

## 未知噪声统计下多模型概率假设密度粒子滤波算法

吴鑫辉, 黄高明, 高俊

(海军工程大学 电子工程学院, 武汉 430033)

**摘要:** 针对传统多目标概率假设密度滤波(PHD)器在噪声先验统计未知或不准确时滤波精度下降甚至丢失目标的问题, 设计一种自适应多模型粒子PHD(MMPHD)滤波算法. 该算法利用多模型近似思想, 推导出一种多模型概率假设密度估计器, 不仅能估计多目标状态, 而且能实时估计未知且时变的噪声参数, 并采用蒙特卡罗方法给出了MMPHD闭集解. 仿真实例表明, 所提出的算法具有应对噪声变化的自适应能力, 可有效提高目标跟踪精度.

**关键词:** 多目标跟踪; 概率假设密度滤波器; 多模型估计器; 蒙特卡罗方法

中图分类号: TP273

文献标志码: A

## Multiple-model probability hypothesis density filter for multi-target tracking without the statistics of noise parameters

WU Xin-hui, HUANG Gao-ming, GAO Jun

(College of Electronic Engineering, Naval University of Engineering, Wuhan 430033, China. Correspondent: WU Xin-hui, E-mail: wuxinhui009@163.com)

**Abstract:** When the prior noise statistic is unknown and time-varying, the conventional probability hypothesis density(PHD) filter declines in accuracy and loses targets. An adaptive multiple-model PHD(MMPHD) filter is proposed to estimate the states of targets and their noise variances. The unknown and time-varying noise is estimated based on multiple-models methods, and the MMPHD filter is designed to jointly estimate the target states and the statistics of the noise. The sequential Monte Carlo method is used to implement the MMPHD filter. Simulation results show that the proposed filter can accommodate the unknown measurement variances effectively and improve the estimation accuracy.

**Key words:** multi-target tracking; probability hypothesis density filter; multiple-model estimator; sequential Monte Carlo method

### 0 引言

多目标跟踪是一种从目标量测值和杂波中估计目标个数和目标状态的方法. 传统的多目标跟踪算法, 例如“最邻近”法、概率数据关联法(PDA)、多假设跟踪(MHT)法等, 大都基于数据关联, 需要建立量测和目标的对应关系<sup>[1]</sup>. 当目标个数较多时, 这些算法都存在着NP-Hard问题<sup>[2]</sup>. 近年来, Mahler<sup>[3]</sup>提出使用概率假设密度滤波(PHD)来解决多目标跟踪问题, 将复杂的多目标状态空间的运算转换为单目标状态空间内的运算, 有效地避免了多目标跟踪中复杂的数据关联问题, 在保证滤波精度的同时, 提高了算法的实时性.

传统的PHD算法需要精确已知噪声先验统计特性<sup>[4]</sup>, 而在实际目标跟踪应用中, 噪声先验统计信息

常常为未知或不准确的. 当噪声统计未知时, PHD估计器易出现滤波精度下降、目标丢失等问题. 现有文献主要针对单目标噪声统计未知情形下的跟踪问题进行了研究, Mohamed等<sup>[5]</sup>利用最大似然准则估计惯性导航中未知参数, Storvik<sup>[6]</sup>提出在粒子滤波算法中使用边缘函数来递推估计系统未知参数, Hyeter等<sup>[7]</sup>提出使用机器学习算法来自适应地估计测量噪声方差. 然而以上算法都只针对系统未知参数或噪声统计未知的单目标跟踪问题, 在多目标跟踪中, 由于目标个数未知, 轨迹未关联, 并且存在大量的杂波值等不利因素, 极大地影响了PHD估计器对未知噪声统计的识别能力.

为解决未知噪声统计下多目标跟踪问题, 本文提出了一种能自适应识别噪声的多模型PHD滤波

收稿日期: 2012-10-22; 修回日期: 2013-03-12.

基金项目: 国家863计划项目(2011AA7014061); 国家自然科学基金项目(60901069).

作者简介: 吴鑫辉(1986—), 男, 博士生, 从事目标探测与跟踪、信号处理的研究; 高俊(1957—), 男, 教授, 博士生导师, 从事数字信号处理、数字通信、短波无线通信等研究.

(MMPHD)算法. 该方法在对各个目标状态进行滤波计算的同时, 利用多模型估计器对未知的或不准确的噪声统计进行实时估计和修正, 并使用蒙特卡罗方法推导出 MMPHD 估计器的闭集解. 相比传统的 PHD 算法, 该算法能跟踪非高斯非线性多目标, 且在噪声统计未知或不准确情况下, 依然具有较高的滤波准确率和跟踪稳定性.

## 1 未知噪声统计下 MMPHD 算法推导

假定目标运动模型为

$$\begin{cases} \mathbf{x}_k = f_{k-1}(\mathbf{x}_{k-1}) + \mathbf{w}_{k-1}, \\ \mathbf{z}_k = h_k(\mathbf{x}_k) + \mathbf{v}_k. \end{cases} \quad (1)$$

其中:  $\mathbf{x}_k$  和  $\mathbf{z}_k$  为目标状态向量和观测向量; 函数  $f_{k-1}(\cdot)$  和  $h_k(\cdot)$  分别为非线性状态函数和观测函数;  $\mathbf{w}_{k-1}$  和  $\mathbf{v}_k$  分别为系统噪声和观测噪声, 服从互不相关的零均值高斯分布, 其协方差矩阵分别为

$$\text{cov}[\mathbf{w}_k \mathbf{w}_k^T] = \mathbf{Q} \delta_{kj}, \quad \text{cov}[\mathbf{v}_k \mathbf{v}_k^T] = \mathbf{R} \delta_{kj}.$$

如果噪声统计特性未知, 则可以建立一系列覆盖真实噪声协方差的模型, 在滤波过程中通过马尔可夫过程逼近真实模型. 假定共有  $M$  个可能模型

$$\begin{cases} \mathbf{x}_k = f_{k-1}(\mathbf{x}_{k-1}, r_k) + \mathbf{w}_{k-1}(r_k), \\ \mathbf{z}_k = h_k(\mathbf{x}_k, r_k) + \mathbf{v}_k(r_k). \end{cases} \quad (2)$$

其中  $r_k (r_k \in M)$  为模型索引. 根据最小均方根误差估计方法, 模型集合 (2) 所得最优噪声方差估计值 ( $\hat{Q}, \hat{R}$ ) 为

$$\begin{aligned} (\hat{Q}, \hat{R}) &= E[\mathbf{Q}, \mathbf{R} | \mathbf{Z}^k] = \\ &\sum_M E[\mathbf{Q}, \mathbf{R} | \mathbf{Z}^k, r_k] p(r_k | \mathbf{Z}^k). \end{aligned} \quad (3)$$

其中:  $E[\mathbf{Q}, \mathbf{R} | \mathbf{Z}^k, r_k]$  为模型  $r_k$  的噪声方差估计值,  $p(r_k | \mathbf{Z}^k)$  为模型  $r_k$  的概率值. 由于各个模型的噪声方差值是已知的, 只需计算每个模型的概率值便可估计出未知的噪声方差. 模型概率可以使用该模型所得状态估计值和测量值进行更新<sup>[8]</sup>.

对于未知噪声统计的 PHD 多目标跟踪, 采用式 (3) 中多模型思想, 将多模型逼近方法应用于 PHD 滤波器中, 从而实现目标状态与噪声方差的估计. 假定各个模型是相互独立的, 根据标准 PHD 递推公式<sup>[9]</sup>, 可得  $k$  时刻各模型  $r_k \in \{1, 2, \dots, M\}$  的预测强度为

$$\begin{aligned} v_{k|k-1}(\mathbf{x}_k, r_k | \mathbf{Z}_k) &= \\ \gamma_k(\mathbf{x}_k, r_k) &+ \int [p_{S,K} f_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1}, r_k) + \\ \beta_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1}, r_k)] &v_{k-1}(\mathbf{x}_{k-1}, r_{k-1} | \mathbf{Z}_{k-1}) d\mathbf{x}_k. \end{aligned} \quad (4)$$

其中:  $\gamma_k(\mathbf{x}_k, r_k)$  为新生强度,  $p_{S,K}$  为目标生存概率,

$f_{k|k-1}(\cdot | \cdot, r_k)$  和  $\beta_{k|k-1}(\cdot | \cdot, r_k)$  分别为模型  $r_k$  的系统方程和衍生目标运动方程.

在时刻  $k$  接收到测量值后, 可对各个模型的预测强度进行更新, 其更新方程为

$$\begin{aligned} v_{k|k}(\mathbf{x}_k, r_k | \mathbf{Z}_k) &= \\ \left[ \sum_{\mathbf{z}_k \in \mathbf{Z}_k} \frac{p_{D,k} g_k(\mathbf{z}_k | \mathbf{x}_k, r_k)}{\kappa_k(\mathbf{z}_k) + \langle p_{D,k} g_k(\cdot), v_{k|k-1} \rangle} + \right. \\ \left. (1 - p_{D,k}) \right] &v_{k|k-1}(\mathbf{x}_{k-1}, r_{k-1} | \mathbf{Z}_{k-1}). \end{aligned} \quad (5)$$

其中:  $\langle g(\cdot), f(\cdot) \rangle = \int g(\cdot) f(\cdot) dx$ ,  $g(\cdot)$  为测量方程,  $p_{D,k}$  为探测概率,  $\kappa_k(\mathbf{z})$  为杂波强度. 若在区域  $S$  中对  $v_{k|k}(\mathbf{x}_k, r_k | \mathbf{Z}_k)$  进行积分, 可得该区域中目标个数估计值  $\hat{N}_{k|k}$ .

在测量值更新步骤之后, 如果直接进入下一时刻滤波, 则算法复杂度将随时间呈指数增长, 因此, 如果将各个模型所得后验强度综合估计, 则可保持算法仍为  $O(n)$ . 假定各模型转移概率  $h_{k|k-1}(r_k = i | r_{k-1} = j) = \pi_{ij}$ , 在时刻  $k$ , 各模型  $r_k = i \in \{1, 2, \dots, M\}$  的后验强度为

$$\begin{aligned} v_{k|k}(\mathbf{x}_k, r_k = i | \mathbf{Z}_k) &= \\ \sum_{j=1}^M v_{k|k}(\mathbf{x}_k, r_k = j | \mathbf{Z}_k) \pi_{ij}, \end{aligned} \quad (6)$$

未知系统噪声方差  $\hat{Q}$  和观测噪声方差  $\hat{R}$  可计算为

$$\begin{aligned} \hat{Q}_{k|k} &= \frac{\int_S \mathbf{Q}_{r_k} v_{k|k}(\mathbf{x}_k, r_k | \mathbf{Z}_k) d\mathbf{x}_k d\mathbf{Q}_{r_k}}{\hat{N}_{k|k}}, \\ \hat{R}_{k|k} &= \frac{\int_S \mathbf{R}_{r_k} v_{k|k}(\mathbf{x}_k, r_k | \mathbf{Z}_k) d\mathbf{x}_k d\mathbf{R}_{r_k}}{\hat{N}_{k|k}}, \end{aligned} \quad (7)$$

$\hat{N}_{k|k}$  为区域  $S$  中目标数的估计值. 由于 MMPHD 算法包含了高维变量的集合积分, 在非线性非高斯条件下, 很难直接推导解析闭集解. 因此, 本文采用 SMC 算法估计目标状态及方差.

## 2 MMPHD 粒子滤波算法

区别于普通粒子滤波算法, MMPHD 算法中的目标强度函数包含了多个模型, 因此粒子需要一个辅助变量来代表采样粒子来自于哪个模型, 该辅助变量称为模型索引. 假定时刻  $k-1$ , MMPHD 的先验强度可由粒子集合  $\{w_{k-1}^i, \mathbf{x}_{k-1}^i, r_{k-1}^i\}_{i=1}^L$  逼近, 即

$$\begin{aligned} v(\mathbf{x}_{k-1}, r_{k-1} | \mathbf{Z}_{k-1}) &= \\ \sum_{i=1}^L w_{k-1}^i \delta(\mathbf{x}_{k-1} - \mathbf{x}_{k-1}^i, r_{k-1} - r_{k-1}^i). \end{aligned} \quad (8)$$

其中:  $w_{k-1}^i$  为粒子  $i$  的权重值,  $r_{k-1}^i$  为模型索引,  $\delta(\cdot)$  为 Delta 函数,  $L$  为粒子存活个数. 式 (8) 中粒子权重

值之和  $\sum_{i=1}^L w_{k-1}^i$  不等于1,而是时刻  $k-1$  的目标个数期望值.

## 2.1 预测步骤

MMPHD 预测步骤中包含了模型预测和目标状态预测,其中模型预测概率可通过模型转移概率函数  $h_{r|r-1}(r_k|r_{k-1})$  递推得出.假定有  $M$  个模型,则对每个模型可使用相同粒子个数  $n_{r_k} = L/M$  ( $r_k \in \{1, 2, \dots, M\}$ ) 进行采样.令  $\mu_{k-1}^j = p(r_{k-1} = j|\mathbf{Z}_{k-1})$  代表时刻  $k-1$  模型  $j$  的概率值,该模型的概率值可通过统计模型索引粒子权重值之和计算得出,即

$$\mu_{k-1}^j = \sum_{l=1}^{n_{r_k}} w_{k-1}^l \delta(r_{k-1} - j) / \sum_{l=1}^L w_{k-1}^l. \quad (9)$$

在时刻  $k$ ,模型概率预测值为

$$\mu_{k|k-1}^j = \sum_i \mu_{k-1}^i h_{r|r-1}(r_k = j|r_{k-1} = i), \quad (10)$$

其中  $\sum_i \mu_{k-1}^i h_{r|r-1}(r_k = j|r_{k-1} = i)$  为各模型的转移概率.

在 MMPHD 预测步骤中,从每个模型粒子总数  $n_{r_k}$  中,使用  $l_s$  个粒子对存活目标重要性密度函数  $q_k(\cdot|\mathbf{x}_{k-1}, r_{k-1}, \mathbf{Z}_{k-1})$  进行采样,采样粒子集合为  $\{\mathbf{x}_{k|k-1}^i\}_{i=1}^{l_s}$ ,使用  $n_{r_k} - l_s$  个粒子对新生目标重要性密度函数  $p_k(\cdot|r_{k-1}, \mathbf{Z}_k)$  进行采样,采样粒子集合表示为  $\{\mathbf{x}_{k|k-1}^i\}_{i=1}^{n_{r_k}-l_s}$ ,即

$$\mathbf{x}_{k|k-1}^i \sim \begin{cases} q_k(\cdot|\mathbf{x}_{k-1}, r_{k-1}, \mathbf{Z}_{k-1}), & i = 1, 2, \dots, l_s; \\ p_k(\cdot|r_{k-1}, \mathbf{Z}_k), & i = l_s + 1, \dots, n_{r_k}. \end{cases} \quad (11)$$

因此, MMPHD 的预测强度可近似为

$$v_{k|k-1}(\mathbf{x}_k, r_k|\mathbf{Z}_{k-1}) = \sum_{j=1}^M \mu_{k-1}^j \left[ \sum_{i=1}^{n_{r_k}} w_{j,k|k-1}^i \delta(\mathbf{x}_k - \mathbf{x}_{j,k|k-1}^i, r_k - r_{j,k|k-1}^i) \right]. \quad (12)$$

$w_{j,k|k-1}^i$  为第  $j$  个模型中第  $i$  个采样粒子的权重值,有

$$w_{j,k|k-1}^i = \begin{cases} \{p_{S,k} f_{k|k-1}(\mathbf{x}_{k|k-1}^i|\mathbf{x}_{k-1|k-1}^i, r_{k|k-1}^i) + \\ \beta_{k|k-1}(\mathbf{x}_{k|k-1}^i|\mathbf{x}_{k-1|k-1}^i, r_{k|k-1}^i)\} / \\ q_k(\mathbf{x}_{k|k-1}^i|\mathbf{x}_{k-1|k-1}^i, r_{k|k-1}^i, \mathbf{Z}_k) \} \mu_j, & i = 1, 2, \dots, l_s; \\ \frac{\gamma_k(\mathbf{x}_{k|k-1}^i|r_{k|k-1}^i)}{p_k(\mathbf{x}_{k|k-1}^i|r_{k|k-1}^i, \mathbf{Z}_k)} \mu_j, & i = l_s + 1, \dots, n_{r_k}. \end{cases} \quad (13)$$

其中:  $f_{k|k-1}(\cdot)$  和  $\beta_{k|k-1}(\cdot)$  为存活目标和衍生目标的状态转移方程,  $p_{S,k}$  为目标存活概率值,  $\gamma_k(\cdot)$  为新生目标强度.

## 2.2 更新步骤

若在时刻  $k$  接收到的测量集为  $\mathbf{Z}_k$ ,则各粒子的权重值更新方程为

$$w_{k|k}^i = \left\{ \sum_{z \in \mathbf{Z}_k} p_{D,k} g_k(z|\mathbf{x}_{k|k-1}^i, r_k^i) / \left[ \kappa_k(z) + p_{D,k} \sum_{j=1}^M \sum_{i=1}^{n_{r_k}} w_{j,k|k-1}^i g_k(z|\mathbf{x}_{k|k-1}^i, r_k^i) \right] \right\} w_{k|k-1}^i. \quad (14)$$

其中:  $g_k(\cdot)$  为观测方程,  $p_{D,k}$  为探测概率,  $\kappa_k(z)$  为杂波强度.为了对各个粒子进行重采样,首先要对粒子权重值进行归一化处理.由于各模型粒子权重值之和为目标个数的期望值

$$\hat{n}_k = \sum_{j=1}^M \sum_{i=1}^{n_{r_k}} w_{k|k}^i, \quad (15)$$

对归一化后粒子集  $\{w_{k|k}^i/\hat{n}_k, \mathbf{x}_{k|k}^i, r_{k|k}^i\}_{i=1}^L$  进行重采样,所得粒子集合  $\{(w^*)_{k|k}^i/\hat{n}_k, \mathbf{x}_{k|k}^i, r_{k|k}^i\}_{i=1}^L$  可用来近似 MMPHD 的后验强度

$$v_{k|k}(\mathbf{x}_{k|k}^i, r_{k|k}^i|\mathbf{Z}_k) = \sum_{i=1}^L (w^*)_{k|k}^i \delta(\mathbf{x}_{k|k}^i - \mathbf{x}_{k|k}^i, r_{k|k}^i - r_{k|k}^i). \quad (16)$$

MMPHD 后验强度不能直接得到目标状态,可以采用  $k$ -mean 方法<sup>[4]</sup>来提取目标状态和噪声方差.聚类  $\{\mathbf{x}_{k|k}^j\}_{j=1}^{J_k}$  获得各个目标状态  $\{\hat{\mathbf{x}}_{k|k}^n\}_{n=1}^{\hat{n}_k}$ ,系统噪声方差  $\hat{Q}$  和观测噪声方差  $\hat{R}$  的估计值为

$$\hat{Q}_{k|k} = \sum_{j=1}^{J_k} \frac{\hat{Q}_k^j (w^*)_{k|k}^j}{\hat{n}_{k|k}}, \quad \hat{R}_{k|k} = \sum_{j=1}^{J_k} \frac{\hat{R}_k^j (w^*)_{k|k}^j}{\hat{n}_{k|k}}. \quad (17)$$

输出时刻  $k$  的估计值,包括目标状态  $\{\hat{\mathbf{x}}_{k|k}^n\}_{n=1}^{\hat{n}_k}$ ,目标个数  $\hat{n}_k$ ,系统噪声方差  $\hat{Q}$  和观测噪声方差  $\hat{R}$ .

## 3 仿真与分析

本节通过模拟真实二维空间的3个变速率转弯目标运动情况来验证本文的算法性能.假设目标在二维平面监控区域  $[-1000, 1000] \times [-1000, 1000]$  m 内,监控区域内总共有3个目标,分别为目标1、目标2和衍生目标3,目标状态和起始时间如表1所示.

表1 各目标状态及起始时间

目标	起始时间/s	结束时间/s	目标初始状态
目标1	1	400	[0; 100; -500; 300]
目标2	1	350	[-400; 100; 400; -200]
衍生目标	35	350	[36; 8; -320; 2]

假定新生目标符合泊松分布,其强度为

$$\nu_\gamma(\mathbf{x}) = 0.1N(\mathbf{x}; \mathbf{m}_\gamma^1, \mathbf{P}_\gamma) + 0.1N(\mathbf{x}; \mathbf{m}_\gamma^2, \mathbf{P}_\gamma).$$

其中

$$\mathbf{m}_\gamma^1 = [10; 100; -500; 300],$$

$$\mathbf{m}_\gamma^2 = [-410; 80; 400; -200],$$

$$\mathbf{P}_\gamma = \text{diag}[100, 50, 100, 50].$$

衍生目标也符合泊松分布,其强度为

$$D_\beta(\mathbf{x}) = 0.1N(\mathbf{x}; \mathbf{m}_\beta, \mathbf{P}_\beta),$$

方差  $\mathbf{P}_\beta = \text{diag}[25, 10, 25, 10]$ . 杂波均匀分布于观测区域,杂波强度  $\lambda_k = 20$ . 目标存活概率  $p_{S,k} = 0.99$ , 探测概率  $p_{D,k} = 0.99$ . 假定传感器位置为  $\mathbf{s} = [x_n^o; y_n^o]$ , 目标在  $k$  时刻转弯速率为  $w_{k,n-1}$ . 转弯速率  $w_{k,n} = w_{k,n-1} + \bar{w}_{k,n}$ ,  $\bar{w}_{k,n}$  为一个满足高斯分布的随机值. 目标的运动模型和观测模型为

$$\mathbf{x}_{k+1,n} = \begin{bmatrix} 1 & \frac{\sin w_{k,n-1} \Delta T}{w_{k,n-1}} & 0 \\ 0 & \cos w_{k,n-1} \Delta T & 0 \\ 0 & \frac{1 - \cos w_{k,n-1} \Delta T}{w_{k,n-1}} & 1 \\ 0 & \sin w_{k,n-1} \Delta T & 0 \end{bmatrix} \mathbf{x}_{k,n-1} + \begin{bmatrix} \frac{1 - \cos w_{k,n-1} \Delta T}{w_{k,n-1}} \\ -\sin w_{k,n-1} \Delta T \\ \frac{\sin w_{k,n-1} \Delta T}{w_{k,n-1}} \\ \cos w_{k,n-1} \Delta T \end{bmatrix} \mathbf{v}_{k,n},$$

$$\mathbf{y}_n = \begin{bmatrix} \tan^{-1} \left( \frac{x_{k,n} - x_n^o}{y_{k,n} - y_n^o} \right) \\ \sqrt{(x_{k,n} - x_n^o)^2 + (y_{k,n} - y_n^o)^2} \end{bmatrix} + \mathbf{n}_{k,n}.$$

其中: 目标运动噪声和观测噪声分别为  $\mathbf{v}_{k,n} = [\sigma_1^2; \sigma_2^2]$ ,  $\mathbf{n}_{k,n} = [\sigma_3^2; \sigma_4^2]$ ,  $\sigma_1^2 = \sigma_2^2$  为加速度噪声方差,  $\sigma_3^2$  为角度测量噪声方差,  $\sigma_4^2$  为距离测量方差. 仿真中 MMPHD 算法的每个模型都使用 500 个粒子, 其中 100 个粒子用于采样新生目标强度.

**实验 1** 噪声方差是时变的并且噪声模型已知.

目标持续观测时间为 400 s, 假定测量噪声  $\mathbf{n}_{k,n}$  的统计特性精确已知, 而系统噪声方差  $\mathbf{v}_{k,n}$  未知并变

化, 且随时间变化满足以下分布:

$$\sigma_1 = \sigma_2 = \begin{cases} 5, & 0 < k < 150; \\ 10, & 150 \leq k < 300; \\ 5, & 300 \leq k < 400. \end{cases} \quad (18)$$

仿真中, MMPHD 中存在两个模型,  $\sigma_1 = \sigma_2 = 5$  或  $\sigma_1 = \sigma_2 = 10$ , 传统 PHD 中噪声方差平方根设为  $\sigma_1 = \sigma_2 = 5$ .

图 1 为式 (17) 估计出的系统噪声方差平方根. 可见, 如果参数模型已知, MMPHD 滤波器能迅速地自适应估计噪声方差. 图 2 和图 3 分别为 MMPHD 和传统 PHD 算法的  $x$  轴和  $y$  轴目标状态估计, 其中, 直线为真实目标轨迹, 阴影为杂波, 圆圈为目标估计值.






图 1 MMPHD 算法系统噪声方差均方根估计



(a)  $x$  轴目标状态估计



(b)  $y$  轴目标状态估计

图 2 MMPHD 算法  $x$  轴和  $y$  轴观测值与估计值

在图 2 中, MMPHD 算法由于在滤波的同时对噪声也进行了估计, 因此具有较高的滤波精度, 在各个时刻都能跟踪上各个目标; 而图 3 中传统 PHD 在时

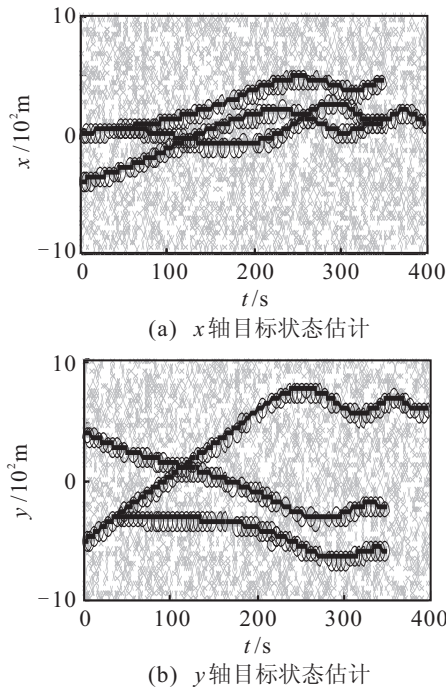


图3 传统PHD算法x轴和y轴观测值与估计值

刻0~50, 300~400, 由于预测噪声与真实噪声匹配, 对目标估计较好, 在时刻150~300时, 由于估计噪声值与实际噪声不相符, 丢失了许多目标, 且滤波精度也不高。

图4为采用OSPA脱靶距离对算法性能进行比较, 定义如下<sup>[10]</sup>:

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

仿真中设置  $c = 300, p = 1$ . 如果在时刻  $k$  目标个数与实际个数不相符, 则在该时刻OSPA距离将出现尖峰。




图4 两种算法OSPA距离对比

由图4可看出, MMPHD算法的脱靶距离小于传统PHD算法。在50s左右两种算法都出现了尖峰, 这是由于衍生目标在时刻35s出现, 对OSPA距离计算造成一定影响。特别地, 在时刻150~300, 传统PHD算法的OSPA距离出现了许多尖峰, 而MMPHD算法正常, 这是因为MMPHD能自适应地估计目标噪声方

差, 具有较高的滤波精度, 而传统PHD算法由于噪声方差不匹配, OSPA距离明显大于MMPHD算法。

**实验2** 噪声方差是时变的并且噪声模型未知。

假定系统噪声方差未知, 令模型噪声方差平方根由  $\sigma_1 = \sigma_2 = 4$  到  $\sigma_1 = \sigma_2 = 11$  以1递增, 共计8个模型, 并代入MMPHD算法中估计目标状态和噪声方差。图5给出了MMPHD算法的噪声方差估计, 由于噪声模型的不精确性, 在噪声方差变化时刻(时刻150, 300), MMPHD算法估计噪声方差存在一定的时间延迟, 但最终能自适应地跟踪噪声变化。




图5 MMPHD算法系统噪声方差均方根估计

图6给出了模型不精确时, MMPHD算法的x轴和y轴目标状态估计图, 可见MMPHD算法仍能较准确地估计各个目标。

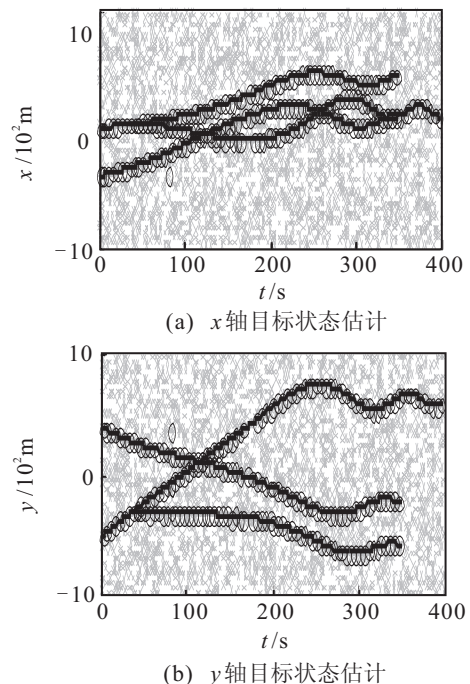


图6 模型不精确时MMPHD算法x轴和y轴观测值与估计值

图7给出了OSPA距离性能比较, 由于MMPHD算法需要一定时间来自适应地估计时变噪声方差, 在时刻150~180和时刻300~350的OSPA距离会出现

尖峰,当噪声方差被正确估计时, MMPHD 算法的 OSPA 距离变为正常.




图 7 不同算法 OSPA 距离对比

## 4 结 论

传统 PHD 算法能有效地对多目标进行估计,但在滤波前需要精确已知噪声的先验统计特性.在实际工程应用中,如果噪声先验信息是未知且时变的,则 PHD 算法易出现滤波精度下降甚至丢失目标的问题.对此,本文设计了一种 MMPHD 粒子滤波算法,该方法在进行滤波计算的同时,利用多模型估计器对未知时变的噪声统计进行实时估计和修正,有效地克服了传统 PHD 在噪声统计未知时变下跟踪性能不佳的缺点,并具有应对噪声变化的自适应能力. MMPHD 算法具有如下特点:适用于非线性跟踪系统,且对未知时变噪声统计的估计较准确,算法收敛性好,具有较强的鲁棒性.

## 参考文献(References)

- [1] 张俊根,姬红兵. 高斯混合粒子 PHD 滤波被动测角多目标跟踪[J]. 控制与决策, 2011, 26(3): 413-417.  
(Zhang J G, Ji H B. Gaussian mixture particle probability hypothesis density based passive bearing-only multi-target tracking[J]. Control and Decision, 2011, 26(3): 413-417.)

- [2] Pollard E, Pannetier B, Romabaut M. Hybrid algorithms for multitarget tracking using MHT and GM-CPHD[J]. IEEE Trans on Aerospace and Electronic Systems, 2011, 47(2): 832-847.
- [3] Mahler R. Multitarget Bayes filtering via first-order multitarget moments[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.
- [4] Vo B N, Singh S, Doucet A. Sequential Monte Carlo methods for multi-target filtering with random finite sets[J]. IEEE Trans on Aerospace and Electronic Systems, 2005, 41(4): 1224-1244.
- [5] Mohamed A H, Schwarz K P. Adaptive Kalman filtering for INS/GPS[J]. J of Geodesy, 1999, 73(5): 193-203.
- [6] Storvik G. Particle filters for state-space models with the presence of unknown static parameters[J]. IEEE Trans on Signal Processing, 2002, 50(2): 281-289.
- [7] Sarkka S, Nummenmaa A. Recursive noise adaptive Kalman filtering by variational Bayesian approximations[J]. IEEE Trans on Automatic Control, 2009, 54(3): 596-600.
- [8] Li X R, Bar-Shalom Y. A recursive multiple model approach to noise identification[J]. IEEE Trans on Aerospace and Electronic Systems, 1994, 30(3): 671-684.
- [9] Vo B T, Vo B N, Cantoni A. Analytic implementations of the cardinalized probability hypothesis density filter[J]. IEEE Trans on Signal Processing, 2007, 55(7): 3553-3567.
- [10] Dominim S, Vo B T, Vo B N. A consistent metric for performance evaluation of multi-object filters[J]. IEEE Trans on Signal Processing, 2008, 56 (8): 3447-3457.

(责任编辑: 孙艺红)