

被动传感器阵列中基于粒子滤波的目标跟踪

李良群 黄敬雄 谢维信

(深圳大学 ATR 国防科技重点实验室 深圳 518060)

摘要: 针对被动传感器阵列中的机动目标跟踪问题, 该文提出了一种基于多模 Rao-Blackwellized 粒子滤波的机动目标跟踪新方法。算法首先基于 Rao-Blackwellization 理论将机动目标跟踪问题划分为模型选择和目标跟踪两个子问题; 采用多模 Rao-Blackwellized 粒子滤波对目标运动模型进行选择, 扩展 Kalman 滤波对目标进行更新, 有效降低了抽样粒子状态维数, 节省了计算时间; 最后, 建立了被动传感器阵列的非线性观测模型。实验结果表明, 提出方法可以有效地对目标模型进行选择, 算法的跟踪性能及稳定性要好于交互多模型(IMM)方法。

关键词: 机动目标跟踪; 被动传感器阵列; Rao-Blackwellized 粒子滤波

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2009)04-0844-04

Target Tracking Based on Particle Filtering in Passive Sensor Array

Li Liang-qun Huang Jing-xiong Xie Wei-xin

(ATR Key Laboratory, Shenzhen University, Shenzhen 518060, China)

Abstract: In this paper, a new Multiple Model Rao-Blackwellized Particle Filter (MMRBPF) based algorithm is proposed for maneuvering target tracking in passive sensor array. The advantage of the proposed approach is that the Rao-Blackwellization allows the algorithm to be partitioned into target tracking and model selection sub-problems, where the target tracking can be solved by the extend Kalman filter, and the model selection by multiple model Rao-Blackwellized particle filter. The analytical relationship between target state and model is exploited to improve the efficiency and accuracy of the proposed algorithm. Finally, a nonlinear measurement model of multiple passive sensors is founded. The simulation results show that the proposed algorithm results in more accurate tracking than the IMM (Interacting Multiple Model) method.

Key words: Maneuvering target tracking; Passive sensor array; Rao-Blackwellized particle filter

1 引言

被动传感器阵列中的机动目标跟踪是一个重要的研究课题。多年来, 许多研究者发表了大量的相关研究论文, 提出了多种方法^[1-10]。其中代表性的方法有: 交互多模型(IMM)、自适应 Kalman 滤波、粒子滤波等。从性能和计算复杂度两方面综合考虑, IMM 方法是一种比较好的方法。它利用扩展 Kalman 滤波对非线性的观测方程进行线性化处理, 通过精选目标运动模型, 可以有效地对三维被动机动目标跟踪。然而, 由于 IMM 方法中模型交互并没有利用目标当前观测信息, 当目标突然机动时, IMM 方法不能及时对机动目标进行检测, 导致目标机动时跟踪性能降低, 从而可能出现目标丢失的情况。此外, 现在的被动传感器系统大多都是测向交叉定位系统, 它通过高精度的测向设备在多个观测点对目标进行测向, 各个测向线的交点就是目标的位置。由于交叉定位带来一部分定位误差, 也会降低目标跟踪的性能。

粒子滤波是一种基于 Bayes 原理用粒子概率密度表示的序贯 Monte-Carlo 模拟方法, 其基本思想就是通过寻找一组在状态空间中传播的随机样本对后验概率分布进行近似, 以样本均值代替积分运算, 从而获得状态的最小方差估计^[3]。最近几年, 为了消除线性化所带来的误差, 粒子滤波被广泛的应用到目标跟踪中来^[3-6]。文献[4]提出了一种基于粒子滤波的交互多模型跟踪算法, 能够对无杂波环境下的机动目标进行较为准确的跟踪, 由于避免了观测方程线性化带来的误差, 它的跟踪性能要好于传统的 IMM 算法; 然而, 这些基于粒子滤波的算法有着一个共同的缺点, 随着目标状态维数的增加, 粒子维数和计算量也增加, 导致粒子退化严重。针对这一问题, Doucet^[7]等人提出了一种 Rao-Blackwellized 粒子滤波器, 将滤波过程分为粒子选择和状态更新两个过程, 能够较好地解决目标状态维数的增加问题。在文献[6,7]的基础上, 本文提出一种多模 Rao-Blackwellized 粒子滤波器并将其应用到实际的目标跟踪中, 为了避免了目标的不可观测性, 建立了被动传感器阵列的非线性观测模型。此外, 本文引入最新的观测信息用于目标模型选择, 推导出 Rao-Blackwellized 粒子滤波的多模型表达式, 使算法更加简单清

2008-02-20 收到, 2008-07-25 改回

广东省自然科学基金(8451806001001836)和博士后科研基金项目(20080441165)资助课题

晰。

2 多模 Rao-Blackwellized 粒子滤波器

2.1 系统模型及 Rao-Blackwellization 理论

考虑下面的非线性一阶马尔可夫离散系统:

$$\mathbf{x}_k = f(x_{k-1}, M_k) + g(M_k) \mathbf{w}_k \quad (1)$$

$$\mathbf{z}_k = h(x_k, M_k) + \mathbf{v}_k \quad (2)$$

$$M_k \sim p(M_k | M_{k-1}) \quad (3)$$

其中 $\mathbf{x}_k \in \mathcal{R}^{n_x}$ 表示系统在 k 时刻的状态向量, $\mathbf{z}_k \in \mathcal{R}^{n_z}$ 表示系统在 k 时刻的观测向量, $\mathbf{w}_k \sim N(0, Q)$ 为过程噪声向量, $\mathbf{v}_k \sim N(0, R)$ 为观测噪声向量。 M_k 表示目标运动模型, 满足一阶马尔可夫链。

通常, 对于两个变量 x 和 m 的状态估计器 $\eta(x, m)$, 根据 Rao-Blackwellization 理论, 该估计器的协方差可以用下式表示^[7]:

$$\text{Var}[\eta(x, m)] = \text{Var}[E(\eta(x, m)|x)] + \text{Var}[E(\eta(x, m)|m)] \quad (4)$$

由于 $\text{Var}[E(\eta(x, m)|x)]$ 非负, 估计器 $\eta' = E(\eta(x, m)|m)$ 的协方差要小于 $\eta(x, m)$ 的协方差。Rao-Blackwellization 理论就是通过估计条件均值 $E(\eta(x, m)|m)$ 来代替原始的状态值 $\eta(x, m)$, 很明显, 次优估计减少了估计的方差。

2.2 多模 Rao-Blackwellized 粒子滤波器

针对被动传感器阵列中的机动目标跟踪问题, 假设 x_k 、 z_k 分别表示 k 时刻的目标状态和观测, 提出方法 (MMRBPF) 的中心思想就是把原始的状态空间划分为两个单独的部分 x_k (状态变量) 和 M_k (模型变量)。采用粒子滤波估计模型概率密度分布 $p(M_k | M_{1:k-1}, z_{1:k})$, 在目标模型变量的条件下, 进一步估计出状态后验概率分布 $p(x_k | x_{1:k-1}, M_{1:k}, z_{1:k})$ 。于是可以把后验概率分解成如下形式:

$$p(x_k, M_k | x_{1:k-1}, M_{1:k-1}, z_{1:k}) = p(x_k | x_{1:k-1}, M_k, M_{1:k-1}, z_{1:k}) p(M_k | x_{1:k-1}, M_{1:k-1}, z_{1:k}) \quad (5)$$

从式(5)可以看出, 在相同粒子数的情况下, 该方法要明显好于其它粒子滤波, 主要原因有两个: 第一, 模型的后验概率密度函数 $p(M_k | x_{1:k-1}, M_{1:k-1}, z_{1:k})$ 的维数要小于 $p(x_k, M_k | x_{1:k-1}, M_{1:k-1}, z_{1:k})$; 第二, 最优算法可以用来更新目标的状态 $p(x_k | x_{1:k-1}, M_k, M_{1:k-1}, z_{1:k})$, 如Kalman滤波等^[1]。本文中, 将重点阐述多模型与Rao-Blackwellized粒子滤波器的结合, 引入最新的观测信息用于目标运动模型的切换, 推导出似然函数和重要性密度函数的表达式。多模 Rao-Blackwellized粒子滤波器(MMRBPF)流程为

(1) 序列重要性采样 For $i = 1, \dots, N$, 从重要性密度函数中采样模型粒子: $M_k^i \sim p(M_k | z_{1:k}, M_{k-1}^i)$;

For $i = 1, \dots, N$, 计算粒子权值 $w_k^i \propto w_{k-1}^i \times \frac{p(z_k | M_k^i, z_{1:k-1}, M_{k-1}^i) p(M_k | M_{k-1}^i)}{p(M_k | z_{1:k}, M_{k-1}^i)}$;

For $i = 1, \dots, N$, 标准化粒子权值 $w_k^i = w_k^i \left[\sum_{j=1}^N w_k^j \right]^{-1}$ 。

(2) 重采样 重新分配粒子权值, 剔除权值较小的粒子, 增加权值较大的粒子。

(3) Kalman 滤波更新 利用 Kalman 滤波对状态进行更新。

在上述流程中, 算法与Rao-Blackwellized粒子滤波器结构相同, 不同的只是观测似然函数 $p(z_k | M_k^i, z_{1:k-1}, M_{k-1}^i)$ 和重要性密度函数 $p(M_k | z_{1:k}, M_{k-1}^i)$ 的计算方法 (M_{k-1}^i 表示粒子 i 的目标模型), 下面给出这两部分的详细计算过程。

2.2.1 似然函数的计算 为了推导 k 时刻观测 z_{k_j} 的概率密度函数 $p(z_{k_j} | M_k, z_{1:k-1}, M_{k-1}^i)$ 。假设在 k 时刻, 总共有 M 个目标运动模型, 定义如下:

$$\left. \begin{aligned} M_k = 1, & \quad \text{表示目标在} k \text{时刻匀速运动} \\ M_k = 2, & \quad \text{表示目标在} k \text{时刻匀速转弯运动} \\ & \quad \vdots \\ M_k = M, & \quad \text{表示目标在} k \text{时刻匀加速运动} \end{aligned} \right\} \quad (6)$$

假设 k 时刻目标的运动模型 $M_k = m$, 观测 z_{k_j} 的似然函数可以定义如下:

$$\begin{aligned} p(z_{k_j} | M_k = m, z_{1:k-1}, M_{k-1}^i) &= \int p(z_{k_j} | M_k = m, x_{k,m}) p(x_{k,m} | z_{1:k-1}, M_{k-1}^i) dx_{k,m} \\ &= \int N(z_{k_j} | h(x_k, M_k = m), R) \\ &\quad \cdot N(x_{k,m} | f(x_{k-1}, M_{k-1}^i), Q) dx_{k,m} \end{aligned} \quad (7)$$

其中 $N(m, Q)$ 表示均值为 m , 方差为 Q 的正态分布函数。从方程(7)可以看出, 观测似然函数就是目标的滤波似然函数。

应用观测方程可得:

$$\begin{aligned} p(z_{k_j} | M_k = m, z_{1:k-1}, M_{k-1}^i) &= N(z_{k_j} | h(f(x_{k-1}, M_{k-1}^i), M_k = m), S_{k,t}), \\ &\quad m = 1, 2, \dots, M \end{aligned} \quad (8)$$

其中 $S_{k,t}$ 表示目标模型 m 的观测协方差。

于是, 观测似然函数可以定义为

$$p(z_k | M_k, z_{1:k-1}, M_{k-1}^i) = \begin{cases} N(z_{k_j} | h(f(x_{k-1}, M_{k-1}^i), M_k = 1), S_{k,1}), & M_k = 1 \\ N(z_{k_j} | h(f(x_{k-1}, M_{k-1}^i), M_k = 2), S_{k,2}), & M_k = 2 \\ \vdots \\ N(z_{k_j} | h(f(x_{k-1}, M_{k-1}^i), M_k = M), S_{k,M}), & M_k = M \end{cases} \quad (9)$$

2.2.2 最优重要性密度函数 对于每个粒子 i , 目标当前运动模型 M_k 只与前一时刻的运动模型 M_{k-1}^i 相关, 与前一时刻的观测 $z_{1:k-1}$ 无关。于是最优重要性密度函数可以写为下式:

$$\begin{aligned} p(M_k | z_{1:k}, M_{k-1}^i) &\propto p(z_k | M_k, z_{1:k-1}, M_{k-1}^i) \\ &\cdot p(M_k | z_{1:k-1}, M_{k-1}^i) = p(z_k | M_k, z_{1:k-1}, M_{k-1}^i) p(M_k | M_{k-1}^i) \end{aligned} \quad (10)$$

因此, 可以按以下步骤对重要性概率密度分布进行采样:

(1) 计算每个模型的概率 $m = 1, 2, \dots, M$

$$\Pi_m^i = p(z_k | M_k^i = m, z_{1:k-1}, M_{k-1}^i) p(M_k^i = m | M_{k-1}^i),$$

$$m = 1, 2, \dots, M \quad (11)$$

(2) 模型概率标准化

$$\hat{\Pi}_m^i = \frac{\Pi_m^i}{\sum_{m=1}^M \Pi_m^i}, \quad m = 1, 2, \dots, M \quad (12)$$

(3) 根据相应的模型概率产生模型粒子, 如, 产生模型粒子 i , 是模型1的概率为 $\hat{\Pi}_1^i$, 是模型2的概率为 $\hat{\Pi}_2^i$, 依次类推, 产生所有需求的模型粒子。

2.2.3 滤波更新 在采样得到的粒子模型 M_k^i 的基础上, 利用扩展kalman滤波对目标状态进行更新, 具体如下:

$$\hat{x}_{k|k-1}^i = f(x_{k-1}^i, M_k^i) \quad (13)$$

$$\hat{z}_{k|k-1}^i = h(x_{k|k-1}^i, M_k^i) \quad (14)$$

$$F_k^i = \left. \frac{\partial f(x_{k-1}^i, M_k^i)}{\partial x_{k-1}^i} \right|_{x_{k|k-1}^i = x_{k-1}^i}, \quad H_k^i = \left. \frac{\partial h(x_k^i, M_k^i)}{\partial x_k^i} \right|_{x_k^i = x_{k|k-1}^i} \quad (15)$$

$$P_{k|k-1}^i = F_k^i P_{k-1|k-1}^i F_k^{iT} + Q \quad (16)$$

$$S_k^i = H_k^i P_{k|k-1}^i H_k^{iT} + R \quad (17)$$

$$W_k^i = P_{k|k-1}^i H_k^{iT} S_k^{i-1} \quad (18)$$

$$\hat{x}_{k|k}^i = \hat{x}_{k|k-1}^i + W_k^i (z_{k,j}^i - \hat{z}_{k|k-1}^i) \quad (19)$$

$$P_{k|k}^i = [I - W_k^i H_k^i] P_{k|k-1}^i \quad (20)$$

2.3 被动传感器阵列观测模型

对于单被动传感器的目标跟踪, 须利用传感器的运动对目标连续测向进行定位跟踪, 且传感器的机动必须远大于被跟踪目标的机动。对于多被动传感器阵列, 由于只有方位和俯仰角等角度信息, 所以需利用多个传感器进行交叉定位得到目标的位置信息。通常被动传感器阵列有两种工作方式, 第1种方式是每个传感器都能够独立地进行二维跟踪得到各个目标的航迹结果, 最后再进行航迹的关联, 这就是所谓的航迹融合; 第2种方式是传感器的所有观测都同时传递到一个融合中心, 统一进行一个三维的跟踪融合。前者的优势在于对带宽的要求小, 适合于处理多目标和大量回波观测的跟踪情况, 缺点是跟踪性能不高, 对于机动目标跟踪性能下降快; 后者跟踪性能优于前者, 但是在多目标跟踪时, 由于回波数较多, 回波与目标的数据关联造成计算量增大。本文采用第2种方式的设计结构对单个机动目标进行跟踪。

设每个传感器都可得到两个观测: 方位角 α_i 和俯仰角 β_i , 采用第2种方法的融合结构, 对于 $n(n \geq 2)$ 个传感器组成的被动传感器阵列, 可建立如下的非线性观测模型:

$$Z(k) = H(X(k)) + V(k) \quad (21)$$

式中

$$Z(k) = [z_1(k)^T \quad z_2(k)^T \cdots \quad z_n(k)^T]^T$$

$$= [(\alpha_1, \beta_1)^T \quad (\alpha_2, \beta_2)^T \cdots \quad (\alpha_n, \beta_n)^T]^T \quad (22)$$

$$H(X(k)) = [H_1(X(k))^T \quad H_2(X(k))^T \cdots \quad H_n(X(k))^T]^T \quad (23)$$

$$V(k) = [v_1(k)^T \quad v_2(k)^T \cdots \quad v_n(k)^T]^T \quad (24)$$

$H_i(X(k))$ 为传感器观测与目标位置的非线性方程, 如式(2)中的 $h(x_k, M_k)$, $V(k)$ 为噪声向量。假设观测噪声 $v_i(k)$ ($i = 1, 2, \dots, n$) 任意两两之间互不相关, 则 $V(k)$ 的协方差矩阵 $R(k)$ 为

$$R(k) = E(V(k)V(k)^T) = \text{diag}[\sigma_{\alpha_1}^2 \sigma_{\beta_1}^2, \dots, \sigma_{\alpha_n}^2 \sigma_{\beta_n}^2] \quad (25)$$

需要说明的是, 在实际的被动传感器阵列中, 同一时刻观测到同一目标的传感器数量一般不会超过三个。因此, 从建立的观测模型来看, 观测的维数不会超过六维, 所以不会因为传感器数的增加带来算法的不稳定性。

3 实验结果及分析

为了验证算法的性能, 实验中分别采用仿真路径和一个实测机动目标空情, 考查算法的均方根误差和航迹丢失率。实验中采用被动传感器阵列中三个被动传感器对单个机动目标进行跟踪。站1的位置为(0, 5km, 0), 站2位置为(0, -5km, 0), 站3: (0, 8.66km, 0)。实验中, $P_D = P_G = 1$, $\sigma_\beta = \sigma_\alpha = 1\text{mrad}$, 粒子数为100。采用文献[10]中提及的目标运动模型。

3.1 仿真数据及分析

实验中, 目标初始位置为(2 km, 8 km, 1km), 运动速度为300m/s, 高度1.0km。采样间隔 $T = 1\text{s}$ 。在前30个采样周期内目标作匀速直线运动; 在第30个采样周期后目标以 $6^\circ/\text{s}$ 的转弯率转弯, 转弯持续20个采样周期; 在随后的20个采样周期内目标作匀速直线运动; 在第70个采样周期后目标以 $4.8^\circ/\text{s}$ 的转弯率转弯, 转弯持续25个采样周期; 在随后的5个采样周期内目标作匀速直线运动。

图1给出了本文提出的MMRBPF方法与IMM方法的均方跟踪误差对比结果。可以看出, 在目标转弯时, IMM方法的跟踪误差明显增大; 本文算法虽然误差也有所增大, 但还是能够很好对目标机动进行处理, 跟踪性能要好于IMM




图1 X、Y、Z方向上的均方根误差

方法。

3.2 实测数据及分析

这部分采用某型号雷达采集的一批实际航迹来对算法进行验证。航迹数据中包括 40 个非周期的航迹点, 飞行时间为 107s。由于航迹点为非周期性的, 所以采样间隔 $T = t(k+1) - t(k)$ 也是变化的, 其它条件都不变。其中, k 表示采样次数, $t(k+1)$ 表示 $k+1$ 次采样时的时间, $t(k)$ 表示 k 次采样时的时间。图 2 和图 3 分别给出了 IMM 方法和 MMRBPF 方法的跟踪结果图, 图 4 显示了两种方法的均方根误差对比。从图中可以看出, 在目标没有机动时, 本文算法的性能要稍差于 IMM 算法, 但在目标机动阶段, 提出算法要明显好于 IMM 方法。主要有两个原因: 第一, Kalman 滤波是一种线性最优滤波器, 在非线性时, 扩展 Kalman 滤波对于线性轨迹也具有不错的跟踪性能。第二, 粒子滤波在粒子数不是很多的情况下并不是最优的, 跟踪性能与粒子数通常是成正比, 文中粒子数为 100, 是在运算量和性能中做了一个折中的结果, 但在目标机动阶段, 由于粒子滤波算法具有良好的模型切换机制, 这就使得本文算法能够及时对目标机动做出反应。以上两点就是新方法在匀速运动阶段没有 IMM 方法好, 而在机动阶段要好于 IMM 方法的原因。




图 2 IMM 的跟踪结果




图 3 MMRBPF 的跟踪结果




图 4 均方根估计误差

表 1 给出了两种算法独立运行 100 次的航迹丢失率比较结果。可以看出, 对于仿真轨迹, 提出方法与传统的 IMM 方法一样, 但是对于实测轨迹时, 本文方法要远好于 IMM 方法。提出方法航迹丢失率为 0%, 而 IMM 为 48%。这是由于 IMM 并不能对目标的突然机动作出及时检测, 导致目标丢失。在计算量方面, 由于降低了采样粒子的维数, 本文方法的运行效率要高于一般粒子滤波方法, 但要差于 IMM 方法。

4 结束语

针对被动传感器阵列中的机动目标跟踪问题, 提出了一

表 1 算法的航迹丢失率比较(%)

	IMM	MMRBPF
仿真轨迹	0	0
实测轨迹	48	0

种新的多模 Rao-Blackwellized 粒子滤波新方法。算法将机动目标跟踪问题划分为模型选择和目标跟踪两个子问题; 用粒子滤波对模型进行选择, 在产生模型粒子时考虑了目标最新观测信息, 可以提高模型切换的反应速度, 提高跟踪精度, 同时也降低了采样粒子的维数, 节省了计算量。实验结果表明, 无论对于仿真数据还是实测数据, 本文方法在跟踪性能及航迹丢失率等方面, 都要好于传统的 IMM 方法。当然在算法的实时性方面, 还有待进一步提高。下一步研究计划就是将提出的多模 Rao-Blackwellized 粒子滤波方法推广到杂波环境中的机动目标跟踪。

参考文献

- [1] Bar-shalom Y and Li X. Multitarget _ Multisensor Tracking: Principles and Techniques [M]. Storrs, CT: YBS Publishing, 1995.
- [2] Blom H A P and Bar-shalom Y. The interacting multiple model algorithm for systems with markovian switching coefficients. *IEEE Trans. on Automatic Control*, 1988, 33(8): 780-783.
- [3] Arulampalam M S, Maskell S, and Gordon N. A tutorial on particle filters for on-line nonlinear non-Gaussian Bayesian tracking [J]. *IEEE Trans. on Signal Processing*, 2002, 50(2): 174-188.
- [4] Boers Y and Driessen J N. Interacting multiple model particle filter [J]. *IEE Proc Radar Sonar Navig*, 2003, 150(5): 344-349.
- [5] Sarkka S, Vehtari A, and Lampinen J. Rao-Blackwellized particle filter for multiple target tracking. *Information Fusion*, 2007, (8): 2-15.
- [6] Xu Xinyu and Li Baoxin. Adaptive Rao-Blackwellized particle filter and its evaluation for tracking in surveillance. *IEEE Trans. on Image Processing*, 2007, 16(3): 838-849.
- [7] Casella G and Robert C P. Rao Blackwellisation of sampling schemes. *Biometrika*, 1996, 83(1): 81-94.
- [8] 李良群. 信息融合系统中的目标跟踪及数据关联技术研究. [博士论文], 西安电子科技大学, 2007, 第 4 章.
- [9] 刘宗香, 黄敬雄, 谢维信, 杨烜. 机动目标跟踪中数据互联新方法. *电子与信息学报*, 2007, 29(10): 2292-2295.
- [10] 修建娟, 何友, 王国宏, 修建华. 两站无源定位系统中的多目标跟踪算法研究. *电子学报*, 2002, 30(12): 1763-1767.

李良群: 男, 1979 年生, 博士后, 研究方向为多传感器信息融合、多目标跟踪。

黄敬雄: 男, 1963 年生, 教授, 博士, 研究方向包括智能信息处理、传感器网络、雷达信号处理等。

谢维信: 男, 1941 年生, 教授, 博士生导师, 中国电子学会信号处理分会主任委员, 研究方向为信号处理、智能信息处理、模糊信息处理、雷达目标识别等。