850 \text{ m} - 400 \text{ m/s}]^T$, $\mathbf{Q}_b = \text{diag}[100 \ 10 \ 100 \ 10]$ 。在每一拍仿真中, 新生目标采样粒子数 $N_j^T = 200 (j = 1, 2, 3)$ 。传感器对目标检测概率 $p_d = 0.98$, 量测噪声径向距离标准差 $\sigma_r = 5 \text{ m}$, 方位角标准差 $\sigma_\theta = 3 \text{ mrad}$, $\lambda_k = 2.5465 \times 10^{-4} / (\text{rad} \cdot \text{m})$, $V = 25000\pi (\text{rad} \cdot \text{m})$, 也即平均每次扫描有 20 个杂波。

为了验证所提算法的性能, 采用标准的 IMMBPF 算法^[11]与所提算法 MMBPF 进行对比分析。仿真平台参数: CPU 主频 3.3 GHz, 8 GB RAM, 仿真软件: Matlab R2014a。

(1) 粒子总数相同时滤波性能对比: 采用与文献[11]相同的粒子个数。IMMBPF 和 MMBPF 每个模型使用 1000 个粒子。蒙特卡洛仿真 50 次, 图 2, 图 3 分别为位置 RMSE 和速度 RMSE 对比图。可以看出, 在机动目标跟踪过程中, MMBPF 比 IMMBPF 有更高的位置和速度估计精度, 同时由表 1 平均运算时间对比数据可以看出, 本文所提的 MMBPF 算法要稍快于 IMMBPF, 说明各模型粒子之间没有进行交互会减少计算量。

(2) 粒子总数不同时滤波性能对比: 由于 CV 运动的线性特性, 用较少的粒子数就可逼近真实的运

表 1 平均运算时间对比(s)

算法	平均运算时间
IMMBPF	0.2799
MMBPF	0.2618

动状态, 因此减少 MMBPF 粒子数, CV 模型使用 300 个粒子, 两个 CT 模型各使用 700 个粒子。IMMBPF 粒子数维持不变, 50 次蒙特卡洛仿真对比结果: 表 2 为平均运算时间对比, 图 4, 图 5 分别为位置估计和速度估计 RMSE 曲线。可见 MMBPF 所用粒子总数约为 IMMBPF 的一半, 但整体跟踪精度仍然要优于 IMMBPF。

表 2 平均运算时间对比(s)

算法	平均运算时间
IMMBPF	0.2719
MMBPF	0.1367

5 结论

本文提出的改进的多模型贝努利粒子滤波算法 (MMBPF), 能够根据模型特性控制每一个模型的粒子数量, 对机动性强的模型采用较多的粒子数, 机动性弱的模型采用较少的粒子数, 可以有效地提高粒子的利用率, 且模型间的粒子不进行交互, 减少了计算量, 目标的状态估计和模型概率更新分开进行, 利用模型的似然函数更新模型后验概率。仿真结果表明, 所提出的多模型贝努利粒子滤波算法用较少的粒子总数就可获得更优的跟踪性能。




图 2 位置 RMSE 曲线




图 3 速度 RMSE 曲线




图4 位置 RMSE 曲线




图5 速度 RMSE 曲线

参考文献

- [1] RISTIC B, VO B T, VO B N, *et al.* A tutorial on Bernoulli filters: Theory, implementation and applications[J]. *IEEE Transactions on Signal Processing*, 2013, 61(13): 3406–3430. doi: 10.1109/TSP.2013.2257765.
- [2] VO B T, VO B N, HOSEINNEZHAD, *et al.* Robust multi-Bernoulli filtering [J]. *IEEE Selected Topics in Signal Processing*, 2013, 7(3): 399–409. doi: 10.1109/JSTSP.2013.2252325.
- [3] PAPI F, KYOVTOROV V, GIULIANNI R, *et al.* Bernoulli filter for track-before-detect using MIMO radar[J]. *IEEE Signal Processing Letters*, 2014, 21(9): 1145–1149. doi: 10.1109/LSP.2014.2325566.
- [4] VO B T, SEE C M, MA N, *et al.* Multi-sensor joint detection and tracking with the Bernoulli filter[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(2): 1385–1402. doi: 10.1109/TAES.2012.6178069.
- [5] GRAMSTROM K, WILLETT P, and BARSHALOM Y. A Bernoulli filter approach to detection and estimation of hidden Markov models using cluttered observation sequences[C]. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Brisbane, Australia, 2015: 3911–3915. doi: 10.1109/ICASSP.2015.7178704.
- [6] BLOM H A P. An efficient filter for abruptly changing systems[C]. *IEEE Proceedings of 23th Conference on Decision and Control*, Las Vegas, NV, USA, 1984, Vol.23: 656–658. doi: 10.1109/CDC.1984.272089.
- [7] MCGINNITY S and IRWIN G W. Multiple model bootstrap filter for maneuvering target tracking[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2000, 36(3): 1006–1012. doi: 10.1109/7.869522.
- [8] 刘贵喜, 高恩克, 范春宇. 改进的交互式多模型粒子滤波跟踪算法[J]. *电子与信息学报*, 2007, 29(12): 2810–2813.
- [9] LIU Guixi, GAO Enke, and FAN Chunyu. Tracking algorithms based on improved interacting multiple model particle filter[J]. *Journal of Electronics & Information Technology*, 2007, 29(12): 2810–2813.
- [10] BOERS Y and DRIESSEN H. Interacting multiple model particle filter[J]. *IEE Proceedings-Radar, Sonar and Navigation*, 2003, 150(5): 344–349. doi: 10.1049/ip-rsn:20030741.
- [11] DRIESSEN H and BOERS Y. Efficient particle filter for jump Markov nonlinear systems[J]. *IEE Proceedings-Radar, Sonar and Navigation*, 2005, 152(5): 323–326. doi: 10.1049/ip-rsn:20045075.
- [12] YANG Wei, FU Yaowen, LONG Jianqian, *et al.* Random finite sets-based joint maneuvering target detection and tracking filter and its implementation[J]. *IET Signal Processing*, 2012, 6(7): 648–660. doi: 10.1049/iet-spr.2011.0171.
- [13] DUNNE D and KIRUBARAJAN T. Multiple model multi-Bernoulli filters for maneuvering targets[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2013, 49(4): 2679–2692. doi: 10.1109/TAES.2013.6621845.
- [14] YANG Yanbo, ZOU Jie, YANG Feng, *et al.* An adaptive particle filter based on the mixing probability[C]. *IEEE International Congress on Image and Signal Processing (CISP)*, Chongqing, China, 2012: 1480–1484. doi: 10.1109/CSIP.2012.6469724.
- [15] 鉴福升, 徐跃民, 阴泽杰. 改进的多模型粒子滤波机动目标跟踪算法[J]. *控制理论与应用*, 2010, 27(8): 1012–1016.
- [16] JIAN Fusheng, XU Yueming, and YIN Zejie. Enhanced multiple model particle filter for maneuvering target tracking[J]. *Control Theory & Application*, 2010, 27(8): 1012–1016.

杨峰：男，1977年生，副教授，主要研究方向为多源信息融合、目标跟踪等。

张婉莹：女，1993年生，硕士生，研究方向为多源信息融合、目标跟踪等。