

文章编号: 1001-0920(2012)12-1864-06

用于机动目标跟踪的多模型高斯混合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, 西安 710049)

摘要: 提出一种多模型高斯混合概率假设密度(PHD)滤波器的实现方法. 该算法使用多模型方法对高斯混合PHD滤波器中存在目标对应的高斯分量进行预测及更新, 使用融合估计后的估计值描述机动目标PHD分布的高斯分量. 该算法具有PHD滤波器和多模型方法的优点, 可以用来处理目标数未知时的机动目标跟踪问题. 该算法与单模型高斯混合PHD滤波器相比, 可提高滤波器对目标发生机动时的跟踪精度; 与已有的多模型PHD滤波器相比, 节省计算时间30%以上.

关键词: 机动目标跟踪; 高斯混合; 概率假设密度; 多模型方法; 估计

中图分类号: TP273

文献标志码: A

Multiple model Gaussian mixture probability hypothesis density filter for maneuvering target tracking

WANG Xiao, HAN Chong-zhao

(School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China.

Correspondent: WANG Xiao, E-mail: wangxiaox@gmail.com)

Abstract: An implementation of multiple model Gaussian mixture probability hypothesis density(GM-PHD) filter is proposed. Based on the GM-PHD, the multiple model GM-PHD filter predicts and updates the state of the Gaussian component by using the multiple model method, and the updated state is used to describe the PHD distribution of the targets. It has the characters of both the PHD filter and the multiple model method, and can deal with multi-targets' maneuvering with unknown number of the targets. Compared with single model GM-PHD, the algorithm gives more accurate estimation on the number and state of the targets. Compared with existing multiple model GM-PHD algorithm, the proposed method saves computation time more than 30%.

Key words: maneuvering target tracking; Gaussian mixture; PHD; multiple model method; estimation

1 引 言

目标跟踪是利用探测器所获得的运动目标的量测, 估计关注区域内目标的个数、位置和速度等状态, 在国防与民用领域具有重要的应用价值. 基于数据关联的跟踪方法在多目标跟踪领域已得到广泛应用^[1-2]. 然而, 无需数据关联, 基于随机有限集理论(RFS), 概率假设密度(PHD)可通过以贝叶斯预测和量测方程为基础的递推传播来组成一种多传感器多目标跟踪滤波器^[3]. PHD滤波器的特点使得其在很多应用领域有了快速发展, 主要有图像跟踪^[4]、航迹管理^[5]、机动目标跟踪^[6-7]等. PHD滤波器的实现方式主要有粒子滤波PHD(PF-PHD)^[8]和高斯混合PHD(GM-PHD)

滤波器^[9]. 与粒子PHD滤波器相比, Vo等^[9]提出的高斯混合PHD(GM-PHD)滤波器的计算量要小得多.

当目标发生机动时, 目标的运动模式存在不确定性. 文献[10]在GM-PHD滤波器中使用修正的输入估计方法对多机动目标进行跟踪. 此外, 多模型方法是处理目标机动的一种有效手段, 基于多模型的PHD滤波器也得到了广泛研究^[6-7,11-12]. 文献[7,11-12]的多模型PHD滤波器是基于粒子滤波的, 其计算过程中需要抽取大量粒子, 消耗大量计算时间. 文献[6]提出了多模型高斯混合PHD滤波器, 但该算法在滤波过程中使用目标PHD和模型变量的联合分布, 算法结构复杂. 本文利用模型条件PHD分布的概念, 用

收稿日期: 2011-06-21; 修回日期: 2012-01-19.

基金项目: 国家自然科学基金创新研究群体科学基金项目(60921003); 国家“973”重点基础研究发展规划项目(2007CB311006); 国家自然科学基金项目(61074176).

作者简介: 王晓(1978-), 男, 博士生, 从事机动目标跟踪、信息融合等研究; 韩崇昭(1943-), 男, 教授, 博士生导师, 从事信息融合、目标跟踪等研究.

多模型方法实现了用于机动目标跟踪的高斯混合 PHD 滤波器, 算法结构得到简化. 在算法整体结构变化不大的前提下, 本文算法提高了单模型算法对机动目标的跟踪效果, 估计精度与文献 [6] 的算法基本一致, 但计算时间节省了 30% 以上.

2 问题描述

在 Mahler^[3]提出的随机有限集理论中, 一个目标的运动状态为 x , 多个目标的状态为一个有限集合 $X = \{x_1, \dots, x_{n_x}\}$; 单个量测值为 z , 多个量测为集合 $Z = \{z_1, \dots, z_{n_z}\}$. 多目标跟踪的贝叶斯递推式为

$$f_{k|k-1}(X_k|Z_{1:k-1}) = \int f_{k|k-1}(X_k|X_{k-1})f_{k-1|k-1}(X_{k-1}|Z_{1:k-1})dX_{k-1}, \quad (1)$$

$$f_{k|k}(X_k|Z_{1:k}) = \frac{f_k(Z_k|X_k)f_{k|k-1}(X_k|Z_{1:k-1})}{\int f_k(Z_k|X_k)f_{k|k-1}(X_k|Z_{1:k-1})dX_k}. \quad (2)$$

其中: $f_{k|k-1}(X_k|X_{k-1})$ 为多目标马尔科夫转移密度函数, 含义为目标当 $k-1$ 时刻状态 X_{k-1} 给定时, k 时刻状态 X_k 的分布密度; $f_{k|k}(X_k|Z_{1:k})$ 为多目标 k 时刻对于量测 $Z_{1:k}$ 的后验密度; $f_{k|k-1}(X_k|Z_{1:k-1})$ 为 k 时刻的预测密度; $f_k(Z_k|X_k)$ 为 k 时刻的似然. 多目标跟踪系统的贝叶斯递推公式包含集合的积分运算, 在计算中存在较大困难, Mahler 提出了概率假设密度方法来解决计算面临的问题.

3 多模型 GM-PHD(MM-GM-PHD) 滤波器

3.1 PHD 滤波器

随机集的 PHD 是一种密度 $D_{k|k}(x_k|Z_{1:k})$, 它在状态空间的任意区域 S 的积分 $\int_S D_{k|k}(x_k|Z_{1:k})dx_k$ 即是在区域 S 内目标个数的期望值.

PHD 滤波器包括预测和更新两个步骤^[1].

1) 预测.

$$D_{k|k-1}(x_k|Z_{1:k-1}) = \gamma_k(x_k) + \int \phi_{k|k-1}(x_k, x_{k-1})D_{k-1|k-1}(x_{k-1}|Z_{1:k-1})dx_{k-1}. \quad (3)$$

其中: $\gamma_k(x_k)$ 为新生目标的随机集的初生强度; 而

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

2) 更新.

$$D_{k|k}(x_k|Z_{1:k}) = D_{k|k-1}(x_k|Z_{1:k-1}) \left[1 - p_{D,k}(x_k) + \sum_{z_k \in Z_k} \frac{\psi_{k,z_k}(x_k)}{\kappa_k(z_k) + \int \psi_{k,z_k}(x_k)D_{k|k-1}(x_k|Z_{1:k-1})dx_k} \right]. \quad (4)$$

其中: $\psi_{k,z_k}(x_k) = p_{D,k}(x_k)g_{k|k}(z_k|x_k)$, $p_{D,k}(x_k)$ 为检测概率, $g_{k|k}(z_k|x_k)$ 为每个目标的似然, $\kappa_k(z_k)$ 为杂波强度.

3.2 GM-PHD 滤波器

PHD 滤波器是基于以下假设.

1) 每一个目标的演化与产生都独立于其他目标.
2) 杂波是 Poisson 分布且与源于目标的量测独立.

3) 由 $D_{k|k-1}$ 决定的预测多目标随机有限集满足 Poisson 分布.

Vo 等^[9]提出的 GM-PHD 滤波器还需满足以下假设.

4) 目标运动模型和传感器测量模型均为线性高斯, 即

$$f_{k|k-1}(x|\zeta) = \mathcal{N}(x; F_{k-1}\zeta, Q_{k-1}), \quad (5)$$

$$g_k(z|x) = \mathcal{N}(z; H_k x, R_k). \quad (6)$$

其中: $\mathcal{N}(\cdot|m, P)$ 为高斯分布的概率密度函数, 均值为 m , 协方差为 P ; F_{k-1} 为状态转移矩阵; Q_{k-1} 为过程噪声协方差阵; H_k 为传感器观测矩阵; R_k 为测量噪声协方差阵.

5) 目标存活概率和传感器检测概率与目标状态相独立, 即

$$p_{S,k}(x) = p_{S,k}, \quad p_{D,k}(x) = p_{D,k}.$$

6) 新生强度和它生强度均为高斯混合形式, 即

$$\gamma_k(x) = \sum_{i=1}^{J_{\gamma,k}} w_{\gamma,k}^{(i)} \mathcal{N}(x; m_{\gamma,k}^{(i)}, P_{\gamma,k}^{(i)}),$$

$$\beta_{k|k-1}(x|\zeta) = \sum_{j=1}^{J_{\beta,k}} w_{\beta,k}^{(j)} \mathcal{N}(x; F_{\beta,k-1}^{(j)}\zeta + d_{\beta,k-1}^{(j)}, Q_{\beta,k-1}^{(j)}).$$

其中: $J_{\gamma,k}$, $w_{\gamma,k}^{(i)}$, $m_{\gamma,k}^{(i)}$, $P_{\gamma,k}^{(i)}$ ($i = 1, 2, \dots, J_{\gamma,k}$) 为描述初生目标强度模型的参数; $J_{\beta,k}$, $w_{\beta,k}^{(j)}$, $F_{\beta,k-1}^{(j)}$, $d_{\beta,k-1}^{(j)}$, $Q_{\beta,k-1}^{(j)}$ ($j = 1, 2, \dots, J_{\beta,k}$) 决定了从前一时刻 ζ 衍生的目标的强度. 基于以上假设 1)~假设 6), 随机有限集的后验强度可以通过 PHD 的演化过程递推求得, 计算过程与单目标滤波中的 Kalman 滤波器相类似. 具体的计算过程可见文献 [9].

3.3 MM-GM-PHD 滤波器

当目标做机动运动时, 目标的运动模式存在不确定性. 多模型方法用一组模型集来描述目标的运动,

目前已成为解决目标模式不确定情况下的机动目标跟踪的主流方法^[13]. 本文利用模型条件 PHD 分布的概念, 用多模型方法计算各高斯分量的模型条件分布, 通过量测数据得到模型分布, 最后计算高斯分量的多模型融合估计结果. 具体方法如下.

在 GM-PHD 滤波器的假设 4) 中, 目标运动由单个模型描述, 可将它扩展为多模型描述. 在目标跟踪问题中, 目标发生的机动主要是当前时刻相对以前时刻而言, 因此本文仅用多模型方法对已存在目标的运动进行建模, 并对目标对应的高斯分量进行估计.

假定 k 时刻的模型由 M 个模型组成模型集 $\{n_k^r, r = 1, 2, \dots, M\}$, 在模型集中第 r 个模型 n_k^r 由以下方程确定:

$$f_{k|k-1}(x|\zeta) = \mathcal{N}(x; F_{k-1}^r \zeta, Q_{k-1}^r), \quad (7)$$

$$g_k(z|x) = \mathcal{N}(z; H_k^r x, R_k^r). \quad (8)$$

式中各个符号的含义与单模型系统中一致. 在 GM-PHD 滤波器中存在对高斯分量的删除与合并, 由不同运动模型产生的高斯分量经过合并后对应模型的概率无法确定, 因此在这里设定每个时刻对应每个模型的先验概率. 在没有量测的情况下, 假定每个模型的先验概率为

$$p(n_k^r) = \frac{1}{M}, \quad r = 1, 2, \dots, M. \quad (9)$$

对于每个量测 $z \in Z_k$, 定义模型似然

$$L_k^r = p[z|n_k^r], \quad (10)$$

则模型的后验概率为

$$p(n_k^r|z) = \frac{p(n_k^r)p(z|n_k^r)}{\sum_r p(n_k^r)p(z|n_k^r)}. \quad (11)$$

本文对由存在目标对应的高斯分量的演化过程用多模型方法进行处理. 如果 $k-1$ 时刻 PHD 的后验强度为高斯混合

$$D_{k-1}(x) = \sum_{i=1}^{J_{k-1}} w_{k-1}^{(i)} \mathcal{N}(x; m_{k-1}^{(i)}, P_{k-1}^{(i)}), \quad (12)$$

则 k 时刻预测强度为

$$D_{k|k-1}(x) = D_{S,k|k-1}(x) + D_{\beta,k|k-1}(x) + \gamma_k(x), \quad (13)$$

其中 $D_{S,k|k-1}(x)$ 为存在目标的 PHD 强度.

用多模型对 $D_{S,k|k-1}(x)$ 进行描述, 有

$$D_{S,k|k-1}^r(x) = p_{S,k} \sum_{j=1}^{J_{k-1}} w_{k-1}^{(j),r} \mathcal{N}(x; m_{S,k|k-1}^{(j),r}, P_{S,k|k-1}^{(j),r}); \quad (14)$$

$$w_{k|k-1}^{(j),r} = w_{k-1}^{(j)},$$

$$m_{S,k|k-1}^{(j),r} = F_{k-1}^r m_{k-1}^{(j)},$$

$$P_{S,k|k-1}^{(j),r} = Q_{k-1}^r + F_{k-1}^r P_{k-1}^{(j)} (F_{k-1}^r)^T.$$

从式 (14) 可以看出, 每个存在目标的预测 PHD 的高

斯分量对应每个模型, 有 J_{k-1} 个. 由于部分高斯分量由多模型产生, 经预测后共产生 $J_{k|k-1} - J_{k-1} + M \times J_{k-1}$ 个高斯分量. 这里 $J_{k-1}, J_{k|k-1}$ 的含义与单模型高斯混合 PHD 滤波器^[9]中相同. 在更新步中需利用量测信息对由多模型产生的 $M \times J_{k-1}$ 个分量进行融合.

对于每个量测 $z \in Z_k$, 高斯分量 $\{w_{k|k-1}^{(j),r}, m_{S,k|k-1}^{(j),r}, P_{S,k|k-1}^{(j),r}\}$, 有

$$\eta_{k|k-1}^{(j),r} = H_k^r m_{S,k|k-1}^{(j),r},$$

$$S_k^{(j),r} = R_k^r + H_k^r P_{S,k|k-1}^{(j),r} (H_k^r)^T,$$

$$K_k^{(j),r} = P_{S,k|k-1}^{(j),r} (H_k^r)^T [S_k^{(j),r}]^{-1},$$

$$w_k^{(j),r} = p_{D,k} w_{k|k-1}^{(j),r} \mathcal{N}(z; \eta_{k|k-1}^{(j),r}, S_k^{(j),r}),$$

$$m_k^{(j),r} = m_{S,k|k-1}^{(j),r} + K_k^{(j),r} (z - \eta_{k|k-1}^{(j),r}),$$

$$P_{k|k}^{(j),r} = [I - K_k^{(j),r} H_k^r] P_{S,k|k-1}^{(j),r}.$$

由式 (9) 和对于量测 z 的似然

$$L_k^r = p[z|n_k^r] = \mathcal{N}(z; \eta_{k|k-1}^{(j),r}, S_k^{(j),r}), \quad (15)$$

则由式 (11) 可得到模型的后验密度 $p(n_k^r|z)$.

将各模型产生的高斯分量融合, 得到

$$w_k^{(j)} = \sum_r^M w_k^{(j),r} p(n_k^r|z), \quad (16)$$

$$m_k^{(j)} = \sum_r^M m_k^{(j),r} p(n_k^r|z), \quad (17)$$

$$P_k^{(j)} = \sum_{r=1}^M [P_k^{(j),r} + (m_k^{(j)} - m_k^{(j),r})(m_k^{(j)} - m_k^{(j),r})^T] p(n_k^r|z). \quad (18)$$

当没有量测时, 式中的 $p(n_k^r|z)$ 用先验概率 $p(n_k^r)$ 代替, 至此完成了多模型高斯分量的融合. 在计算中, 需要用每个量测值对分量都进行这样处理. 与文献 [9] 中的计算过程相似, 下面给出完整的多模型高斯混合 PHD 的计算过程.

给定 $\{w_{k-1}^{(i)}, m_{k-1}^{(i)}, P_{k-1}^{(i)}\}_{i=1}^{J_{k-1}}$ 和量测 Z_k .

Step 1: 初生目标预测.

$i = 0$

for $j = 1, 2, \dots, J_{\gamma,k}$,

$i = i + 1, w_{k|k-1}^{(i)} = w_{\gamma,k}^{(j)}$,

$m_{k|k-1}^{(i)} = m_{\gamma,k}^{(j)}, P_{k|k-1}^{(i)} = P_{\gamma,k}^{(j)}$.

end

for $j = 1, 2, \dots, J_{\beta,k}$,

for $l = 1, 2, \dots, J_{k-1}$,

$i = i + 1,$

$w_{k|k-1}^{(i)} = w_{k-1}^{(l)} w_{\beta,k}^{(j)}$,

$m_{k|k-1}^{(i)} = d_{\beta,k-1}^{(j)} + F_{\beta,k-1}^{(j)} m_{k-1}^{(l)}$,

$$P_{k|k-1}^{(i)} = Q_{\beta, k-1}^{(j)} + F_{\beta, k-1}^{(j)} P_{k-1}^{(l)} (F_{\beta, k-1}^{(j)})^T.$$

end

end

Step 2: 存在目标预测.

for $j = 1, 2, \dots, J_{k-1}$, $i = i + 1$,

$$w_{k|k-1}^{(i), r} = p_{S, k} w_{k-1}^{(j)}, m_{k|k-1}^{(i), r} = F_{k-1}^r m_{k-1}^{(j)},$$

$$P_{k|k-1}^{(i), r} = Q_{k-1}^r + F_{k-1}^r P_{k-1}^{(j)} (F_{k-1}^r)^T,$$

 $r = 1, 2, \dots, M$.

end

 $J_{k|k-1} = i$.

Step 3: 构建更新分量.

for $j = 1, 2, \dots, J_{k|k-1} - J_{k-1}$,

$$\eta_{k|k-1}^{(j)} = H_k m_{k|k-1}^{(j)},$$

$$S_k^{(j)} = R_k + H_k P_{k|k-1}^{(j)} H_k^T,$$

$$K_k^{(j)} = P_{k|k-1}^{(j)} H_k^T (S_k^{(j)})^{-1},$$

$$P_{k|k}^{(j)} = [I - K_k^{(j)} H_k] P_{k|k-1}^{(j)}.$$

end

for $j = J_{k|k-1} - J_{k-1} + 1, \dots, J_{k|k-1}$,

$$\eta_{k|k-1}^{(j), r} = H_k^r m_{k|k-1}^{(j), r},$$

$$S_k^{(j), r} = R_k^r + H_k^r P_{k|k-1}^{(j), r} (H_k^r)^T,$$

$$K_k^{(j), r} = P_{k|k-1}^{(j), r} (H_k^r)^T (S_k^{(j), r})^{-1},$$

$$P_{k|k}^{(j), r} = [I - K_k^{(j), r} H_k^r] P_{k|k-1}^{(j), r},$$

 $r = 1, 2, \dots, M$.

end

Step 4: 更新.

for $j = 1, 2, \dots, J_{k|k-1} - J_{k-1}$,

$$w_k^{(j)} = (1 - p_{D, k}) w_{k|k-1}^{(j)},$$

$$m_k^{(j)} = m_{k|k-1}^{(j)},$$

$$P_k^{(j)} = P_{k|k-1}^{(j)}.$$

end

for $j = J_{k|k-1} - J_{k-1} + 1, 2, \dots, J_{k|k-1}$,

$$w_k^{(j), r} = (1 - p_{D, k}) w_{k|k-1}^{(j), r},$$

$$m_k^{(j), r} = m_{k|k-1}^{(j), r},$$

$$P_k^{(j), r} = P_{k|k-1}^{(j), r},$$

$$w_k^{(j)} = \sum_{r=1}^M w_k^{(j), r} p(n_k^r),$$

$$m_k^{(j)} = \sum_{r=1}^M m_k^{(j), r} p(n_k^r),$$

$$P_k^{(j)} = \sum_{r=1}^M [P_k^{(j), r} + (m_k^{(j)} - m_k^{(j), r})(m_k^{(j)} - m_k^{(j), r})^T] p(n_k^r).$$

end

 $l = 0$.for each $z \in Z_k, l = l + 1$,for $j = 1, 2, \dots, J_{k|k-1} - J_{k-1}$,

$$w_k^{(l, J_{k|k-1} + j)} = p_{D, k} w_{k|k-1}^{(j)} \mathcal{N}(z; \eta_{k|k-1}^{(j)}, S_k^{(j)}),$$

$$m_k^{(l, J_{k|k-1} + j)} = m_{k|k-1}^{(j)} + K_k^{(j)} (z - \eta_{k|k-1}^{(j)}),$$

$$P_k^{(l, J_{k|k-1} + j)} = P_{k|k}^{(j)}.$$

end

for $j = J_{k|k-1} - J_{k-1} + 1, 2, \dots, J_{k|k-1}$,

$$w_k^{(l, J_{k|k-1} + j), r} = p_{D, k} w_{k|k-1}^{(j), r} \mathcal{N}(z; \eta_{k|k-1}^{(j), r}, S_k^{(j), r}),$$

$$m_k^{(l, J_{k|k-1} + j), r} = m_{k|k-1}^{(j), r} + K_k^{(j), r} (z - \eta_{k|k-1}^{(j), r}),$$

$$P_k^{(l, J_{k|k-1} + j), r} = P_{k|k}^{(j), r}, r = 1, 2, \dots, M,$$

$$w_k^{(l, J_{k|k-1} + j)} = \sum_{r=1}^M w_k^{(l, J_{k|k-1} + j), r} p(n_k^r | z),$$

$$m_k^{(l, J_{k|k-1} + j)} = \sum_{r=1}^M m_k^{(l, J_{k|k-1} + j), r} p(n_k^r | z),$$

$$P_k^{(l, J_{k|k-1} + j)} = \sum_{r=1}^M [P_k^{(l, J_{k|k-1} + j), r} + (m_k^{(l, J_{k|k-1} + j)} - m_k^{(l, J_{k|k-1} + j), r})(m_k^{(l, J_{k|k-1} + j)} - m_k^{(l, J_{k|k-1} + j), r})^T] p(n_k^r | z).$$

end

$$w_k^{(l, J_{k|k-1} + j)} = \frac{w_k^{(l, J_{k|k-1} + j)}}{J_{k|k-1} \kappa_k(z) + \sum_{i=1}^{J_{k|k-1}} w_k^{(l, J_{k|k-1} + i)}},$$

 $j = 1, 2, \dots, J_{k|k-1}$.

end

 $J_k = l J_{k|k-1} + J_{k|k-1}$,输出 $\{w_k^{(i)}, m_k^{(i)}, P_k^{(i)}\}_{i=1}^{J_k}$.

4 仿真分析

模拟一个二维平面区域 $[-1000, 1000] \times [-1000, 1000]$ 内的多目标机动跟踪问题. 系统目标运动模型为

$$x_k = F_{k|k-1}^r x_{k-1} + w_k^r,$$

$$z_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} x_k + v_k^r.$$

每个目标的状态 $x_k = [x_{k1}, x_{k2}, x_{k3}, x_{k4}]^T$ 包括位置变量 $[x_{k1}, x_{k3}]^T$, 速度变量 $[x_{k2}, x_{k4}]^T$, 量测 $z_k = [z_{k1}, z_{k2}]^T$ 为位置变量. 对于模型 r , $F_{k|k-1}^r x_{k-1}$ 是模型状态转移矩阵, w_k^r 是过程噪声, 其协方差阵为

$$Q_k^r = \begin{bmatrix} 225 & & & \\ & 100 & & \\ & & 225 & \\ & & & 100 \end{bmatrix},$$

v_k^r 是量测噪声, 协方差阵为 $R_k^r = \begin{bmatrix} 100 & & & \\ & 100 & & \\ & & & \\ & & & \end{bmatrix}$. 由 1 个 CV 和 2 个 CT 模型组成多模型粒子 PHD 滤波器, 在 CV 模型中

$$F_{k|k-1}^{CV} = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix};$$

在 CT 模型中

$$F_{k|k-1}^{CT} = \begin{bmatrix} 1 & \frac{\sin(\omega T)}{\omega} & 0 & -\frac{\cos(\omega T) - 1}{\omega} \\ 0 & \cos(\omega T) & 0 & -\sin(\omega T) \\ 0 & \frac{1 - \cos(\omega T)}{\omega} & 1 & \frac{\sin(\omega T)}{\omega} \\ 0 & \sin(\omega T) & 0 & \cos(\omega T) \end{bmatrix}.$$

其中: T 代表量测数据的时间间隔, ω 代表 CT 模型中的转弯角速度. 仿真中取 $T = 1$ s, $\omega = \pm 0.5$ rad/s. 模

$$\text{型概率转移矩阵 } \Pi = \begin{bmatrix} 0.9 & 0.05 & 0.05 \\ 0.05 & 0.9 & 0.05 \\ 0.05 & 0.05 & 0.9 \end{bmatrix}.$$

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 $e_{k|k-1}(x_{k-1}) = 0.95$, 衍生概率 $\gamma_k(x_{k-1}) = 0.05$. 新生目标的强度函数为 $\gamma_k(x_k) = 0.1N(\cdot|\bar{x}, Q)$, 其中

$$\bar{x} = [-300, 60, -400, -32.5]^T,$$

$$Q = \begin{bmatrix} 100 & & & \\ & 10 & & \\ & & 100 & \\ & & & 10 \end{bmatrix}.$$

杂波均匀分布在观测空间 $[-1000, 1000] \times [-1000, 1000]$, 每个扫描周期杂波个数均值 $\lambda = 50$.

图 1 描述了 3 个目标在杂波环境中 60 个量测周期的机动运动情况. 目标 1 在 1 s 起始于状态 $[600, -45, -250, 12]^T$, 消失于 50 s, 1~20 s 作 CV 运动, 21~38 s 以 $\omega = -0.2$ rad/s 作 CT 运动, 39~50 s 以 $\omega = 0.2$ rad/s 作 CT 运动. 目标 2 在 4 s 起始于状态 $[-300, 60, -400, 32.5]^T$, 消失于 45 s, 4~7 s 作 CV 运动, 8~15 s 以角速度 $\omega = 0.2$ rad/s 作 CT 运动, 16~30 s 以 $\omega = -0.2$ rad/s 作 CT 运动, 31~36 s 以 $\omega = -0.4$ rad/s 作 CT 运动, 37~45 s 以 $\omega = 0.4$ rad/s 作 CT 运动. 目标 3 在 5 s 衍生于目标 1, 消失于 60 s, 5~25 s 作 CV 运动,




图 1 机动目标轨迹

26~40 s 以 $\omega = -0.4$ rad/s 作 CT 运动, 41~47 s 以 $\omega = 0.4$ rad/s 作 CT 运动, 48~60 s 作 CV 运动. 所有目标共有 5 种运动模式.

将本文提出的算法与单模型 GM-PHD 滤波器和文献 [6] 中的 MM-GM-PHD 滤波器进行比较, 通过 100 次蒙特卡洛仿真实验, 图 2 给出了 3 种滤波器对目标数估计的均值. 单模型滤波器在目标发生机动时会对目标失跟, 对目标数估计出现了错误. 两种多模型滤波器则对目标数的估计比较准确.




图 2 目标数估计

由于 PHD 滤波器没有进行数据关联, 均方误差 (RMSE) 无法对滤波器的性能进行评价. 本文使用 Wasserstein 距离 (WD)^[8] 对估计结果进行分析, WD 反映集合间的距离, 值越大说明误差越大. 图 3 对比了 3 种算法的 WD 值, 当目标没有发生机动时, 单模型滤波器的 WD 值小于多模型滤波器; 当有目标发生机动之后, 单模型滤波器的 WD 值增加, 单模型滤波器的 WD 明显差于多模型的情况; 当所有的目标均产生机动时, 单模型滤波器对目标数的估计为 0, 即没有目标, WD 无意义. 两种多模型滤波器的 WD 值基本相同, 说明估计精度相差不大. 当目标发生机动或目标个数发生变化时, WD 值会增加.




图 3 Wasserstein 距离

在算法的计算量的对比上, 使用平均每步所需消耗的 CPU 时间进行对比. 用于测试算法的 PC 机的 CPU 为 AMD Athlon 64 X2 Dual Core Processor 5400+ 2.81 GHz, 内存为 2 G. 通过 100 次蒙特卡洛仿真, GM-PHD 滤波器单个仿真周期所需的平均时间为 2.93 s, 文献 [6] 中 MM-GM-PHD 滤波器所需时间为 10.58 s, 本文的 MM-GM-PHD 滤波器所需平均时间为 6.58 s.

由于多模型滤波器的引入, 算法的计算时间会相应增加, 但比起已有的 MM-GM-PHD 滤波器, 本文算法的计算时间要节省 30% 以上。

5 结 论

高斯混合 PHD 滤波器是 PHD 滤波器的一种实现方式。与基于数据关联的目标跟踪方法相比, PHD 滤波器的优点在于可处理目标数未知情况下的多目标跟踪问题, 但当目标发生机动运动时, 滤波结果会产生因滤波模型不确定引起的误差。本文采用多模型方法对存在目标的运动进行建模, 对存在目标的高斯分量用多模型方法估计。使用模型条件概率的方法简化了已有的 MM-GM-PHD 滤波器的计算步骤, 与单模型 GM-PHD 滤波器相比, 提高了计算精度; 与已有的 MM-GM-PHD 滤波器相比, 节省了计算时间。

参考文献(References)

- [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 Q, Ye X N, Zhang H C. 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 C Z, Li C, Zhu H Y. 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 Trans on Aerospace and Electronic System, 2003, 39(4): 1152-1178.
- [4] Wang Y D, Wu J K, Kassim A A, et al. Data driven probability hypothesis density filter for visual tracking[J]. IEEE Trans on Circuits and Systems for Video Technology, 2008, 18(8): 1085-1090.
- [5] Panta K, Clark D E, Vo B N. Data association and trackmanagement for the Gaussian mixture probability hypothesis density filter[J]. IEEE Trans on Aerospace and Electronic Systems, 2009, 45(3): 1003-1016.
- [6] Pasha S A, Vo B N, Tuan H D, et al. A Gaussian mixture PHD filter for jump Markov system models[J]. IEEE Trans on Aerospace and Electronic System, 2009, 45(3): 919-936.
- [7] Punithakumar K, Kirubarajan T, Sinha A. Multiple-model probability hypothesis density filter for tracking maneuvering targets[J]. IEEE Trans on Aerospace and Electronic System, 2008, 44(1): 87-98.
- [8] Vo B N, Singh A, Doucet A. Sequential Monte Carlo methods for multi-target filtering with random finite sets[J]. IEEE Trans on Aerospace and Electronic System, 2005, 41(4): 1224-1245.
- [9] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter[J]. IEEE Trans on Signal Processing, 2006, 54(11): 4091-4104.
- [10] 刘贵喜, 周承兴, 王泽毅, 等. 用于多个机动目标的混合高斯概率假设密度跟踪器[J]. 控制理论与应用, 2011, 28(8): 1087-1092.
(Liu G X, Zhou C X, Wang Z Y, et al. Gaussian-mixture probability-hypothesis-density tracker for multiple maneuvering targets[J]. Control Theory & Applications, 2011, 28(8): 1087-1092.)
- [11] 连峰, 韩崇昭, 刘伟峰, 等. 多模型概率假设密度平滑器[J]. 自动化学报, 2010, 36(7): 939-950.
(Lian F, Han C Z, Liu W F, et al. Multiple-model probability hypothesis density smoother[J]. Acta Automatica Sinica, 2010, 36(7): 939-950.)
- [12] 王晓, 韩崇昭. 用于机动目标跟踪的多模型概率假设密度滤波器[J]. 西安交通大学学报, 2011, 45(12): 1-5.
(Wang X, Han C Z. A probability hypothesis density filter with multiple models for maneuvering target tracking[J]. J of Xi'an Jiaotong University, 2011, 45(12): 1-5.)
- [13] Li Rong X, Vesselin P Jilkov. Survey of maneuvering target tracking, Part V: Multiple-model methods[J]. IEEE Trans on Aerospace and Electronic System, 2005, 41(4): 1255-1321.

(上接第1863页)

- [11] Liu X. Modeling timed concurrent systems using generalized ultrametrics[R]. Berkeley: Electrical Engineering and Computer Sciences Department, University of California, 2006.
- [12] Priess-Crampe S, Ribenboim P. Fixed point and attractor theorems for ultrametric spaces[J]. Forum Mathematicum, 2000, 12(1): 53-64.
- [13] Liu J. On the causality of mixed-signal and hybrid models[C]. The 6th Int Workshop on Hybrid Systems. Prague, 2003: 328-342.