

基于 RBPF 和数据关联的多目标跟踪

杨毅, 吴炜, 杨晓敏, 陈默, 王正勇

(四川大学电子信息学院图像信息研究所, 成都 610064)

摘要: 粒子滤波用一组带有权值的随机采样点近似后验概率密度函数, 实现对任意状态模型的精确估计。把 Rao-Blackwellized 粒子滤波与多假设跟踪算法相结合, 将多目标跟踪问题分为 2 个部分, 即数据关联中后验概率分布的估计和基于数据关联的单个目标跟踪估计。前者通过序列重要性重采样实现, 后者使用卡尔曼滤波进行最小均方误差估计。实验结果表明, 采用最优重要性分布可以减少计算所需粒子数和计算量。

关键词: 卡尔曼滤波; 序列重要性重采样; Rao-Blackwellized 粒子滤波; 多假设跟踪; 最优重要性分布

Multiple Target Track Based on RBPF and Data Association

YANG Yi, WU Wei, YANG Xiao-min, CHEN Mo, WANG Zheng-yong

(Image Information Institute, School of Electronics and Information Engineering, Sichuan University, Chengdu 610064)

【Abstract】 Particle filter approximates to the posterior probability density function with a set of weighted random sample points and realizes accurate estimation of arbitrary state model. It combines Rao-Blackwellized Particle Filter(RBPF) with Multiple Hypothesis Tracking(MHT) and separates multiple target track problem into two parts: estimation of the posterior probability distribution of data association and estimation of the single target track based on the data association. The former can be solved by Sequential Importance Resampling(SIR), and the latter can be solved by minimum mean square error estimation with Kalman filter. Experimental results show that the calculation particle count and the calculation amount can be reduced by using optimal importance distribution.

【Key words】 Kalman filter; sequential importance resampling; Rao-Blackwellized Particle Filter(RBPF); Multiple Hypothesis Tracking(MHT); optimal importance distribution

1 概述

目标跟踪是计算机视觉领域的一个核心问题, 其目的是模拟生理视觉系统的运动感知功能, 赋予机器辨识图像序列中物体运动及其相互关系的能力。传统基于概率估计的目标跟踪方法是卡尔曼滤波^[1], 其后, 学者提出扩展卡尔曼滤波(Extended Kalman Filter, EKF)和无迹卡尔曼滤波(Uncented Kalman Filter, UKF)。粒子滤波方法^[2-3]又称序列蒙特卡罗(Sequential Monte Carlo, SMC)^[4]方法, 通过蒙特卡罗模拟, 实现状态的贝叶斯递推估计。理论上, 当粒子数足够多时, 能逼近真实的后验概率分布, 但在实际中必须考虑跟踪系统的实时性和计算量。

多目标跟踪技术不同于单目标跟踪技术, 主要差别是两者使用的状态空间模型不同。单目标跟踪中目标状态针对单目标建模, 检测到的其他目标都被假设为虚警或杂波, 导致算法在目标交叉或目标靠近时出现误跟。对于多目标跟踪, 由于在观测关联过程中同时考虑了多个目标, 且假设每个时刻每一观测都有唯一的源, 因此能正确跟踪近距离目标和交叉目标。多目标跟踪基本原理如图 1 所示。




图 1 多目标跟踪基本原理

2 Rao-Blackwellized 粒子滤波

2.1 重采样粒子滤波算法

常见的序列重要性采样(Sequential Importance Sampling, SIS)算法存在一个严重缺陷: 经若干次递归后, 只剩一个权重很大(接近 1)的有效粒子, 而其他粒子的权重几乎为零, 即粒子退化问题。当退化现象发生时, 粒子群不能有效表达后验概率密度, 可以采用序列重要性重采样(Sequential Importance Resampling, SIR)策略。重采样的核心思想是繁殖权重大的粒子, 淘汰权重小的粒子。如图 2 所示, 小黑点的面积代表粒子权重, 初始粒子均匀分配权重, 经过一次采样, 淘汰权重较小的粒子, 繁殖权重大的粒子, 并对新的粒子重新均匀分配权重、重采样, 依此循环。




图 2 重采样粒子权重更新策略

作者简介: 杨毅(1982-), 男, 硕士研究生, 主研方向: 目标识别和跟踪; 吴炜、杨晓敏, 博士; 陈默, 博士研究生; 王正勇, 副教授

收稿日期: 2009-11-03 **E-mail:** ee_yang@126.com

2.2 贝叶斯滤波方法

目标跟踪的本质是概率推理问题，解决此类问题的最优方法是贝叶斯滤波，它通过 2 步实现：状态预测和状态更新。贝叶斯滤波的实质是求解后验概率密度的过程，获得目标状态的后验概率，并根据某些准则(如最大后验估计)近似地计算出目标状态值。定义一个基于贝叶斯框架的系统模型： $x_k \in R^n$ 为目标在 k 时刻的状态值， $y_k \in R^d$ 为目标在 k 时刻的测量值， $p(x_k | x_{k-1})$ 为目标的动态模型， $p(y_k | x_k)$ 为目标的测量模型。

2.3 Rao-Blackwellized 粒子滤波算法

状态 x_k 表示所关注的任意变量，如目标二维坐标位置等。引入任意潜在变量 λ ，系统的动态模型和测量模型分别为 $p(x_k | x_{k-1}, \lambda_{k-1})$ 和 $p(y_k | x_k, \lambda_k)$ 。已知重要性分布 $\pi(\lambda_k | \lambda_{k-1}^{(i)}, y_{1:k})$ ，对当前粒子群 $\{\omega_k^{(i)}, \lambda_k^{(i)}, m_k^{(i)}, P_k^{(i)} : i = 1, 2, \dots, N\}$ 进行处理，其中， m 为均值； P 为协方差； ω 为粒子权重； N 为粒子数。在 k 时刻，Rao-Blackwellized 粒子滤波(Rao-Blackwellized Particle Filter, RBPF)^[5]算法的流程如下：

(1)对粒子均值 m 和协方差 P 做卡尔曼滤波预测：

$$m_k^{-(i)} = A_{k-1}(\lambda_{k-1}^{(i)})m_{k-1}^{(i)} \quad (1)$$

$$P_k^{-(i)} = A_{k-1}(\lambda_{k-1}^{(i)})P_{k-1}^{(i)}A_{k-1}^T(\lambda_{k-1}^{(i)}) + Q_{k-1}(\lambda_{k-1}^{(i)}) \quad (2)$$

(2)根据相应的重要性分布，更新潜在变量 $\lambda_k^{(i)}$ ：

$$\lambda_k^{(i)} \sim \pi(\lambda_k | \lambda_{k-1}^{(i)}, y_{1:k}) \quad (3)$$

(3)计算新的权重：

$$\omega_k^{*(i)} \propto \omega_{k-1}^{*(i)} \times \frac{p(y_k | \lambda_k^{(i)}, y_{1:k-1})p(\lambda_k^{(i)} | \lambda_{k-1}^{(i)})}{\pi(\lambda_k | \lambda_{k-1}^{(i)}, y_{1:k})}, i = 1, 2, \dots, N \quad (4)$$

(4)归一化权重：

$$\omega_k^{(i)} = \omega_k^{*(i)} / \sum_{i=1}^N \omega_k^{*(i)} \quad (5)$$

(5)对粒子均值 m 和协方差 P 做卡尔曼滤波更新：

$$m_k^{(i)} = m_k^{-(i)} + K_k^{(i)}[y_k - H_k(\lambda_k^{(i)})m_k^{-(i)}] \quad (6)$$

$$P_k^{(i)} = P_k^{-(i)} - K_k^{(i)}S_k^{(i)}[K_k^{(i)}]^{-1} \quad (7)$$

其中， $S_k^{(i)} = H_k(\lambda_k^{(i)})P_k^{-(i)}H_k^T(\lambda_k^{(i)}) + R_k(\lambda_k^{(i)})$ ； $K_k^{(i)} = P_k^{-(i)}H_k^T(\lambda_k^{(i)})S_k^{-(i)}$ 。

(6)当粒子数量 $n_{\text{eff}} = \frac{1}{\sum_{i=1}^N (\omega_k^{*(i)})^2} < \eta$ (η 是提前设定的阈值)时，进行重采样，粒子分布可近似为

$$p(x_k, \lambda_k | y_{1:k}) \approx \sum_{i=1}^N w_k^{(i)} \delta(\lambda_k - \lambda_k^{(i)}) N(x_k | m_k^{(i)}, P_k^{(i)}) \quad (8)$$

3 基于 RBPF 和多假设跟踪的多目标跟踪算法

把 RBPF 和多假设跟踪(Multiple Hypothesis Tracking, MHT)相结合，提出 RBPF-MHT 算法，将多目标跟踪问题分为 2 个部分：多目标数据关联中后验概率分布的估计和基于数据关联单个目标跟踪的估计。可以分别通过 SIR 和卡尔曼滤波进行最小均方误差(Minimum Mean Squared Error, MMSE)估计解决。将跟踪过程简化为目标判别，辨别当前获得的测量值是属于杂波还是目标 j ，并在此判别基础上对目标 j 进行稳定跟踪。

3.1 数据关联指标 C_k

MHT 理论假设：若测量 $y_i(k)$ 源于已建立的轨迹，则服从高斯概率分布；若测量 $y_i(k)$ 源于杂波，则服从均匀分布。初始目标状态为

$$p(x_{0,j}) = \sum \omega^{(i)} N(x_{0,j} | m_{0,j}^{(i)}, P_{0,j}^{(i)}) \quad (9)$$

(1)已知目标动态模型和测量模型分别为

$$p(x_{k,j} | x_{k-1,j}) = N(x_{k,j} | A_{k-1}x_{k-1,j}, Q_{k-1,j}) \quad (10)$$

$$p(y_k | x_{k,j}, c_k = j) = N(y_k | H_{k,j}x_{k,j}, R_{k,j}) \quad (11)$$

当系统非线性非高斯时，使用 EKF 近似估计：

$$p(x_{k,j} | x_{k-1,j}) = N(x_{k,j} | f(x_{k-1,j}, k-1), Q_{k-1,j}) \quad (12)$$

$$p(y_k | x_{k,j}, c_k = j) = N(y_k | h(x_{k-1,j}, k-1), R_{k,j}) \quad (13)$$

(2)杂波或虚警服从均匀分布：

$$p(y_k | c_k = 0) = 1/V \quad (14)$$

其中， c_k 是数据关联指标。 $c_k = 0$ 时关联为杂波， $c_k = j$ 时关联为第 j 个目标。 c_k 服从 m 级马尔可夫模型，设 c_k 服从 0 级马尔可夫模型： $p(c_k | c_{k-1}) = p(c_k)$ 。 A_{k-1} 是转移矩阵， $H_{k,j}$ 是测量模型矩阵。

3.2 最优重要性分布

RBPF-MHT 需要获得一个最优的重要性分布，其选取满足 2 个基本原则：易于采样和易于估计采样概率密度函数。理想的重要性分布通常定义为

$$\pi(x_k | x_{k-1}, y_{1:k}) = p(x_k | x_{k-1}, y_{1:k}) \quad (15)$$

引入数据关联指标 c_k 后，设定该最优分布为 $\pi(c_k | y_{1:k}, c_{k-1}^{(i)})$ ，根据贝叶斯定律有

$$p(c_k | y_{1:k}, c_{k-1}^{(i)}) \propto p(y_k | c_k, y_{1:k-1}, c_{k-1}^{(i)}) \times p(c_k | c_{k-1}^{(i)}) \quad (16)$$

对边缘测量似然：

$$p(y_k | c_k, y_{1:k-1}, c_{k-1}^{(i)}) = \begin{cases} 1/V & \text{if } c_k = 0 \\ KF_{th}(y_k, m_{j,k}^{-(i)}, P_{j,k}^{-(i)}, H_{j,k}, R_{j,k}) & \text{if } c_k = j \end{cases} \quad (17)$$

其中， $KF_{th}(\bullet)$ 表示卡尔曼滤波测量的似然估计； $H_{j,k}$ 表示测量模型矩阵； $R_{j,k}$ 表示目标 j 的测量协方差矩阵。

3.3 RBPF-MHT 算法实现

在 MHT 框架下利用 RBPF 算法对多目标实施跟踪，设数据关联指标 c_k 等价于任意潜在变量 λ ，即 $\lambda_k = c_k$ ，从而使计算简化为对每个目标进行卡尔曼预测和更新以及测量似然的估计，而不用对系统联合状态进行处理。RBPF-MHT 算法描述的粒子群为

$$\{c_{k-m+1}^{(i)}, m_{k,1}^{(i)}, m_{k,2}^{(i)} \dots m_{k,j}^{(i)} \dots m_{k,T}^{(i)}, P_{k,1}^{(i)}, P_{k,2}^{(i)} \dots P_{k,j}^{(i)} \dots P_{k,T}^{(i)}, \omega_k^{(i)}\} \quad (18)$$

归纳出 RBPF-MHT 算法的 3 个关键要素：

(1)测量 y_k 的似然估计 $p(y_k | c_k, y_{1:k-1}, c_{k-1}^{(i)})$ 。

(2)数据关联指标 c_k 的预测概率 $p(c_k | c_{k-1}^{(i)})$ 。

(3)最优的重要性分布 $p(c_k | y_{1:k}, c_{k-1}^{(i)})$ 。

RBPF-MHT 框架下的 SIR 算法描述如下：

对 $i = 1, 2, \dots, N$ ，做如下处理：

(1)基于最优重要性分布，对数据关联指标 c_k 采样，即

$$c_k^{(i)} \sim p(c_k^{(i)} | y_{1:k}, c_{k-1}^{(i)})$$

(2)计算粒子新的权重值：

$$\omega_k^{*(i)} \propto \omega_{k-1}^{*(i)} \times \frac{p(y_k | c_k^{(i)}, y_{1:k-1}, c_{k-1}^{(i)})p(c_k^{(i)} | c_{k-1}^{(i)})}{p(c_k | c_{k-1}^{(i)}, y_{1:k})}$$

(3)归一化权重值：


$$\omega_k^{(i)} = \omega_k^{*(i)} / \sum_{i=1}^N \omega_k^{*(i)}$$

(4)当 $n_{\text{eff}} < \eta$ 时，进行重采样。

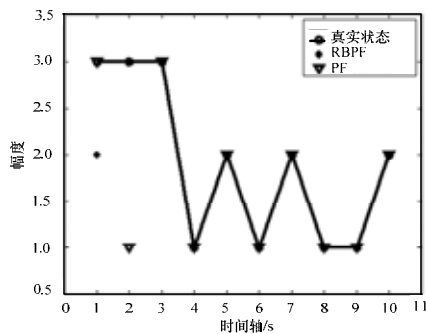
4 实验仿真

本文设计了 3 个不同的实验。第 1 个实验比较粒子滤波(Particle Filter, PF)与 RBPF，实验基于最大后验概率估计，粒子数 $N=100$ 。如图 3 所示，PF 在 $t=1, 2, 3$ 时刻共 3 个点出现错误，RBPF 在 $t=1$ 时刻出现错误。当粒子数 $N=200$ 时，PF 在 $t=2$ 时刻出现错误，RBPF 在 $t=1$ 时刻出现错误。随着粒子数量的增加，PF 算法的精度提高，RBPF 算法变化很小，但 PF 性能提高以牺牲计算量为代价，其粒子数量提高 1 倍。当

粒子数量维持在较低水平时, RBPF 具有优越性, 即以较少的粒子数达到较好的估计效果。



(a) 粒子数 $N=100$



(b) 粒子数 $N=20$

图 3 PF 与 RBPF 算法的比较

第 2 个实验基于 RBPF-MHT 进行单目标跟踪。设定如下场景: 二维空间中任意一个目标, 加入随机噪声(为了更好地模拟真实情形)。单目标稳定跟踪如图 4 所示, 其中, 散乱点表示随机噪声; 虚线表示真实轨迹; 实线是实验估计结果。

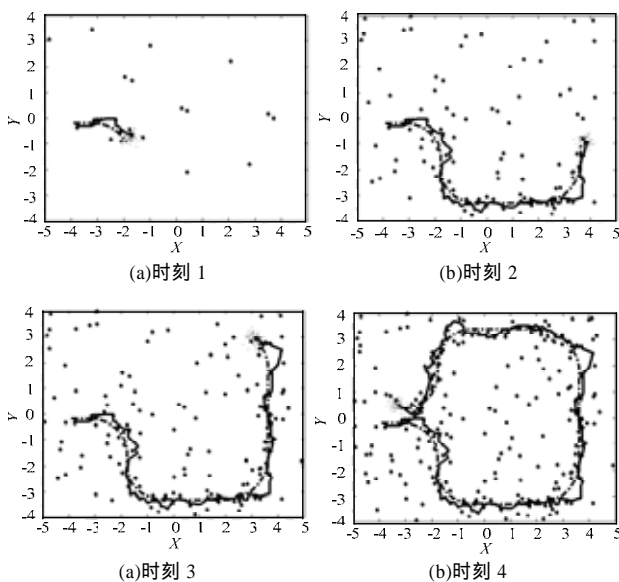




图 4 单目标跟踪(粒子数 $N=100$)

第 3 个实验基于 RBPF-MHT 进行多目标跟踪, 设定目标数量 $m=3$, 3 条曲线作为目标运动轨迹, 包括 2 条直线和一条半圆弧, 目标运动的方向分别为从下至上、从左至右、沿半圆弧逆时针, 不同目标会在交点相会, 实验结果见图 5(a)。

实验结果显示, 对 3 个不同目标的跟踪达到了很好效果, 实时跟踪稳定。在 PF 算法中, 通过增加粒子数量, 能得到更好的效果。在本实验中, 小幅度增加粒子数量对实验效果的改善并不明显, 验证了 RBPF-MHT 算法对粒子数量需求不敏感的结论。任意 2 个目标交叉或靠近时, 算法能稳定跟踪源目标, 如图 5(b)所示。



(a) 对 3 个目标的实时跟踪



(b) 最终轨迹

图 5 对 3 个目标的实时跟踪及其结果(粒子数 $N=100$)

5 结束语

基于粒子滤波的目标跟踪在交通监控、自主导航和人体跟踪等领域有十分重要的应用。传统粒子滤波算法要达到较好跟踪效果, 需要足够多的粒子, 其计算量巨大。而现实中通常需要跟踪系统具有实时性和稳定性。RBPF-MHT 算法通过采用最优的重要性分布, 有效降低了计算压力。如何进一步降低跟踪系统对计算能力的需求, 实现对未知目标的检测和稳定跟踪等, 是下一步的研究方向。

参考文献

- [1] Kalman R E. A New Approach to Linear Filtering and Prediction Problems[J]. Journal of Basic Engineering, 1960, 82: 34-45.
- [2] Gordon N J, Salmond D J, Smith A F M. Novel Approach to Nonlinear/Non-Gaussian Bayesian State Estimation[J]. IEEE Proceedings of Radar and Signal Processing, 1993, 140(2): 107-113.
- [3] 崔平远, 郑黎方, 裴福俊. 基于自调整粒子滤波的组合导航方法研究[J]. 计算机工程, 2008, 34(14): 185-187.
- [4] Doucet A, Godsill S, Andrieu C. On Sequential Monte Carlo Sampling Methods for Bayesian Filtering[J]. Statistics and Computing, 2000, 10(3): 197-208.
- [5] Särkkä S, Vehtari A, Lampinen J. Rao-Blackwellized Particle Filter for Multiple Target Tracking[J]. Information Fusion, 2007, 8(1): 2-15.

编辑 陈 晖