

一种具有信息保持能力的 GM-PHD 滤波器

刘宗香, 谢维信, 王 品, 余 友

(深圳大学 ATR 国防科技重点实验室, 广东深圳 518060)

摘 要: 概率假设密度(PHD)滤波器是解决虚警、漏检和目标数未知情况下多目标跟踪问题的新方法. 然而在该滤波器中已存在的目标一旦在某个时刻不能被传感器检测到, 漏检目标的大量信息会被滤波器丢弃. 为解决漏检目标的信息丢失问题, 对 PHD 滤波器的预测和更新方程进行了修正, 提出了一种具有信息保持能力的 PHD 滤波器. 在此基础上提出了适用于线性高斯模型的修正 PHD 滤波器高斯混合(GM)实现算法. 仿真实验结果表明, 与现有的 PHD 滤波器相比, 在存在漏检的情况下所提出的 GM-PHD 滤波器能够提供更好的多目标跟踪能力.

关键词: 多目标跟踪; 概率假设密度滤波器; 高斯混合实现; 线性高斯模型

中图分类号: TP 391; TN 953 **文献标识码:** A **文章编号:** 0372-2112 (2013) 08-1603-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2013.08.024

A Gaussian Mixture PHD Filter with the Capability of Information Hold

LIU Zong-xiang, XIE Wei-xin, WANG Pin, YU You

(ATR Key Lab, Shenzhen University, Shenzhen, Guangdong 518060, China)

Abstract: The probability hypothesis density (PHD) filter has been proved to be an efficient method for the multi-target tracking in the presence of false alarms, missed detections and an unknown number of targets. However, in the original PHD filter, a large amount of information of the existing targets will be immediately discarded by the PHD filter once they cannot be detected by a sensor at a given time. To resolve the information loss problem of missed true targets, we modify the prediction and update equations of the PHD filter and propose a modified PHD filter with the capability of information hold. A Gaussian mixture implementation of the modified PHD filter for linear Gaussian models is also presented. The simulation results demonstrate that the proposed filter can achieve better tracking performance of multiple targets than the original PHD filter in the presence of missed detections.

Key words: multi-target tracking; probability hypothesis density filter; Gaussian mixture implementation; linear Gaussian models

1 引言

基于限集统计学(FISST)的多目标贝叶斯滤波器是用于目标检测、定位与跟踪的、理论上最优的数学基础, 近年来受到广泛重视^[1,2]. 由于从后验分布中提取目标状态需要知道目标数, 多目标贝叶斯滤波器仅适用于解决目标数已知情况下的多目标跟踪问题. 为解决目标数未知情况下的多目标跟踪问题, Mahler 提出了“一阶矩滤波器”, 即概率假设密度(PHD)滤波器^[3]. 两种近似方法即粒子滤波(PF)方法^[4-5]和高斯混合(GM)方法^[6,7]也相继提出以解决 PHD 滤波器中积分难以运算的问题. PF-PHD 滤波器采用了大量的粒子, 实时性能差, 利用聚类技术估计目标状态具有不可靠性, 而 GM-PHD 滤波器能更加有效和可靠地从后验矩中提取出目标状态^[6,8,9]. 目前, PHD 滤波器已在定位和跟踪^[1,10]等领域

取得了应用. 然而, PHD 滤波器有两个主要缺点: (1) 存在巨量信息的丢失; (2) 在存在虚警、特别是漏检情况下目标数估计是极不稳定的^[1]. 为提高目标数估计的稳定性, Mahler 等提出了 CPHD 滤波器^[1,11]. CPHD 滤波器是高阶矩滤波器, 同时传递 PHD 和用于估计目标数的势分布. 然而 CPHD 滤波器计算复杂度高, 且没能完全解决漏检目标信息丢失问题. 既然目标的状态是从后验 PHD 中提取的, 这样即便我们能得到准确的目标数估计, 如果漏检目标的信息已被 PHD 滤波器或 CPHD 滤波器丢弃了, 漏检目标的状态也难以从 PHD 中提取出来. 为解决 PHD 滤波器的信息丢失问题, 我们对 PHD 滤波器的预测和更新方程进行了修正. 这一修正能将漏检目标的有用信息驻留在后验更新矩中, 从而避免了漏检引起的信息丢失. 基于修正 PHD 滤波器的预测与更新方程, 我们提出了一种修正 PHD 滤波器的高斯混合实现

算法.仿真实验表明,所提出的 GM-PHD 滤波器提高了目标数估计的稳定性和目标状态提取的可靠性.

2 修正的 PHD 滤波器

2.1 PHD 滤波器

PHD 滤波器的递推由预测步和更新步构成.用 $\mathbf{v}_{k-1}(\mathbf{x}|Z^{(k-1)})$ 表示 $k-1$ 时刻多目标的后验矩,PHD 滤波器的预测方程为:

$$\mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)}) = \boldsymbol{\gamma}_k(\mathbf{x}) + \int [p_{S,k}(\mathbf{x}')f_{k|k-1}(\mathbf{x}|\mathbf{x}') + \beta_{k|k-1}(\mathbf{x}|\mathbf{x}')] \mathbf{v}_{k-1}(\mathbf{x}'|Z^{(k-1)}) d\mathbf{x}' \quad (1)$$

其中, \mathbf{x} 为目标的状态, $Z^{(k-1)} = (Z_1, Z_2, \dots, Z_{k-1})$ 是由 1 至 $k-1$ 时刻所有测量组成的集合, $\mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)})$, $f_{k|k-1}(\cdot|\mathbf{x}')$, $p_{S,k}(\mathbf{x}')$, $\beta_{k|k-1}(\cdot|\mathbf{x}')$ 和 $\boldsymbol{\gamma}_k(\cdot)$ 分别是后验预测矩、状态转移概率、幸存概率、衍生目标矩和新生目标矩.

假设 $\mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)})$ 为后验的预测矩,PHD 滤波器的更新方程为

$$\mathbf{v}_k(\mathbf{x}|Z^{(k)}) \approx (1 - p_{D,k}(\mathbf{x})) \mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)}) + \sum_{z \in Z_k} \frac{p_{D,k}(\mathbf{x})g_k(z|\mathbf{x})\mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)})}{\lambda_k(z) + \int p_{D,k}(\mathbf{x})g_k(z|\mathbf{x})\mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)})d\mathbf{x}} \quad (2)$$

其中, Z_k , $g_k(\cdot|\mathbf{x})$, $p_{D,k}(\mathbf{x})$ 和 $\lambda_k(z)$ 分别表示 k 时刻多目标测量集、单目标测量的似然、目标的检测概率和杂波矩,而 z 表示测量集 Z_k 中的一个测量.

假设目标的检测概率是恒定不变的,即 $p_{D,k}(\mathbf{x}) = 0.95$, 并且 k 时刻传感器没有采集到任何测量,即 $Z_k = \emptyset$, 则式(2)可简化为:

$$\mathbf{v}_k(\mathbf{x}|Z^{(k)}) \approx 0.05 \mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)}) \quad (3)$$

从式(3)中不难看出,在假设的条件 ($p_{D,k}(\mathbf{x}) = 0.95$, $Z_k = \emptyset$) 下,95% 的目标信息被 PHD 滤波器从后验矩中抛弃了.既然后验矩的积分为积分空间的目标数,显然,更新的目标数也仅为预测目标数的 5%,从而导致不可信的目标数估计.由于在 PHD 滤波器中漏检造成了信息丢失和不可信的目标数估计,因此,需要对 PHD 滤波器进行修正.

2.2 修正的 PHD 滤波器

为了推导修正 PHD 滤波器的预测与更新方程,考虑如下的假设:

假设 1 预测矩 $\mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)})$ 能够表示成各目标(包含真目标和若干假目标)后验密度的和,即

$$\mathbf{v}_{k|k-1}(\mathbf{x}|Z^{(k-1)}) = \sum_{i=1}^{J_{k|k-1}} p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)}) \quad (4)$$

其中, $J_{k|k-1}$ 表示用于形成 k 时刻预测矩的目标个数, $p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)})$ 为目标 i 的后验密度.

假设 2 每一目标的幸存概率和检测概率是状态

独立的,即

$$p_{S,k}^i(\mathbf{x}) = p_{S,k}^i, p_{D,k}^i(\mathbf{x}) = p_{D,k}^i, i = 1, 2, \dots, J_{k-1} \quad (5)$$

在假设 1 和 2 下,由式(2)可推导出更新矩也为各个目标后验密度的和,并且

$$\mathbf{v}_k(\mathbf{x}|Z^{(k)}) \approx \sum_{i=1}^{J_{k|k-1}} (1 - p_{D,k}^i) p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)}) + \sum_{z \in Z_k} \frac{\sum_{i=1}^{J_{k|k-1}} p_{D,k}^i g_k(z_j|\mathbf{x}) p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)})}{\lambda_k(z_j) + \sum_{i=1}^{J_{k|k-1}} p_{D,k}^i \int g_k(z_j|\mathbf{x}) p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)}) d\mathbf{x}} \quad (6)$$

从式(6)中也可看出,如果目标 i 在 k 时刻从测量集中漏掉了(此时, k 时刻测量集中无目标 i 的信息),只有 $1 - p_{D,k}^i$ 倍该目标的预测信息保留在后验矩中,而余下的信息被 PHD 滤波器抛弃了.结果漏检导致了该目标信息的丢失.在 PHD 滤波器中,用于形成后验矩的目标包括真目标和假目标.为了在真目标被漏的情况下将其信息驻留在后验矩中,需要考虑以下问题:(1) 在所有的目标中,哪些是存活的真目标?(2) 一个存活的真目标在某一时刻是否被漏了?(3) 如果一个存活的真目标在某一时刻被漏了,如何将其有用的信息保留下来?

利用式(4)中的后验预测矩,我们能解决第一个问题.如果各个目标的预测密度能由式(4)给出,那么各目标的预测概率能通过预测密度的积分获得,即有

$$\hat{p}_{k|k-1}^i = \int p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)}) d\mathbf{x}, i = 1, 2, \dots, J_{k|k-1} \quad (7)$$

一个目标的预测概率表示其是一个真目标的概率.在所有存活目标中, $\hat{p}_{k|k-1}^i$ 充分大的目标,即

$$\hat{p}_{k|k-1}^i > 0.5, i = 1, 2, \dots, J_{k|k-1} \quad (8)$$

满足式(8)的目标能被定义为存活的真目标.为了确定存活的目标是否在某一时刻被漏了,需要得到该目标的后验更新概率.给定 k 时刻各目标的预测密度 $p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)})$, $i = 1, 2, \dots, J_{k|k-1}$ 和 k 时刻的一个测量 z_j , 各目标的后验更新密度能用贝叶斯定理获得

$$p_k^i(\mathbf{x}|Z^{(k-1)}, z_j) = \frac{p_{D,k}^i g_k(z_j|\mathbf{x}) p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)})}{\lambda_k(z_j) + \sum_{i=1}^{J_{k|k-1}} p_{D,k}^i \int g_k(z_j|\mathbf{x}) p_{k|k-1}^i(\mathbf{x}|Z^{(k-1)}) d\mathbf{x}} \quad (9)$$

后验更新密度积分即为后验更新概率,因此在给定条件下目标 i 的后验更新概率为

$$\hat{p}_k^{i,j} = \int p_k^i(\mathbf{x}|Z^{(k-1)}, z_j) d\mathbf{x} = \frac{p_{D,k}^i \int g_k(z_j|\mathbf{x}) \mathbf{v}_{k|k-1}^i(\mathbf{x}|Z^{(k-1)}) d\mathbf{x}}{\lambda_k(z_j) + \sum_{i=1}^{J_{k|k-1}} p_{D,k}^i \int g_k(z_j|\mathbf{x}) \mathbf{v}_{k|k-1}^i(\mathbf{x}|Z^{(k-1)}) d\mathbf{x}} \quad (10)$$

在给定条件下目标 i 被漏的概率为 $\hat{p}_{M,k}^{i,j} = 1 - \hat{p}_k^{i,j}$. 如果测量集 \mathbf{Z}_k 中有多个测量, 只有当所有的测量都不源于目标 i 才表明该目标 i 被漏了. 因此, 给定预测矩 $\mathbf{v}_{k|k-1}(\mathbf{x} | Z^{(k-1)})$ 和测量集 \mathbf{Z}_k , 目标 i 被漏的概率为

$$\begin{aligned} \hat{p}_{M,k}^i &= \prod_{z_j \in Z^{(k)}} \hat{p}_{M,k}^{i,j} = \prod_{z_j \in Z^{(k)}} (1 - \hat{p}_k^{i,j}) \\ &= \prod_{z_j \in Z^{(k)}} \left(1 - \frac{p_{D,k}^i \int g_k(z_j | \mathbf{x}) \mathbf{v}_{k|k-1}^i(\mathbf{x} | Z^{(k-1)}) d\mathbf{x}}{\lambda_k(z_j) + \sum_{i=1}^{J_{k|k-1}} p_{D,k}^i \int g_k(z_j | \mathbf{x}) \mathbf{v}_{k|k-1}^i(\mathbf{x} | Z^{(k-1)}) d\mathbf{x}} \right) \end{aligned} \quad (11)$$

在所有存活目标中, $\hat{p}_{M,k}^i$ 充分大的目标, 即

$$\hat{p}_{M,k}^i > 0.5, i = 1, 2, \dots, J_{k|k-1} \quad (12)$$

满足式(12)的目标能被定义为被漏的目标. 为了避免被漏目标的有用信息被 PHD 滤波器抛弃, PHD 滤波器的更新方程被修正为

$$\begin{aligned} \mathbf{v}_k(\mathbf{x} | Z^{(k)}) &\approx \sum_{i=1}^{J_{k|k-1}} \alpha_i^i \hat{p}_{M,k}^i p_{k|k-1}^i(\mathbf{x} | Z^{(k-1)}) \\ &+ \sum_{i=1}^{J_{k|k-1}} (1 - \alpha_i^i) (1 - p_{D,k}^i) p_{k|k-1}^i(\mathbf{x} | Z^{(k-1)}) \\ &+ \sum_{z_j \in Z_k} \frac{\sum_{i=1}^{J_{k|k-1}} p_{D,k}^i g_k(z_j | \mathbf{x}) p_{k|k-1}^i(\mathbf{x} | Z^{(k-1)})}{\lambda_k(z_j) + \sum_{i=1}^{J_{k|k-1}} p_{D,k}^i \int g_k(z_j | \mathbf{x}) p_{k|k-1}^i(\mathbf{x} | Z^{(k-1)}) d\mathbf{x}} \end{aligned} \quad (13)$$

其中, α_k^i 为确定目标是否被漏的标识, 被定义为

$$\alpha_k^i = \begin{cases} 1, & \text{if } \hat{p}_{k|k-1}^i > 0.5 \text{ and } \hat{p}_{M,k}^i > 0.5 \\ 0, & \text{otherwise} \end{cases} \quad (14)$$

从式(13)中不难看出, 被漏目标的预测信息被驻留在后验的更新矩中.

需要注意的是, 目标被漏可能由两种原因引起: (1) 漏检; (2) 目标的消失. 如果一个真目标在某一时刻被漏了, 也可能是该目标已经消失了, 因此应减少其在下一时刻的幸存概率, 以便将消失目标的信息尽快从后验矩中抛弃掉. 基于此, 各目标的幸存概率能被定义为

$$p_{S,k}^i = \begin{cases} 0.5, & \text{if } \alpha_{k-1}^i = 1 \\ p_{S,k}, & \text{otherwise} \end{cases} \quad (15)$$

其中, $p_{S,k}$ 是先验的幸存概率.

假设 $k-1$ 时刻后验矩 $\mathbf{v}_{k-1}(\mathbf{x} | Z^{(k-1)})$ 能表示为

$$\mathbf{v}_{k-1}(\mathbf{x} | Z^{(k-1)}) = \sum_{i=1}^{J_{k|k-1}} p_{k-1}^i(\mathbf{x} | Z^{(k-1)}) \quad (16)$$

则 k 时刻预测矩为

$$\begin{aligned} \mathbf{v}_{k|k-1}(\mathbf{x} | Z^{(k-1)}) &= \gamma_k(\mathbf{x}) \\ &+ \sum_{i=1}^{J_{k|k-1}} \int [p_{S,k}^i f_{k|k-1}^i(\mathbf{x} | \mathbf{x}') + \beta_{k|k-1}(\mathbf{x} | \mathbf{x}')] p_{k-1}^i(\mathbf{x}' | Z^{(k-1)}) d\mathbf{x}' \end{aligned} \quad (17)$$

式(17)和式(13)分别为修正 PHD 滤波器的预测与更新

方程.

3 线性高斯条件下修正 PHD 滤波器的高斯混合实现算法

线性高斯下目标运动和传感器观测方程为:

$$\mathbf{x}_k = \mathbf{F}_{k-1} \mathbf{x}_{k-1} + u_{k-1} \quad (18)$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + w_k \quad (19)$$

其中, \mathbf{F}_{k-1} 是状态转移矩阵, \mathbf{H}_k 是观测矩阵, \mathbf{x}_k 为状态向量, u_{k-1} 和 w_k 为均值为 0、方差分别为 \mathbf{Q}_{k-1} 和 \mathbf{R}_k 的过程与观测噪声. 为了简便, 这里我们假设没有衍生目标, 并且新目标矩为高斯混合的形式

$$\gamma_k(\mathbf{x}) = \sum_{i=1}^{J_{\gamma,k}} w_{\gamma,k}^i N(\mathbf{x}; \mathbf{m}_{\gamma,k}^i, \mathbf{P}_{\gamma,k}^i) \quad (20)$$

其中, J 表示高斯项的个数, w 、 \mathbf{m} 和 \mathbf{P} 分别为高斯项的权重、状态的均值和方差.

修正 PHD 滤波器的高斯混合实现算法由预测、更新、裁减与合并、目标状态提取四步组成.

3.1 预测

假设 $k-1$ 时刻的高斯项为

$$(w_{k-1}^i, \mathbf{m}_{k-1}^i, \mathbf{P}_{k-1}^i, \alpha_{k-1}^i), i = 1, 2, \dots, J_{k-1} \quad (21)$$

并且假定 $k-1$ 时刻的后验矩是高斯混合的形式

$$\mathbf{v}_{k-1}(\mathbf{x} | Z^{(k-1)}) = \sum_{i=1}^{J_{k-1}} w_{k-1}^i N(\mathbf{x}; \mathbf{m}_{k-1}^i, \mathbf{P}_{k-1}^i) \quad (22)$$

由式(17)、式(18)和式(22)可以推导出 k 时刻预测矩也是高斯混合的形式

$$\mathbf{v}_{k|k-1}(\mathbf{x} | Z^{(k-1)}) = \mathbf{v}_{S,k|k-1}(\mathbf{x} | Z^{(k-1)}) + \gamma_k(\mathbf{x}) \quad (23)$$

其中, $\gamma_k(\mathbf{x})$ 由式(20)确定, 而

$$\begin{aligned} \mathbf{v}_{S,k|k-1}(\mathbf{x} | Z^{(k-1)}) &= \sum_{i=1}^{J_{k-1}} w_{S,k|k-1}^i N(\mathbf{x}; \mathbf{m}_{S,k|k-1}^i, \mathbf{P}_{S,k|k-1}^i) \end{aligned} \quad (24)$$

$$w_{S,k|k-1}^i = \begin{cases} 0.5 w_{k-1}^i, & \text{if } \alpha_{k-1}^i = 1 \\ p_{S,k} w_{k-1}^i, & \text{if } \alpha_{k-1}^i = 0 \end{cases} \quad (25)$$

$$\begin{aligned} \mathbf{m}_{S,k|k-1}^i &= \mathbf{F}_{k-1} \mathbf{m}_{k-1}^i, \mathbf{P}_{S,k|k-1}^i \\ &= \mathbf{Q}_{k-1} + \mathbf{F}_{k-1} \mathbf{P}_{k-1}^i \mathbf{F}_{k-1}^T \end{aligned} \quad (26)$$

预测的高斯项由 $(w_{S,k|k-1}^i, \mathbf{m}_{S,k|k-1}^i, \mathbf{P}_{S,k|k-1}^i, \alpha_{S,k|k-1}^i), i = 1, 2, \dots, J_{k-1}$ 和 $(w_{\gamma,k}^j, \mathbf{m}_{\gamma,k}^j, \mathbf{P}_{\gamma,k}^j, \alpha_{\gamma,k}^j), j = 1, 2, \dots, J_{\gamma,k}$ 组成. 其中, $\alpha_{S,k|k-1}^i = 0, \alpha_{\gamma,k}^j = 0$.

3.2 更新

假设预测矩 $\mathbf{v}_{k|k-1}(\mathbf{x} | Z^{(k-1)})$ 是高斯混合形式

$$\begin{aligned} \mathbf{v}_{k|k-1}(\mathbf{x} | Z^{(k-1)}) &= \sum_{i=1}^{J_{k|k-1}} w_{k|k-1}^i N(\mathbf{x}; \mathbf{m}_{k|k-1}^i, \mathbf{P}_{k|k-1}^i) \end{aligned} \quad (27)$$

并且预测的高斯项为

$$(w_{k|k-1}^i, \mathbf{m}_{k|k-1}^i, \mathbf{P}_{k|k-1}^i, \alpha_{k|k-1}^i), i = 1, 2, \dots, J_{k|k-1} \quad (28)$$

那么由式(13)、(19)和(27)可推导出 k 时刻后验矩 $\nu_k(x|Z^{(k)})$ 也是高斯混合形式

$$\nu_k(x|Z^{(k)}) = \sum_{i=1}^{J_{k|k-1}} w_{k|k}^i \cdot N(x; m_{k|k-1}^i, P_{k|k-1}^i) + \sum_{z_j \in Z_k} \sum_{i=1}^{J_{k|k-1}} w_{k|k}^{i,j} N(x; m_{k|k}^{i,j}, P_{k|k}^{i,j}) \quad (29)$$

其中: $m_{k|k}^{i,j} = m_{k|k-1}^i + K_i \cdot (z_j - H_k m_{k|k-1}^i)$ (30)

$P_{k|k}^{i,j} = (I - K_i \cdot H_k) P_{k|k-1}^i$ (31)

$K_i = P_{k|k-1}^i H_k^T (H_k P_{k|k-1}^i H_k^T + R_k)^{-1}$ (32)

$$w_{k|k}^{i,j} = \frac{p_{D,k}^i \cdot w_{k|k-1}^i \cdot N(z_j; H_k m_{k|k-1}^i, H_k P_{k|k-1}^i H_k^T + R_k)}{\lambda c(z_j) + \sum_{l=1}^{J_{k|k-1}} p_{D,k}^l w_{k|k-1}^l N(z_j; H_k m_{k|k-1}^l, H_k P_{k|k-1}^l H_k^T + R_k)} \quad (33)$$

$\hat{p}_{M,k}^i = \prod_{z_j \in Z_k} (1 - w_{k|k}^{i,j})$ (34)

$\alpha_{k|k}^i = \begin{cases} 1, & \text{if } w_{k|k-1}^i > 0.5 \text{ and } \hat{p}_{M,k}^i > 0.5 \\ 0, & \text{otherwise} \end{cases}$ (35)

$w_{k|k}^i = \alpha_{k|k}^i \hat{p}_{M,k}^i w_{k|k-1}^i + (1 - \alpha_{k|k}^i) (1 - p_{D,k}^i) w_{k|k-1}^i$ (36)

更新高斯项由 $(w_{k|k}^i, m_{k|k-1}^i, P_{k|k-1}^i, \alpha_{k|k}^i)$, $i = 1, \dots, J_{k|k-1}$ 和 $(w_{k|k}^{i,j}, m_{k|k}^{i,j}, P_{k|k}^{i,j}, \alpha_{k|k}^{i,j})$, $i = 1, \dots, J_{k|k-1}, j = 1, \dots, m_k$ 组成. 其中, $\alpha_{k|k}^{i,j} = 0, i = 1, \dots, J_{k|k-1}, j = 1, \dots, m_k$.

3.3 裁减与合并

假设 k 时刻形成后验矩 $\nu_k(x|Z^{(k)})$ 的高斯项为

$(w_{k|k}^i, m_{k|k}^i, P_{k|k}^i, \alpha_{k|k}^i), i = 1, 2, \dots, J_{k|k}$ (37)

删除权重充分小即 $w_{k|k}^i < \tau$ 的高斯项. 将距离充分小即 $d_{ij} < U$ 的高斯项合并成一个. 合并距离 d_{ij} 定义为:

$d_{ij} = (m_{k|k}^i - m_{k|k}^j)^T (P_{k|k}^i + P_{k|k}^j)^{-1} \cdot (m_{k|k}^i - m_{k|k}^j)$ (38)

多个高斯项的合并方法如下:

$w_k^b = \sum_{i \in L} w_{k|k}^i, m_k^b = \frac{1}{w_k} \sum_{i \in L} w_{k|k}^i m_{k|k}^i$ (39)

$P_k^b = \frac{1}{w_k} \sum_{i \in L} w_{k|k}^i (P_{k|k}^i + (m_{k|k}^i - m_k^b) \cdot (m_{k|k}^i - m_k^b)^T)$ (40)

其中, L 为由要合并高斯项下标形成的集合. 合并高斯项标识 α 取为合并前权重最大高斯项的标识.

3.4 目标状态提取

假设裁减与合并步后, 余下的高斯项为 $(w_k^i, m_k^i, P_k^i, \alpha_k^i), i = 1, \dots, J_k$. 提取权重 $w_k^i > 0.5$ 的高斯项作为滤波器的输出. 相应高斯项中的均值和方差分别为存活目标的状态估计和误差估计.

4 仿真实验及分析

仿真实验考虑 10 个在二维空间 $[-1000(m), 1000(m)] \times [-1000(m), 1000(m)]$ 中匀速运动的目标. 每一目标的状态由位置和速度构成, 表示为 $x_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$, 而测量为目标位置加上观测噪声. 运动方程(18)中的状态转移矩阵和过程噪声方差为

$$F_k = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, Q_k = \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix} \sigma_v^2$$

其中, $T = 1s, \sigma_v = 1ms^{-2}$. 10 个目标均为新生目标. 目标 1~8 分别在 $k = 1s, k = 1s, k = 3s, k = 3s, k = 5s, k = 8s, k = 10s$ 和 $k = 12s$ 出现于观测空间, 在余下时间持续存在. 目标 9 和 10 分别于 $k = 14s$ 和 $k = 15s$ 出现于观测空间, 并分别在 $k = 40s$ 和 $k = 30s$ 消失. 各目标初始状态如下:

$x^{(1)} = [-900(m), 35(ms^{-1}), -900(m), 35(ms^{-1})]^T$

$x^{(2)} = [-900(m), 35(ms^{-1}), 900(m), -35(ms^{-1})]^T$

$x^{(3)} = [-900(m), 35(ms^{-1}), -860(m), 35(ms^{-1})]^T$

$x^{(4)} = [-900(m), 35(ms^{-1}), 860(m), -35(ms^{-1})]^T$

$x^{(5)} = [-200(m), 25(ms^{-1}), -900(m), 30(ms^{-1})]^T$

$x^{(6)} = [-900(m), 30(ms^{-1}), 200(m), 10(ms^{-1})]^T$

$x^{(7)} = [-450(m), 35(ms^{-1}), -200(m), 0(ms^{-1})]^T$

$x^{(8)} = [-200(m), 30(ms^{-1}), -900(m), 20(ms^{-1})]^T$

$x^{(9)} = [-900(m), 25(ms^{-1}), 200(m), 25(ms^{-1})]^T$

$x^{(10)} = [-450(m), 40(ms^{-1}), -200(m), 40(ms^{-1})]^T$

10 批目标包含有相距很近的目标和交叉目标, 目标轨迹如图 1 所示.




图1 目标的真实轨迹

新目标矩取为:

$\gamma_k(x) = \sum_{i=1}^5 0.1 N(x; m_{\gamma,k}^i, P_{\gamma,k}^i)$

其中: $m_{\gamma,k}^1 = [-900(m), 0(ms^{-1}), -900(m), 0(ms^{-1})]^T$

$m_{\gamma,k}^2 = [-900(m), 0(ms^{-1}), 900(m), 0(ms^{-1})]^T$

$m_{\gamma,k}^3 = [-200(m), 0(ms^{-1}), -900(m), 0(ms^{-1})]^T$

$m_{\gamma,k}^4 = [-900(m), 0(ms^{-1}), 200(m), 0(ms^{-1})]^T$

$m_{\gamma,k}^5 = [-450(m), 0(ms^{-1}), -200(m), 0(ms^{-1})]^T$

而 $P_{\gamma,k} = (\text{diag}([50 \ 25 \ 50 \ 25]))^2$. 目标检测概率

为 $p_{D,k} = 0.85$, 观测方程(19)中的观测矩阵和观测噪声的方差分别为

$$\mathbf{H}_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \mathbf{R}_k = \begin{bmatrix} 4(\text{m}^2) & 0 \\ 0 & 4(\text{m}^2) \end{bmatrix}$$

杂波服从泊松分布, 杂波密度取为 $\lambda_c = 5 \times 10^{-6} \text{m}^{-2}$ (每个周期平均 20 个杂波测量). 实现算法中的裁减阈值为 $\tau = 10^{-3}$, 合并阈值为 $U = 4$, 幸存概率为 $p_{S,k} = 0.9$, 检测概率为 $p_{D,k}^i = 0.85$.

为了评估修正 PHD 滤波器(MPHD filter)和 PHD 滤波器(PHD filter)的性能, 本文使用了平均目标数、目标数均方根误差(RMS)和 OSPA 距离三种度量. 其中 OSPA 距离是新近提出的度量^[12]. 对于任意两个有限集 $X = \{x_1, \dots, x_m\}$ 和 $Y = \{y_1, \dots, y_n\}$, 如果 $m \leq n$, OSPA 距离被定义为:

$$d_{p,c}(X, Y) = \left(\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m d_c(x_i, y_{\pi(i)})^p + c^p(n-m) \right) \right)^{1/p}$$

其中 $d_c(x, y) = \min(c, d(x, y))$ 为截断距离, Π_n 表示集合 $\{1, 2, \dots, n\}$, $1 \leq p < \infty$ 为 OSPA 度量参数. 如果 $m > n$, OSPA 距离为 $d_{p,c}(X, Y) = d_{p,c}(Y, X)$. 作为一种评价标准, OSPA 距离对虚警和漏检均能给出合理的评判, 当出现虚警或漏检时, 用截断距离 c 进行惩罚. 仿真实验中, 参数 p 和 c 设置为 $p = 2$ 和 $c = 10\text{m}$. 100 次 Monte Carlo 实验后 3 种不同滤波器得到的平均目标数、目标数均方根误差和 OSPA 距离如图 2~4.

5 种不同检测概率下分别进行 100 次 Monte Carlo 实验, 3 种滤波器的平均 OSPA 距离如图所示.




图2 三种滤波器的平均目标数




图3 三种滤波器的目标数均方根误差




图4 三种滤波器的OSPA距离

从图 2 和图 3 可看出, 与 PHD 滤波器相比, 修正 PHD 滤波器能获得更加精确和稳定的目标数估计, 平均目标数与真实目标数更为接近, 目标数估计的均方根误差更小; 除了在目标消失时刻 ($k = 30\text{s}$ 和 $k = 40\text{s}$) 外, 在其它时刻修正 PHD 滤波器的目标数估计比 CPHD 滤波器更为精确和稳定. 从图 4 可看出, 修正 PHD 滤波器的多目标跟踪精度高于 PHD 滤波器或 CPHD 滤波器, 其 OSPA 距离比 PHD 滤波器和 CPHD 滤波器得到的 OSPA 距离要小得多. 出现这一情况的主要原因是修正 PHD 滤波器能将漏检目标的信息驻留在后验矩中. 在修正的 PHD 滤波器中, 被检测到的真目标产生较大的高斯权重, 其状态能被滤波器取出作为存活目标的状态, 而被漏的真目标将保持其原有权重, 其状态也能被滤波器提取出来. 而在 PHD 滤波器中, 被漏的真目标因其大量的信息被滤波器抛弃, 其状态不能被滤波器提取出来. 从图 3 和 4 也能看到, RMS 误差曲线或 OSPA 距离上出现了一些峰值点. 这是由于两个原因造成的: (1) 已出现的新目标未能及时被滤波器检测出来; (2) 已消失的目标其信息未能从后验矩中及时删除. 需要指出的是, 由于在修正 PHD 滤波器中, 已消失目标也会作为被漏的真目标, 其信息会驻留至下一时刻, 这样在目标消失时刻即 $k = 30\text{s}$ 和 $k = 40\text{s}$ 时图 3 和图 4 中修正 PHD 滤波器的目标数误差曲线和 OSPA 距离曲线出现了峰值. 从图 5 可看出, 在 5 种不同的检测概率下修正 PHD 滤波器的平均 OSPA 距离均小于 PHD 滤波器和 CPHD 滤波器的平均 OSPA 距离, 这一结果进一步表明修正 PHD 滤波器具有更好的多目标跟踪性能. 从实验所需时间看, 修正 PHD 滤波器完成 1 次实验需 3.4s, PHD 滤波器需 2.8s, 而 CPHD 滤波器需 61s. 修正 PHD 滤波器计算时间稍大于 PHD 滤波器, 而远小于 CPHD 滤波器. 主要原因是修正 PHD 滤波器是一阶矩滤波器, 只传递 PHD, 不传递用于估计目标数的势分布, 其计算的复杂度与 PHD 相同, 而 CPHD 滤波器是高阶矩滤波器, 同时传递 PHD 和势分布, 计算复杂度高. 由于确定目标是否被漏检需要一些时间, 因此修正 PHD 滤波器计算时间比 PHD 滤波器的计算时间稍大.

值得请注意的是,从图 2~4 中我们还发现 CPHD 滤波器对新出现目标的响应速度较慢,从而导致其目标数估计偏离了真实的目标数,结果其平均 OSPA 距离偏大.尽管从 $k = 18s$ 后,CPHD 滤波器的目标数估计要比 PHD 滤波器精确和稳定得多,但由于漏检目标的状态不能被准确地提取出来,其平均 OSPA 距离仅稍小于 PHD 滤波器的 OSPA 距离.在本文仿真条件下,5 种不同检测概率下 CPHD 滤波器的平均 OSPA 距离均是最高(见图 5).




图5 五种检测概率下三种滤波器的OSPA距离

5 结论

漏检目标信息的丢失是 PHD 滤波器的一个关键问题,会导致漏检目标的状态不能被提取出来作为滤波器的输出.为克服漏检造成的信息丢失问题,对 PHD 滤波器的预测与更新方程进行了修正,提出了一种具有信息保持能力的 PHD 滤波器.所提出的滤波器能将漏检目标的信息保持下来并传递至下一时刻,因此能有效避免和减少漏检造成的信息丢失问题.仿真结果表明,与 PHD 滤波器相比,修正的 PHD 滤波器在存在漏检的情况下能够提供更加精确和可靠的目标数估计,并能实现更好的多目标跟踪能力.

参考文献

- [1] Mahler R. Statistical Multisource-Multitarget Information Fusion [M]. Artech House, Norwood, MA, 2007. 565 – 651.
- [2] 杨威,等.基于有限集统计学理论的目标跟踪技术研究综述[J].电子学报,2012,40(7):1410 – 1448.
Yang Wei, Fu Yao-wen, Long Jian-qian, et al. The FISST-based target tracking techniques: a survey[J]. Acta Electronica Sinica, 2012, 40(7): 1410 – 1448. (in Chinese)
- [3] Mahler R. Multitarget bayes filtering via first-Order multitarget moments[J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4): 1152 – 1178.
- [4] Vo B N, Doucet S S. Sequential Monte Carlo methods for multi-target filtering with random finite sets[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(4): 1224 – 1245.

- [5] Ouyang C, et al. Extensions of the SMC-PHD for jump Markov systems[J]. Signal Processing, 2012, 92(6): 1422 – 1430.
- [6] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091 – 4014.
- [7] Wang Y, et al. Detection-guided multi-target Bayesian filter [J]. Signal Processing, 2012, 92(2): 564 – 574.
- [8] 欧阳成, 姬红兵, 田野. 一种基于模糊聚类的 PHD 航迹维持算法[J]. 电子学报, 2012, 40(6): 1284 – 1288.
Ouyang Cheng, Ji Hong-bing, Tian Ye. Fuzzy clustering based algorithm for track continuity in PHD filter[J]. Acta Electronica Sinica, 2012, 40(6): 1284 – 1288. (in Chinese)
- [9] 王品, 谢维信, 刘宗香, 等. 一种非线性 GM-PHD 滤波新方法[J]. 电子学报, 2012, 40(8): 1597 – 1602.
Wang Pin, Xie Wei-xin, Liu Zong-xiang, et al. A novel Gaussian mixture PHD filter for nonlinear models[J]. Acta Electronica Sinica, 2012, 40(8): 1597 – 1602. (in Chinese)
- [10] Zhang H J, Jing Z L, Hu S Q. Localization of multiple emitter based on the sequential PHD filter [J]. Signal Processing, 2010, 90(1): 34 – 43.
- [11] Mahler R, Vo B T, Vo B N, CPHD filtering with unknown clutter rate and detection profile [J]. IEEE Transactions on Signal Processing, 2011, 59(8): 3497 – 3513.
- [12] Ristic B, et al. A metric for performance evaluation of multi-target tracking algorithms [J]. IEEE Transactions on Signal Processing, 2011, 59(1): 3452 – 3457.

作者简介



刘宗香(通信作者) 男, 1965 年生于河南省光山县, 1985 和 1988 年分别获天津大学学士学位和硕士学位, 2005 年获西安电子科技大学工学博士学位, 现为深圳大学教授. 获军队科技进步奖一等奖 2 项、二等奖 1 项、三等奖 8 项. 主要研究方向为数据融合、智能信号处理、模糊信号处理.

E-mail: zongxiangliu@sohu.com



谢维信 男, 教授、博士生导师、中国电子学会信号处理分会主任委员, 深圳大学信息与通信工程科学学术带头人. 1941 生于广东省花都, 1965 年毕业于西安军事电讯工程学院. 1981 ~ 1983 年和 1989 ~ 1990 年分别在美国宾夕法尼亚大学作访问学者和访问教授. 主要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.

E-mail: wxxie@szu.edu.cn