

用于机动目标跟踪的多模型概率假设密度滤波器

王晓, 韩崇昭

(西安交通大学电子与信息工程学院, 710049, 西安)

摘要: 针对概率假设密度(PHD)滤波器在多目标跟踪问题中无法解决目标发生较大机动时的目标丢失问题,提出了一种多模型概率假设密度(MM-PHD)滤波器. 这种 MM-PHD 滤波器在粒子 PHD 滤波器的基础上,使用多模型方法对滤波器中每个描述目标状态的粒子的状态进行更新,再将更新后的粒子代入传统的 PHD 滤波器中用于估计目标的 PHD 的分布. 该滤波器结合 PHD 滤波器和多模型方法的特点,可用于目标数未知的多机动目标跟踪,且对目标的数量和状态的估计更加准确. 多机动目标跟踪的仿真实验表明,与已有方法相比,该滤波器对目标数的估计与真实情况基本一致,描述多目标状态估计误差的 Wasserstein 距离值降低了 50% 以上.

关键词: 机动目标跟踪; 概率假设密度; 多模型; 估计

中图分类号: TP274 **文献标志码:** A **文章编号:** 0253-987X(2011)12-0001-05

A Probability Hypothesis Density Filter with Multiple Models for Maneuvering Target Tracking

WANG Xiao, HAN Chongzhao

(Schools of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A multiple model probability hypothesis density (MM-PHD) filter is proposed to solve the track loss problem of PHD filter in highly maneuvering targets tracking. The MM-PHD filter bases on the particle PHD filter, and updates the state of the particles using the multiple model method. Then the updated state of the particles is used to evaluate the PHD distribution of the targets. The filter combines the features of both the PHD filter and the multiple model method and can deal with multi-targets' maneuvering with the number of targets unknown. The proposed filter estimates the number and the state of the targets more accurately than the existing filters do. Simulation results and comparisons with existing algorithms show that the number of targets estimated by the proposed algorithm is consistent with the real situation and the Wasserstein distance value that describes the estimation error decreases more than 50%.

Keywords: maneuvering target tracking; probability hypothesis density; multiple model; estimation

目标跟踪是利用探测器所获得的运动目标的量测,确定所关注区域内目标的数量、位置及速度等状态,在国防与民用领域均具有重要的应用价值. 基于数据关联的跟踪方法在机动目标跟踪领域已得到广

泛应用^[1-2]. 但是,数据关联本身十分复杂,同时数据关联方法无法处理目标数变化时的情况. Mahler^[3]提出的概率假设密度(probability hypothesis density, PHD)为直接估计目标数量、解决目标跟踪问题

收稿日期: 2011-04-25. 作者简介: 王晓(1978—),男,博士生;韩崇昭(通信作者),男,教授,博士生导师. 基金项目: 国家自然科学基金创新研究群体科学基金资助项目(60921003);国家“973 计划”资助项目(2007CB311006);国家自然科学基金资助项目(61074176).

网络出版时间: 2011-09-13

网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20110913.0900.003.html>

提供了新的途径. PHD 滤波器反映了 PHD 分布的变化过程, 在观测区域里, 目标数量可由 PHD 的积分求得, 目标位置可由 PHD 分布的峰值确定. PHD 滤波器目前常用的实现方式有粒子滤波 PHD(PF-PHD)^[3-4] 和高斯混合 PHD(GM-PHD)^[5]. PF-PHD 通过蒙特卡罗统计方法, 使用大量粒子模拟观测空间中的 PHD 分布. 与其他的滤波方法一样, PHD 滤波器在进行目标跟踪滤波时, 同样需要对目标的运动模式进行建模. 当观测的目标做机动运动时, 通常处理起来比较困难, 主要的困难在于目标运动模式的不确定性. 滤波器中模型的正确与否对滤波结果有重要影响. 此时如果增加滤波器中目标运动模型的过程噪声, 即加大运动模型的不确定性, 则可在一定程度上保证滤波器不致失跟. 在 PF-PHD 中, 这样做可增加粒子的采样范围, 但主要会带来 2 个缺点: ①采样范围扩大后如要保证单位空间内的采样密度, 需增加采样粒子数; ②采样范围扩大后在杂波密度不变的情况下增加了杂波对滤波结果的影响. 多模型方法是处理目标机动的一种有效方法. 文献[6]提出了一种多模型 PF-PHD, 该方法的本质在于通过多模型采样增加采样粒子的覆盖范围, 经过重采样后, 由与目标运动模式一致的模型生成的粒子会被自动挑选出来, 不同模型生成的粒子之间没有进行融合.

本文提出了一种利用多模型方法更新采样粒子分布的多模型 PF-PHD 滤波器, 与文献[6]中的方法相比, 该算法对目标数量和状态的估计更加准确.

1 问题描述

1.1 随机有限集模型和 PHD

在随机有限集理论中, 一个目标的运动状态为 $\mathbf{x}$, n_x 个目标的状态为一个有限集合 $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_{n_x}\}$, 单个量测值为 $\mathbf{z}$, n_z 个量测为集合 $\mathbf{Z} = \{\mathbf{z}_1, \dots, \mathbf{z}_{n_z}\}$. 随机集的概率假设密度 $D_{k|k}(\mathbf{x}_k | \mathbf{Z}_{1:k})$ 在状态空间的任意区域 S 的积分 $\int_S D_{k|k}(\mathbf{x}_k | \mathbf{Z}_{1:k}) d\mathbf{x}_k$ 是在区域 S 内目标数量的期望值. PHD 滤波器包括预测和更新 2 个步骤^[3].

(1) 预测步

$$D_{k|k-1}(\mathbf{x}_k | \mathbf{Z}_{1:k-1}) = \gamma_k(\mathbf{x}_k) + \int \varphi_{k|k-1}(\mathbf{x}_k, \mathbf{x}_{k-1}) D_{k-1|k-1}(\mathbf{x}_{k-1} | \mathbf{Z}_{1:k-1}) d\mathbf{x}_{k-1} \quad (1)$$

式中: $\gamma_k(\mathbf{x}_k)$ 为新生目标的随机集的出生强度; $\varphi_{k|k-1}(\mathbf{x}_k, \mathbf{x}_{k-1}) = b_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1}) + e_{k|k-1}(\mathbf{x}_{k-1}) \cdot$

$f_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1})$, 其中 $b_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1})$ 为由 $k-1$ 时刻状态 $\mathbf{x}_{k-1}$ 衍生出的目标的衍生强度, $e_{k|k-1}(\mathbf{x}_{k-1})$ 为目标的存在概率, $f_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1})$ 为单个目标的状态转移概率密度.

(2) 更新步

$$D_{k|k}(\mathbf{x}_k | \mathbf{Z}_{1:k}) = D_{k|k-1}(\mathbf{x}_k | \mathbf{Z}_{1:k-1}) [1 - p_{D,k}(\mathbf{x}_k) + \sum_{z_k \in \mathbf{Z}_k} \frac{\Psi_{k,z_k}(\mathbf{x}_k)}{\kappa_k(\mathbf{z}_k) + \int \Psi_{k,z_k}(\mathbf{x}_k) D_{k|k-1}(\mathbf{x}_k | \mathbf{Z}_{1:k-1}) d\mathbf{x}_k}] \quad (2)$$

式中: $\Psi_{k,z_k}(\mathbf{x}_k) = p_{D,k}(\mathbf{x}_k) g_{k|k}(\mathbf{z}_k | \mathbf{x}_k)$, $p_{D,k}(\mathbf{x}_k)$ 为检测概率; $g_{k|k}(\mathbf{z}_k | \mathbf{x}_k)$ 为每个目标的似然函数; $\kappa_k(\mathbf{z}_k)$ 为杂波强度.

1.2 粒子 PHD 滤波器

粒子滤波是一种基于蒙特卡罗仿真的统计计算方法, 在机动目标跟踪中, 它可以处理非线性非高斯问题^[7]. PHD 在演化过程中存在积分运算, 当用解析表达式无法表述时, 粒子滤波是一种合适的选择. 粒子滤波的基础是序贯重要性采样, 所需分布的后验密度可用随机采样粒子的加权和近似表述^[8]. 在粒子 PHD 滤波器中, 用采样粒子的分布来近似表述 PHD 的分布情况. 给定 $k-1$ 时刻的粒子 $\{\omega_{k-1}^{(i)}, \mathbf{x}_{k-1}^{(i)}\}_{i=1}^{L_{k-1}}$, PF-PHD 的主要计算过程如下^[4].

(1) 预测步: 对于 $i = 1, \dots, L_{k-1}$, 抽取 $\tilde{\mathbf{x}}_k^{(i)} \sim q_k(\mathbf{x}_k | \mathbf{x}_{k-1}^{(i)}, \mathbf{Z}_k)$, 计算预测粒子权重

$$\tilde{\omega}_{k|k-1}^{(i)} = \frac{\varphi_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)}, \mathbf{x}_{k-1}^{(i)})}{q_k(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{Z}_k)} \omega_{k-1}^{(i)} \quad (3)$$

对于 $i = L_{k-1} + 1, \dots, L_{k-1} + J_k$, J_k 是 k 时刻对新生目标所抽取的粒子数, 抽取 $\tilde{\mathbf{x}}_k^{(i)} \sim p_k(\mathbf{x}_k | \mathbf{Z}_k)$, 计算预测粒子权重

$$\tilde{\omega}_{k|k-1}^{(i)} = \frac{1}{J_k} \frac{\gamma_k(\tilde{\mathbf{x}}_k^{(i)})}{p_k(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{Z}_k)} \quad (4)$$

(2) 更新步: 对于量测 $\mathbf{z} \in \mathbf{Z}_k$, 计算

$$C_k(\mathbf{z}) = \sum_{j=1}^{L_{k-1}+J_k} \Psi_{k,z}(\tilde{\mathbf{x}}_k^{(j)}) \tilde{\omega}_{k|k-1}^{(j)} \quad (5)$$

对于 $i = 1, \dots, L_{k-1} + J_k$, 计算更新权重

$$\tilde{\omega}_k^{(i)} = [1 - p_{D,k}(\mathbf{x}_k^{(i)}) + \sum_{z_k \in \mathbf{Z}_k} \frac{\Psi_{k,z_k}(\mathbf{x}_k^{(i)})}{\kappa_k(\mathbf{z}_k) + C_k(\mathbf{z}_k)}] \tilde{\omega}_{k|k-1}^{(i)} \quad (6)$$

(3) 重采样步: k 时刻的 PHD 分布情况体现在 $\{\tilde{\omega}_k^{(i)}, \tilde{\mathbf{x}}_k^{(i)}\}_{i=1}^{L_{k-1}+J_k}$ 中, 所有粒子权重的加权和为

目标数量的预测值,即 $\hat{N}_{k|k} = \sum_{j=1}^{L_{k-1}+J_k} \tilde{\omega}_k^{(j)}$. 对粒子 $\{(\tilde{\omega}_k^{(i)}/\hat{N}_{k|k}), \tilde{\mathbf{x}}_k^{(i)}\}_{i=1}^{L_{k-1}+J_k}$ 进行重采样后得到粒子 $\{(\omega_k^{(i)}/\hat{N}_{k|k}), \mathbf{x}_k^{(i)}\}_{i=1}^{L_k}$, 调整权重后得到 $\{\omega_k^{(i)}, \mathbf{x}_k^{(i)}\}_{i=1}^{L_k}$ 用于 $k+1$ 时刻的计算.

利用状态提取算法可从重采样后的粒子 $\{\omega_k^{(i)}, \mathbf{x}_k^{(i)}\}_{i=1}^{L_k}$ 中提取所需的目标状态信息.

2 多模型粒子 PHD 滤波器

当目标进行高机动运动时,目标状态估计面临目标运动模式不确定的困难. 多模型方法通过使用滤波器中模型组合的方式解决运动模式不确定的问题. 交互多模型(interacting multiple model, IMM) 是一种最普遍使用的多模型方法,其主要步骤包括模型条件重初始化、模型条件滤波、模型概率更新和估计融合^[9].

采用 PHD 滤波器对每个目标的机动运动做出正确跟踪是一个重要而且困难的问题. 由于滤波器将所有目标的状态及其量测都看作是一组变量的集合,无法对某个确定的目标进行区分,但滤波器需要对某个特定的目标的机动做出相应处理. 本文提出的 MM-PHD 滤波器,对每个存在目标的抽样粒子使用多模型方法估计它们的状态,利用量测数据更新每个已存在目标抽样粒子的状态,而对于所有目标的粒子集合,仍使用 PHD 滤波器的演化过程(式(3)、式(4))对其进行更新.

在 PF-PHD 滤波器的预测步,对于存在目标和衍生目标,抽取粒子 $\tilde{\mathbf{x}}_k^{(i)} \sim q_k(\mathbf{x}_k | \mathbf{x}_{k-1}^{(i)}, \mathbf{Z}_k)$, 粒子的预测权重为

$$\tilde{\omega}_{k|k-1}^{(i)} = \frac{\varphi_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)}, \mathbf{x}_{k-1}^{(i)})}{q_k(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{Z}_k)} \omega_{k-1}^{(i)} = \frac{b_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}) + e_{k|k-1}(\mathbf{x}_{k-1}^{(i)}) f_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})}{q_k(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{Z}_k)} \quad (7)$$

式中: $b_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})$ 是衍生粒子的强度函数,对 $b_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})$ 有 $b_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}) = \gamma_{k|k-1}(\mathbf{x}_{k-1}^{(i)}) \cdot f_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}); \gamma_{k|k-1}(\mathbf{x}_{k-1}^{(i)})$ 为从 $k-1$ 时刻的粒子 $\mathbf{x}_{k-1}^{(i)}$ 衍生出粒子的概率; $f_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})$ 为概率密度函数,在没有关于衍生粒子信息的情况下,密度函数可取为存在目标的状态转移概率密度函数.

如果取重要性抽样函数 $q_k(\mathbf{x}_k | \mathbf{x}_{k-1}^{(i)}, \mathbf{Z}_k) = f_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1}^{(i)})$, 则有

$$\tilde{\omega}_{k|k-1}^{(i)} = \gamma_{k|k-1}(\mathbf{x}_{k-1}^{(i)}) + e_{k|k-1}(\mathbf{x}_{k-1}^{(i)}) \quad (8)$$

即粒子预测权重与预测粒子状态 $\tilde{\mathbf{x}}_k^{(i)}$ 无关. 因此,可以利用多模型方法对粒子状态 $\tilde{\mathbf{x}}_k^{(i)}$ 进行更新,同时不影响粒子的预测权重.

假设 k 时刻多模型系统中的第 m 个模型为 $s_k^m = \{s_k = m\}, m=1, \dots, M$, 则该模型的方程为

$$\left. \begin{aligned} \mathbf{x}_k &= f_{k|k-1}^m(\mathbf{x}_{k-1}, \mathbf{w}_k^m) \\ \mathbf{z}_k &= g_k^m(\mathbf{x}_k, \mathbf{v}_k^m) \end{aligned} \right\} \quad (9)$$

式中: $\mathbf{w}_k^m$ 和 $\mathbf{v}_k^m$ 分别是过程噪声和量测噪声,其协方差阵分别为 $\mathbf{Q}_k^m$ 和 $\mathbf{R}_k^m$.

对于 $i=1, \dots, L_{k-1}$, 抽取 $\tilde{\mathbf{x}}_k^{(i),m} \sim f_{k|k-1}^m(\mathbf{x}_{k-1}^{(i)}, m=1, \dots, M)$, 由式(9)有

$$\tilde{\omega}_{k|k-1}^{(i),1} = \dots = \tilde{\omega}_{k|k-1}^{(i),M} = \gamma_{k|k-1}(\mathbf{x}_{k-1}^{(i)}) + e_{k|k-1}(\mathbf{x}_{k-1}^{(i)}) \quad (10)$$

定义每个粒子 i 对于每个模型 m 的似然函数为

$$L_k^{(i),m} = \max_{j=1,2,\dots,n_{z_k}} (p[\mathbf{z}_j | \tilde{\mathbf{x}}_k^{(i),m}]), \quad i=1, \dots, L_{k-1}; \quad m=1, \dots, M \quad (11)$$

式中: n_{z_k} 为 k 时刻的量测个数. 在这里假定与粒子 $\tilde{\mathbf{x}}_k^{(i),m}$ 最接近的量测数据就是该粒子对应目标的量测. 对于每个粒子 $\tilde{\mathbf{x}}_k^{(i),m}$, 定义模型概率 $\mu_k^{(i),m} = \frac{\mu_{k|k-1}^{(i),m} L_k^{(i),m}}{\sum_m \mu_{k|k-1}^{(i),m} L_k^{(i),m}}$, 其中 $\mu_{k|k-1}^{(i),m}$ 是预测模型概率, $\mu_{k|k-1}^{(i),m} = \sum_j \pi_{jm} \mu_{k-1}^{(i),m}$, π_{jm} 是模型转移概率, $\pi_{jm} = P(s_k = m | s_{k-1} = j)$.

当 $i=1, \dots, L_{k-1}$ 时,由每个模型抽样得到的粒子 $\tilde{\mathbf{x}}_k^{(i),1}, \dots, \tilde{\mathbf{x}}_k^{(i),M}$ 和模型概率 $\mu_k^{(i),1}, \dots, \mu_k^{(i),M}$ 可得到多模型的混合粒子

$$\tilde{\mathbf{x}}_k^{(i)} = \sum_m \tilde{\mathbf{x}}_k^{(i),m} \mu_k^{(i),m} \quad (12)$$

由式(11)可得每个混合粒子的预测权重

$$\tilde{\omega}_{k|k-1}^{(i)} = \gamma_{k|k-1}(\mathbf{x}_{k-1}^{(i)}) + e_{k|k-1}(\mathbf{x}_{k-1}^{(i)}) \quad (13)$$

至此,我们完成了对存在和衍生目标的多模型的混合粒子抽样与粒子预测权重的计算,得到 $\{\tilde{\mathbf{x}}_k^{(i)}, \tilde{\omega}_{k|k-1}^{(i)}\}_{i=1}^{L_{k-1}}$, 和每个粒子的模型权重 $\boldsymbol{\mu}_k^{(i)} = [\mu_k^{(i),1}, \dots, \mu_k^{(i),M}]^T$.

对于新生目标,使用传统的粒子 PHD 滤波器方法完成采样和预测权重的计算. 对新生粒子 $\tilde{\mathbf{x}}_k^{(i)}, i=L_{k-1}+1, \dots, L_{k-1}+J$, 其模型权重可设为 $\mu_k^{(i),m} = 1/M, m=1, \dots, M$.

对粒子 $\{\tilde{\mathbf{x}}_k^{(i)}, \tilde{\omega}_{k|k-1}^{(i)}\}_{i=1}^{L_{k-1}+J}$ 进行更新计算后得到 $\{\tilde{\mathbf{x}}_k^{(i)}, \tilde{\omega}_k^{(i)}\}_{i=1}^{L_{k-1}+J}$, 将 $\{\tilde{\mathbf{x}}_k^{(i)}, \tilde{\omega}_k^{(i)}\}_{i=1}^{L_{k-1}+J}$ 与 $\{\mu_k^{(i)}\}_{i=1}^{L_{k-1}+J}$

起重采样后得到 $\{\tilde{\mathbf{x}}_k^{(i)}, \tilde{\omega}_k^{(i)}, \mu_k^{(i)}\}_{i=1}^{L_k}$ 用于 $k+1$ 时刻的计算. 滤波器在初始化时, $\{\tilde{\mathbf{x}}_0^{(i)}, \tilde{\omega}_0^{(i)}, \mu_0^{(i)}\}_{i=1}^{L_0}$ 中 $\{\tilde{\mathbf{x}}_0^{(i)}, \tilde{\omega}_0^{(i)}\}_{i=1}^{L_0}$ 与粒子 PHD 滤波器相同, 模型概率 $\mu_0^{(i)}$ 的各分量可取 $\mu_0^{(i),m}=1/M, m=1, \dots, M$.

与文献[6]算法相比, 本文算法利用新息更新每个粒子的状态, 所得到的用于描述 PHD 分布的粒子更加集中. 同时, 本文算法具有 IMM 的优点, 即滤波器模型集中的单一模型无法与目标运动模式完全匹配时, 也可通过多个模型加权方式近似匹配目标的真实运动模式.

3 仿真分析

模拟一个二维平面区域 $[-1 \text{ km}, 1 \text{ km}] \times [-1 \text{ km}, 1 \text{ km}]$ 内的多目标机动跟踪问题. 系统每个运动目标模型为

$$\left. \begin{aligned} \mathbf{x}_k &= \mathbf{F}_{k|k-1} \mathbf{x}_{k-1} + \mathbf{w}_k \\ \mathbf{z}_k &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \mathbf{x}_k + \mathbf{v}_k \end{aligned} \right\} \quad (14)$$

每个目标的状态 $\mathbf{x}_k = [x_{k1}, x_{k2}, x_{k3}, x_{k4}]^T$ 包括位置变量 $[x_{k1}, x_{k3}]^T$ 、速度变量 $[x_{k2}, x_{k4}]^T$, 量测 $\mathbf{z}_k = [z_{k1}, z_{k2}]^T$ 为位置变量. $\mathbf{F}_{k|k-1}$ 是状态转移矩阵, $\mathbf{w}_k$ 是过程噪声, 其协方差阵为 $\mathbf{Q}_k = \text{diag}([225 \text{ m}^2, 100 (\text{m/s})^2, 225 \text{ m}^2, 100 (\text{m/s})^2])^T$, $\mathbf{v}_k$ 是量测噪声, 协方差阵为 $\mathbf{R}_k = \text{diag}([100 \text{ m}^2, 100 \text{ m}^2])^T$.

在仿真场景中, 模型可在任何时刻产生或消失. 每个目标的生存概率 $e_{k|k-1}(\mathbf{x}_{k-1}) = 0.95$, 衍生概率 $\gamma_k(\mathbf{x}_{k-1}) = 0.05$. 新生目标的强度函数为 $\gamma_k(\mathbf{x}_k) = 0.1N(\cdot | \bar{\mathbf{x}}, \mathbf{Q})$, 其中 $\bar{\mathbf{x}} = [-400 \text{ m}, 60 \text{ m/s}, -200 \text{ m}, -10 \text{ m/s}]^T$, $\mathbf{Q} = \text{diag}([100 \text{ m}^2, 10 (\text{m/s})^2, 100 \text{ m}^2, 10 (\text{m/s})^2])^T$. 杂波均匀分布在观测空间 $[-1 \text{ km}, 1 \text{ km}] \times [-1 \text{ km}, 1 \text{ km}]$, 每个扫描周期杂波个数均值 $\lambda = 50$. 粒子的状态提取算法使用 k -均值方法.

使用一个 CV 和 2 个 CT 模型组成多模型粒子 PHD 滤波器. 各模型的状态转移阵分别为

$$\mathbf{F}_{k|k-1}^{\text{CV}} = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (15)$$

$$\mathbf{F}_{k|k-1}^{\text{CT}} = \begin{bmatrix} 1 & \frac{\sin \omega T}{\omega} & 0 & -\frac{\cos \omega T - 1}{\omega} \\ 0 & \cos \omega T & 0 & -\sin \omega T \\ 0 & \frac{1 - \cos \omega T}{\omega} & 1 & \frac{\sin \omega T}{\omega} \\ 0 & \sin \omega T & 0 & \cos \omega T \end{bmatrix} \quad (16)$$

式中: T 是量测数据的时间间隔; ω 是 CT 模型中的转弯角速度. 仿真中取 $T=1 \text{ s}$, $\omega = \pm 0.8 \text{ rad/s}$. 各模型的概率转移矩阵是

$$\mathbf{\Pi} = \begin{bmatrix} 0.9 & 0.05 & 0.05 \\ 0.05 & 0.9 & 0.05 \\ 0.05 & 0.05 & 0.9 \end{bmatrix} \quad (17)$$

图 1 描述了 3 个目标在杂波环境中 30 个量测周期的机动运动情况. 目标 1 在 1 s 起始于状态 $[-800 \text{ m}, 45 \text{ m/s}, 750 \text{ m}, -60 \text{ m/s}]^T$, 消失于 28 s, 从 1 s 到 19 s 作 CV 运动, 从 20 s 到 23 s 以 $\omega = -0.8 \text{ rad/s}$ 作 CT 运动, 从 24 s 到 28 s 以 $\omega = 0.4 \text{ rad/s}$ 作 CT 运动; 目标 2 在 2 s 起始于状态 $[-400 \text{ m}, 60 \text{ m/s}, -200 \text{ m}, -10 \text{ m/s}]^T$, 消失于 22 s, 从 2 s 到 7 s 以 $\omega = 0.4 \text{ rad/s}$ 作 CT 运动, 从 8 s 到 17 s 以作 CV 运动, 从 18 s 到 22 s 以 $\omega = -0.8 \text{ rad/s}$ 作 CT 运动; 目标 3 在 6 s 衍生于目标 1, 消失于 30 s, 从 6 s 到 18 s 作 CV 运动, 从 19 s 到 21 s 以 $\omega = 0.8 \text{ rad/s}$ 作 CT 运动, 从 22 s 到 30 s 以 $\omega = -0.4 \text{ rad/s}$ 作 CT 运动.




图 1 3 个目标的真实轨迹及杂波

通过 100 次蒙特卡罗仿真实验, 对比了本文算法与文献[6]算法的目标数量估计的均值, 如图 2 所示. 本文使用 Wasserstein 距离 (Wasserstein Distance, WD)^[4] (d_w) 对估计结果进行分析. 图 3 对比了本文算法和文献[6]算法的 d_w 结果. 从图 2 和图 3 可以看出, 本文提出的算法在处理目标机动时的结果明显优于文献[6]中的算法. 文献[6]中仅使用多模型对 PHD 粒子进行采样, 在处理模型集中的模型无法与目标的真实运动模式匹配的机动运动时, 滤波结果可能会产生较大误差, 此时本文算法的 WD 值比文献[6]的降低 50% 以上.

图 4 比较了 2 种算法单步估计的运算时间. 从图中可以看出, PF-PHD 算法中的运算时间主要由




图 2 2 种算法的目标数量估计均值




图 3 2 种算法的 WD 结果




图 4 2 种算法的计算时间对比

粒子滤波器中每个目标对应的粒子数量 n 决定,在仿真中分别取 $n=100, 300, 500$. 在每个目标粒子数相同的情况下,本文算法的计算时间要多于文献[6]的算法. 文献[6]算法在粒子采样过程中需要对生成粒子的每个模型进行采样,然后根据抽取的模型再对 PHD 粒子进行抽样,由于抽取的粒子总数并未发生改变,因而该算法的运算时间与单模型 PF-PHD 基本相同. 本文提出的算法需对每个存在和衍生目标对应的粒子进行多模型采样,并将多模型采样的结果进行融合以确定最终的采样粒子状态,因而在粒子采样时增加了运算时间,增加的时间由多模型算法中模型的数目决定.

4 结 论

PHD 滤波器可用于目标数未知时杂波环境下

的目标跟踪. 当目标发生机动时,滤波器要处理运动模式不确定带来的困难,多模型方法是解决此类问题的有效手段. 本文提出了一种将多模型方法用于 PHD 滤波器的实现方式,理论分析和仿真实验证明了算法的合理性和有效性. 与已有的算法相比,本文提出的算法在处理目标机动时在计算性能上具有明显优势,但计算时需付出一些时间代价.

参考文献:

- [1] 潘泉,叶西宁,张洪才. 广义概率数据关联算法[J]. 电子学报,2005,33(3):467-472.
PAN Quan, YE Xining, ZHANG Hongcai. Generalized probability data association algorithm[J]. Acta Electronica Sinica, 2005,33(3):467-472.
- [2] 韩崇昭,李晨,朱洪艳. 红外搜索跟踪系统的数据关联算法研究[J]. 控制与决策,2008,28(2):171-176.
HAN Chongzhao, LI Chen, ZHU Hongyan. Data association algorithm of infrared search and track system[J]. Control and Decision, 2008,28(2):171-176.
- [3] MAHLER R P S. Multitarget Bayes filtering via first-order multitarget moments [J]. IEEE Transactions on Aerospace and Electronic System, 2003, 39 (4): 1152-1178.
- [4] VO B N, SINGH S, DOUCTE A. Sequential Monte Carlo methods for multi-target filtering with random finite sets [J]. IEEE Transactions on Aerospace and Electronic System, 2005, 41(4): 1224-1245.
- [5] VO B N, MA Wingkin. The Gaussian mixture probability hypothesis density filter [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091-4104.
- [6] PUNITHAKUMAR K, KIRUBARAJAN T, SINHA A. Multiple-model probability hypothesis density filter for tracking maneuvering targets [J]. IEEE Transactions on Aerospace and Electronic System, 2008, 44 (1):87-98.
- [7] GORDON N J, SALMOND D J, SMITH A F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation [J]. IEE Proceedings: F, 1993, 140(2): 107-113.
- [8] ARULAMPALAM S, MASKELL S, GORDON N, et al. A tutorial on particle filters for on-line nonlinear/non-Gaussian Bayesian tracking [J]. IEEE Transactions on Signal Process, 2002, 50(2):174-188.
- [9] LI Xiaorong, JILKOV V P. Survey of maneuvering target tracking: part V Multiple-model methods [J]. IEEE Transactions on Aerospace and Electronic System, 2005, 41(4):1255-1321.

(编辑 刘杨)