

量化量测下的多目标变分贝叶斯 PHD 滤波

王明杰¹, 姬红兵¹, 张永权¹

1) 西安电子科技大学, 西安 710071

摘要: 为了满足数字传输和有限带宽的要求, 原始量测在发送到信息处理中心之前需要进行量化。在此基础上, 研究了量化量测下的多目标跟踪问题, 提出了变分贝叶斯量化概率假设密度(VBQPHD)滤波。该方法可联合估计量化量测噪声方差和目标状态, 并采用一个方差上界确定量化噪声方差估计的有效性。实验结果表明, 对于量化量测下的多目标跟踪问题, 本文所提方法的跟踪性能要优于传统的滤波方法。

关键词: 多目标跟踪; 量化量测; 变分贝叶斯; 概率假设密度

中图分类号: TN953 文献标识码: A

VBPHD for Multi-target tracking with quantized measurement

Mingjie Wang¹, Hongbing Ji¹, Yongquan Zhang¹

1) Xidian University, Xi'an 710071

Abstract: To meet the requirements of digital transmission with limited bandwidth, the raw measurements need to be quantized before transmitted to the information center. However, the quantized noise will degrade the target tracking performance. To tackle this problem, multi-target tracking with quantized measurements is investigated in this paper, and the variational Bayesian quantized probability hypothesis density (VBQPHD) filter is proposed. Both the variance of the quantized measurement noise and system state are jointly estimated, and the effectiveness of the variance estimate is verified by a known upper bound. Simulation results show that the proposed algorithm outperforms conventional quantized PHD method for multi-target tracking with quantized measurement.

Key words: Multi-target tracking; quantized measurement; variational Bayesian; probability hypothesis density

引言

被动多传感器多目标跟踪技术是多传感器数据融合系统的一个重要组成部分^{[1][2]}, 在军事和民用领域具有广阔的应用前景, 备受国内外专家学者的关注。随着传感器技术的不断发展, 单个传感器可以获取的信息量越来越大, 且传感器网络中包含的传感器数量也越来越多, 致使需要传输的数据量急剧增加。为了满足数字传输和有限带宽的要求, 需要对传感器得到的量测进行量化处理, 然后再传输到信息处理中心。

在处理量化量测的系统中, 由于量化误差的存在, 使得目标跟踪系统变得更加复杂。在假设量化区间是矩形的前提下, 文献[3]给出了利用数值算法近似最小均方误差(MMSE)估计的方法以处理量化量测下的状态估计问题。文献[4]结合多模型理论, 提出了概率量测定位滤波(PML)。在假设量化误差是高斯白噪声的情况下, 可以利用卡尔曼滤

波理论来进行状态估计^[5], 但卡尔曼滤波得到最优估计的前提是噪声方差必须已知, 在实际情况中, 精确的量化误差通常不易得到。一般情况下, 利用其上界来替代量化噪声的方差^[5], 但这样会带来较大的估计误差。另外, 如果将上述几种方法应用到多目标跟踪中, 需要处理数据关联问题, 致使滤波的计算量增加。

本文在假设量化噪声是高斯白噪声的情况下, 将随机集理论与变分贝叶斯(VB)技术相结合, 提出变分贝叶斯量化概率假设密度(VBQPHD)滤波联合估计量化量测噪声方差和目标状态, 并用一个方差上界确定量化噪声方差估计的有效性, 从而有效地解决了量化量测下的多目标状态估计问题。

1 问题描述

1.1 量化量测系统

假设系统的状态方程和量测方程分别为

$$\begin{aligned} \mathbf{x}_k &= \mathbf{F}\mathbf{x}_{k-1} + \mathbf{w}_k \\ \mathbf{y}_k &= \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \end{aligned} \quad (1)$$

其中, \mathbf{x}_k 表示 k 时刻的目标状态, \mathbf{y}_k 表示量测信息, \mathbf{F} 和 \mathbf{H} 分别表示状态转移矩阵和量测矩阵; $\mathbf{w}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k)$ 和 $\mathbf{v}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_k)$ 分别表示互不相关的过程噪声和量测噪声, 其中 $\mathcal{N}(\mathbf{0}, \Sigma)$ 表示均值为 0 且方差为 Σ 的高斯分布。

设初始状态 $x_0 \sim \mathcal{N}(m_0, P_0)$, 且与过程噪声和量测噪声不相关。 $\mathbf{R}_k = \text{diag}\{(\sigma_k^1)^2, \dots, (\sigma_k^d)^2\}$, $\text{diag}\{\cdot\}$ 表示对角矩阵, d 是量测噪声的维数。

为了满足数字传输和有限带宽的要求, 需要对传感器得到的量测进行量化处理, 表示为

$$\mathbf{z}_k = \mathcal{Q}(\mathbf{y}_k) \quad (2)$$

量化量测相当于在原有的量测上加了量化噪声^[11], 即

$$\mathbf{z}_k = \mathbf{y}_k + \mathbf{e}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k + \mathbf{e}_k \quad (3)$$

其中 $\mathbf{v}_k = \mathbf{v}_k + \mathbf{e}_k$, \mathbf{e}_k 是量化噪声, 在假设量化噪声是高斯白噪声的情况下, 其方差可近似表示为

$$\begin{aligned} \mathbf{R}_{\mathbf{e},k} &= E\{\mathbf{e}_k \mathbf{e}_k^T\} \\ &\leq \text{diag}\{(\Delta_k^1)^2/4, \dots, (\Delta_k^d)^2/4\} \end{aligned} \quad (4)$$

$\Delta_k^i (i=1 \dots d)$ 是量测每个分量的量化区间长度, 这样 \mathbf{v}_k 的方差可表示为

$$\begin{aligned} \mathbf{R}_{\mathbf{v},k} &= \mathbf{R}_{\mathbf{v},k} + \mathbf{R}_{\mathbf{e},k} \\ &\leq \text{diag}\{(\sigma_k^1)^2 + (\Delta_k^1)^2/4, \dots, (\sigma_k^d)^2 + (\Delta_k^d)^2/4\} \end{aligned} \quad (5)$$

2 变分贝叶斯量化 PHD 滤波

2.1 VBQPHD 递归

通过以上分析, 量化量测下的多目标跟踪问题可转化为量化量测噪声未知下的多目标状态估计问题。

基于随机集(RFS)^[6]的多目标跟踪方法有效避免了数据关联问题, 为多目标跟踪提供了全新的思路。文献[7]提出了基于随机集的多目标贝叶斯滤波和概率假设密度(PHD)滤波, 文献[8]在此基础上提出了能提供 PHD 滤波闭合解的高斯混合 PHD 滤波。

变分贝叶斯方法可有效估计未知噪声方差^[9], 文献[10]把 PHD 滤波与变分贝叶斯方法相结合, 处理传统量测下的多目标跟踪问题。

假设系统状态 \mathbf{x} 和量化量测噪声方差 \mathbf{R}_v 是相互独立的, 目标存活概率 p_s , 检测概率 p_D , 且 $k-1$ 时刻系统状态和量化量测噪声方差的联合后验 PHD 为 $D_{k-1}(\mathbf{x}, \mathbf{R}_v)$, 则预测 PHD $D_{k|k-1}(\mathbf{x}, \mathbf{R}_v)$ 可以表示为

$$\begin{aligned} D_{k|k-1}(\mathbf{x}, \mathbf{R}_v) &= \int (p_s f_{k|k-1}(\mathbf{x}|\mathbf{x}') + b_{k|k-1}(\mathbf{x}|\mathbf{x}')) p_{k|k-1}(\mathbf{R}_v|\mathbf{R}') \\ &\quad \times D_{k-1}(\mathbf{x}', \mathbf{R}') d(\mathbf{x}') d(\mathbf{R}') + \gamma_k(\mathbf{x}, \mathbf{R}_v) \end{aligned} \quad (6)$$

其中, $f_{k|k-1}(\mathbf{x}|\mathbf{x}')$ 表示多目标状态转移函数, $b_{k|k-1}(\mathbf{x}|\mathbf{x}')$ 表示 k 时刻衍生目标集合的 PHD, $p_{k|k-1}(\mathbf{R}_v|\mathbf{R}')$ 表示噪声的转移概率, $\gamma_k(\mathbf{x}, \mathbf{R}_v)$ 表示 k 时刻新生目标 PHD。

当 k 时刻的量测产生时, 更新的联合后验分布表示为

$$\begin{aligned} D_{k|k}(\mathbf{x}, \mathbf{R}_v) &= (1 - p_D) D_{k|k-1}(\mathbf{x}, \mathbf{R}_v) \\ &\quad + \sum_{\mathbf{z} \in \mathcal{Z}_k} \frac{p_D D_{D,k}(\mathbf{x}, \mathbf{R}_v | \mathbf{z})}{\kappa_k(\mathbf{z}) + \iint p_D D_{D,k}(\mathbf{x}', \mathbf{R}' | \mathbf{z}) d(\mathbf{x}') d(\mathbf{R}')} \end{aligned} \quad (7)$$

其中, $D_{D,k}(\mathbf{x}, \mathbf{R}_v | \mathbf{z}) = g(\mathbf{z}|\mathbf{x}, \mathbf{R}_v) D_{k|k-1}(\mathbf{x}, \mathbf{R}_v)$, $\kappa_k(\mathbf{z})$ 表示杂波随机集强度。

由于无法得到详细的 \mathbf{R}_v 和 $p_{k|k-1}(\mathbf{R}_v|\mathbf{R}')$, 所以无法得到 $D_{D,k}(\mathbf{x}, \mathbf{R}_v | \mathbf{z})$ 的解析解。假设 $D_{D,k}(\mathbf{x}, \mathbf{R}_v | \mathbf{z})$ 可近似为两个因式 $Q_{\mathbf{x},k}(\mathbf{x})$ 和 $Q_{\mathbf{R},k}(\mathbf{R}_v)$ 的乘积, 即

$$D_{D,k}(\mathbf{x}, \mathbf{R}_v | \mathbf{z}) \approx Q_{\mathbf{x},k}(\mathbf{x}) Q_{\mathbf{R},k}(\mathbf{R}_v) \quad (8)$$

为了能够得到更精确的联合后验的近似, 此处利用变分法来最小化 $Q_{\mathbf{x},k}(\mathbf{x}) Q_{\mathbf{R},k}(\mathbf{R}_v)$ 对 $D_{D,k}(\mathbf{x}, \mathbf{R}_v | \mathbf{z})$ 的 KL 散度, 具体推导过程与文献[10]相似。最后, 可得到强度函数 $Q_{\mathbf{x},k}(\mathbf{x})$ 和 $Q_{\mathbf{R},k}(\mathbf{R}_v)$ 分别是高斯分布和逆伽玛分布的积分形式

$$\begin{aligned} Q_{\mathbf{x},k}(\mathbf{x}) &= \int \mathcal{N}(\mathbf{x}'; \mathbf{m}_k, \mathbf{P}_k) d(\mathbf{x}') \\ Q_{\mathbf{R},k}(\mathbf{R}_v) &= \int \left(\prod_{l=1}^d \text{IG}((\sigma_{k,l})^2; \alpha_{k,l}, \beta_{k,l}) \right) d(\sigma_{k,l}) \end{aligned} \quad (9)$$

其中 d 表示量化量测噪声的维数, $\text{IG}(\cdot|\alpha, \beta)$ 表示参数为 α, β 的逆伽玛分布。

2.2 高斯混合 VBQPHD

通过以上推导, 当初始条件符合文献[8]时, 可以得到高斯混合变分贝叶斯量化 PHD(GM-VBQPHD)算法。具体如下:

(1) 预测: 假设 $k-1$ 时刻联合后验

PHD $D_{k-1}(\mathbf{x}, \mathbf{R}_v)$ 是高斯和逆伽玛的混合形式, 即

$$D_{k-1}(\mathbf{x}, \mathbf{R}_v) \square \sum_{i=1}^{J_{k-1}} [w_{k-1}^{(i)} \mathbf{N}(\mathbf{x}; \mathbf{m}_{k-1}^{(i)}, \mathbf{P}_{k-1}^{(i)}) \times \prod_{l=1}^d \text{IG}((\sigma_{k-1,l}^{(i)})^2; \alpha_{k-1,l}^{(i)}, \beta_{k-1,l}^{(i)})] \quad (10)$$

那么预测也可近似为高斯和逆伽玛的混合形式

$$D_{k|k-1}(\mathbf{x}, \mathbf{R}_v) = v_{S,k|k-1}(\mathbf{x}, \mathbf{R}_v) + b_{k|k-1}(\mathbf{x}, \mathbf{R}_v) + \gamma_k(\mathbf{x}, \mathbf{R}_v) \quad (11)$$

其中,

$$v_{S,k|k-1}(\mathbf{x}, \mathbf{R}_v) = p_S \sum_{i=1}^{J_{k-1}} [w_{k-1}^{(i)} \mathbf{N}(\mathbf{x}; \mathbf{m}_{S,k|k-1}^{(i)}, \mathbf{P}_{S,k|k-1}^{(i)}) \times \prod_{l=1}^d \text{IG}((\sigma_{S,k|k-1,l}^{(i)})^2; \alpha_{S,k|k-1,l}^{(i)}, \beta_{S,k|k-1,l}^{(i)})] \quad (12)$$

$$b_{k|k-1}(\mathbf{x}, \mathbf{R}_v) = \prod_{i=1}^{J_{k-1}} \prod_{j=1}^{J_{b,k}} [w_{k-1}^{(i)} w_{b,k}^{(j)} \mathbf{N}(\mathbf{x}; \mathbf{m}_{b,k|k-1}^{(i,j)}, \mathbf{P}_{b,k|k-1}^{(i,j)}) \times \prod_{l=1}^d \text{IG}((\sigma_{b,k|k-1,l}^{(i,j)})^2; \alpha_{b,k|k-1,l}^{(i,j)}, \beta_{b,k|k-1,l}^{(i,j)})] \quad (13)$$

$$\gamma_k(\mathbf{x}, \mathbf{R}_v) = \sum_{i=1}^{J_{\gamma,k}} [w_{\gamma,k}^{(i)} \mathbf{N}(\mathbf{x}; \mathbf{m}_{\gamma,k}^{(i)}, \mathbf{P}_{\gamma,k}^{(i)}) \times \prod_{l=1}^d \text{IG}((\sigma_{\gamma,k,l}^{(i)})^2; \alpha_{\gamma,k,l}^{(i)}, \beta_{\gamma,k,l}^{(i)})] \quad (14)$$

$$\mathbf{m}_{S,k|k-1}^{(i)} = \mathbf{F}_{S,k-1}^{(i)} \mathbf{m}_{S,k-1}^{(i)} \quad (15)$$

$$\mathbf{P}_{S,k|k-1}^{(i)} = \mathbf{F}_{S,k-1}^{(i)} \mathbf{P}_{S,k-1}^{(i)} (\mathbf{F}_{S,k-1}^{(i)})^T + \mathbf{Q}_{k-1} \quad (16)$$

$$\mathbf{m}_{b,k|k-1}^{(i,j)} = \mathbf{F}_{b,k-1}^{(j)} \mathbf{m}_{b,k-1}^{(i,j)} + \mathbf{d}_{b,k-1}^{(j)} \quad (17)$$

$$\mathbf{P}_{b,k|k-1}^{(i,j)} = \mathbf{F}_{b,k-1}^{(j)} \mathbf{P}_{b,k-1}^{(i,j)} (\mathbf{F}_{b,k-1}^{(j)})^T + \mathbf{Q}_{b,k-1}^{(j)} \quad (18)$$

$v_{S,k|k-1}(\mathbf{x}, \mathbf{R}_v)$ 表示从 $k-1$ 时刻到 k 时刻存活目标集合的 PHD, J_{k-1} , w_{k-1} , $\mathbf{m}_{S,k|k-1}^{(i)}$, $\mathbf{P}_{S,k|k-1}^{(i)}$ 是存活目标 PHD 的参数^[8]; $J_{b,k}$, $w_{b,k}^{(j)}$, $\mathbf{m}_{b,k|k-1}^{(i,j)}$, $\mathbf{P}_{b,k|k-1}^{(i,j)}$ 是衍生目标集合 PHD $b_{k|k-1}(\mathbf{x}, \mathbf{R}_v)$ 的参数^[8]; $J_{\gamma,k}$, $w_{\gamma,k}^{(i)}$, $\mathbf{m}_{\gamma,k}^{(i)}$, $\mathbf{P}_{\gamma,k}^{(i)}$ 是新生目标 PHD $\gamma_k(\mathbf{x}, \mathbf{R}_v)$ 的参数^[8]。

逆伽玛分布的参数预测可以根据以下公式得到

$$\alpha_{S,k|k-1,l}^{(i)} = \rho \square \alpha_{S,k-1,l}^{(i)} \quad (19)$$

$$\beta_{S,k|k-1,l}^{(i)} = \rho \square \beta_{S,k-1,l}^{(i)} \quad (20)$$

$$\alpha_{b,k|k-1,l}^{(i,j)} = \rho \square \alpha_{b,k-1,l}^{(i,j)} \quad (21)$$

$$\beta_{b,k|k-1,l}^{(i,j)} = \rho \square \beta_{b,k-1,l}^{(i,j)} \quad (22)$$

其中, $\rho \in (0,1]$ 是衰减因子。

(2)更新: 假设预测联合 PHD $D_{k|k-1}(\mathbf{x}, \mathbf{R}_v)$ 可近似为高斯和逆伽玛的混合形式, 即

$$D_{k|k-1}(\mathbf{x}, \mathbf{R}_v) \square \sum_{i=1}^{J_{k-1}} [w_{k|k-1}^{(i)} \mathbf{N}(\mathbf{x}; \mathbf{m}_{k|k-1}^{(i)}, \mathbf{P}_{k|k-1}^{(i)}) \times \prod_{l=1}^d \text{IG}((\sigma_{k|k-1,l}^{(i)})^2; \alpha_{k|k-1,l}^{(i)}, \beta_{k|k-1,l}^{(i)})] \quad (23)$$

则强度函数 $Q_{\mathbf{x},k}(\mathbf{x})$ 和 $Q_{\mathbf{R},k}(\mathbf{R}_v)$ 可以表示为

$$Q_{\mathbf{x},k}(\mathbf{x}) = \sum_{i=1}^{J_{k-1}} [w_k^{(i)} \mathbf{N}(\mathbf{x}; \mathbf{m}_k^{(i)}, \mathbf{P}_k^{(i)})] \quad (24)$$

$$Q_{\mathbf{R},k}(\mathbf{R}_v) = \sum_{i=1}^{J_{k-1}} \prod_{l=1}^d \text{IG}((\sigma_{k,l}^{(i)})^2; \alpha_{k,l}^{(i)}, \beta_{k,l}^{(i)})$$

因此, 联合后验 PHD 可表示为

$$D_{k|k}(\mathbf{x}, \mathbf{R}_v) \square (1-p_D) D_{k|k-1} + \sum_{\mathbf{z} \in \mathbf{Z}_k} \sum_{j=1}^{J_{k-1}} [w_k^{(j)} \mathbf{N}(\mathbf{x}; \mathbf{m}_{k|k}^{(j)}, \mathbf{P}_{k|k}^{(j)}) \times \prod_{l=1}^d \text{IG}((\sigma_{k,l}^{(j)})^2; \alpha_{k,l}^{(j)}, \beta_{k,l}^{(j)})] \quad (25)$$

其余参数可根据以下的迭代计算得到, 具体过程为:

首先, 令 $\mathbf{m}_{k|k}^{(j)} \stackrel{(0)}{=} \mathbf{m}_{k|k-1}^{(j)}$, $\mathbf{P}_{k|k}^{(j)(0)} = \mathbf{P}_{k|k-1}^{(j)}$, $\alpha_{k,l}^{(j)} = 0.5 + \alpha_{k|k-1,l}^{(j)}$, $\beta_{k,l}^{(j)(0)} = \beta_{k|k-1,l}^{(j)}$, for $l = 1, \dots, d$ 。然后根据式(27)–(32)进行迭代。

$$\mathbf{R}_k^{(j)(n)} = \text{diag} \left[\frac{\beta_{k,l}^{(j)(n)}}{\alpha_{k,l}^{(j)}}, \dots, \frac{\beta_{k,d}^{(j)(n)}}{\alpha_{k,d}^{(j)}} \right] = \text{diag} \{ (\sigma_k^{1,j})^2, \dots, (\sigma_k^{d,j})^2 \} \quad (26)$$

根据式(5)可知, 加入量化噪声后致使量化测量噪声不确定, 但可得到量化测量噪声方差的上界, 因此, 我们可引入一步判定以提高滤波性能。如果 $(\sigma_k^{l,j})^2 \geq (\sigma_k^l)^2 + (\Delta_k^l)^2/4$, 则令 $(\sigma_k^{l,j})^2 = (\sigma_k^l)^2 + (\Delta_k^l)^2/4$, 否则直接采用 $(\sigma_k^{l,j})^2$ 。

$$\mathbf{K}_k^{(j)(n)} = \mathbf{P}_{k|k-1}^{(j)} \mathbf{H}_k^T [\mathbf{H}_k \mathbf{P}_{k|k-1}^{(j)} \mathbf{H}_k^T + \mathbf{R}_k^{(j)(n)}]^{-1} \quad (27)$$

$$\mathbf{m}_{k|k}^{(j)(n)} = \mathbf{m}_{k|k-1}^{(j)} + \mathbf{K}_{k|k-1}^{(j)(n)} (\mathbf{y} - \mathbf{H}_k \mathbf{m}_{k|k-1}^{(j)}) \quad (28)$$

$$\mathbf{P}_{k|k}^{(j)(n)} = [\mathbf{I} - \mathbf{K}_k^{(j)(n)} \mathbf{H}_k] \mathbf{P}_{k|k-1}^{(j)} \quad (29)$$

$$w_k^{(j)(n)} = \frac{p_{D,k} w_{k|k-1}^{(j)} N(\mathbf{y}; \mathbf{H}_k \mathbf{m}_{k|k-1}^{(j)}, \mathbf{S}_{k|k-1}^{(j)(n)})}{\kappa_k(\mathbf{y}) + p_{D,k} \sum_{i=1}^{J_{k|k-1}} w_{k|k-1}^{(i)} N(\mathbf{y}; \mathbf{H}_k \mathbf{m}_{k|k-1}^{(i)}, \mathbf{S}_{k|k-1}^{(i)(n)})} \quad (30)$$

$$\beta_{k,i}^{(j)(n+1)} = \beta_{k,i}^{(j)} + \frac{1}{2} (\mathbf{y} - \mathbf{H}_k \mathbf{m}_{k|k}^{(j)(n)})_i^2 + \frac{1}{2} (\mathbf{H}_k \mathbf{P}_k^{(j)(n)} \mathbf{H}_k^T)_{ii} \quad (31)$$

其中, $n \in [1, N]$, N 表示最大迭代次数。

当估计状态值满足 $\|\mathbf{m}_{k|k}^{(j)(n)} - \mathbf{m}_{k|k}^{(j)(n-1)}\| < \varepsilon$ 或者达到最大迭代次数, 停止迭代。最后, 可得到参数值 $w_k^{(j)} = w_k^{(j)(n)}$, $\mathbf{m}_k^{(j)} = \mathbf{m}_{k|k}^{(j)(n)}$, $\mathbf{P}_k^{(j)} = \mathbf{P}_{k|k}^{(j)(n)}$, $\beta_{k,l}^{(j)} = \beta_{k,l}^{(j)(n)}$ 。

3 实验仿真

为了验证所提方法的有效性, 考虑二维仿真场景中的多目标跟踪问题。系统的状态方程和量测方程如(1)式所示。其中,

$$\mathbf{F} = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad \mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$$

量化量测方程 $\mathbf{z}_k = \Delta \text{floor}(\mathbf{y}_k / \Delta)$, 其中 Δ 是基本量化尺度, $\text{floor}(x)$ 是向下取整函数, 表示取不大于 x 的最大整数。另外, 过程噪声方差 $\mathbf{Q}_k = \text{diag}[\sigma_{w1}^2, \sigma_{w2}^2]$, $\sigma_{w1} = \sigma_{w2} = 0.5m$, 观测噪声方差 $\mathbf{R}_{v,k} = \text{diag}[\sigma_{v1}^2, \sigma_{v2}^2]$, $\sigma_{v1} = \sigma_{v2} = 1m$ 。

假设场景中共有四个目标做匀速直线运动, 目标 1 在 $k=1$ 时刻出现, 持续 25s, 且初始状态为 $\mathbf{m}_1 = [10m, 10m, 2.6m/s, 1.2m/s]^T$, 目标 2,3,4 出现在第 7 时刻, 第 11 时刻, 第 15 时刻, 分别在第 30,35,40 时刻消失。本文只考虑新生目标, 未考虑衍生目标, 且新生目标随机集 PHD 为

$$\gamma_k(\mathbf{x}, \mathbf{R}_v) = 0.02 \times \sum_{i=1}^3 (N(\mathbf{x}; \mathbf{m}_{\gamma,k}^{(i)}, \mathbf{P}_{\gamma,k}^{(i)}) \times \prod_{l=1}^d \text{IG}((\sigma_{\gamma,k,l}^{(i)})^2; \alpha_{\gamma,k,l}^{(i)}, \beta_{\gamma,k,l}^{(i)})) \quad (32)$$

其中,

$$\mathbf{m}_{\gamma,k}^{(1)} = [10m, 60m, 0m/s, 0m/s]^T \quad (33)$$

$$\mathbf{m}_{\gamma,k}^{(2)} = [70m, 0m, 0m/s, 0m/s]^T \quad (34)$$

$$\mathbf{m}_{\gamma,k}^{(3)} = [90m, 90m, 0m/s, 0m/s]^T \quad (35)$$

$$\mathbf{P}_{\gamma,k} = \text{diag}[5, 5, 1, 1] \quad (36)$$

目标的存活概率和检测概率分别是 $p_s = 0.99$, $p_D = 0.98$, 设杂波数服从均值是 3 的 Poisson 分布, 在观测区域内均匀分布。采样间隔 $T=1s$, 共采样 40 次。逆伽玛分布参数的初始值设为: $\alpha_0 = \beta_0 = 1$, 衰减因子 $\rho = 0.9$ 。由于混合项随着时间的增加而增加, 所以在滤波的过程中需进行修剪合并处理, 修剪合并处理方法与文献 [10] 相同。修剪阈值 $T_1 = 10^{-5}$, $T_2 = 100$, 合并门限 $U = 4$, 最大的高斯逆伽玛混合项数目 $J_{\max} = 100$ 。

图 1 为基本量化尺度 $\Delta = 2m$ 时采用本文方法单次实验的跟踪结果。其中, 实线表示目标真实运动轨迹, “*” 表示所提方法的滤波结果。

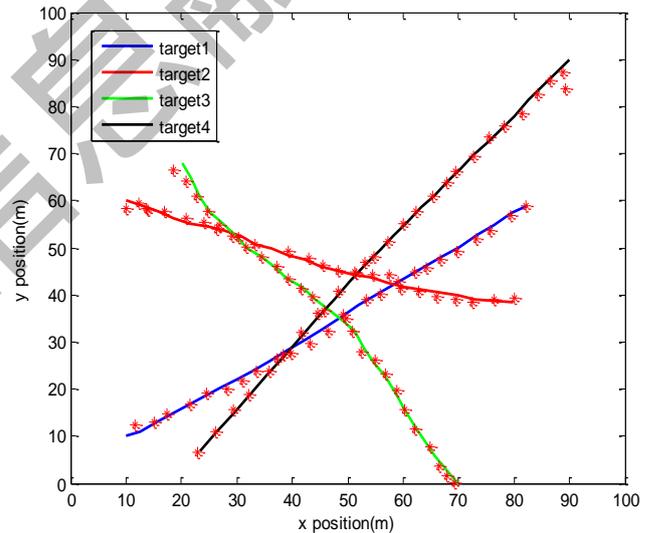


图 1 本文算法单次滤波结果

为了更好地比较算法的跟踪性能, 我们将直接采用量化量测得来的滤波(QPHD)结果与本文算法进行比较, 并进行了 100 次蒙特卡洛实验。图 2 和图 3 分别为基本量化尺度 $\Delta = 2m$ 时两种算法的目标数估计均值以及 OSPA 距离。通过对比可知, 本文所提算法的跟踪性能要优于 QPHD 滤波的性能。

图 4 和图 5 是量化尺度分别为 $\Delta = 2m$ 和 $\Delta = 5m$ 时两种方法的 OSPA 距离。由图可知, 当基本量化尺度增大时, 两种滤波性能都有所下降, 这是因为基本量化尺度增大导致量化误差也随之增大, 但量化 PHD 滤波算法性能下降速度明显快于本文方法。

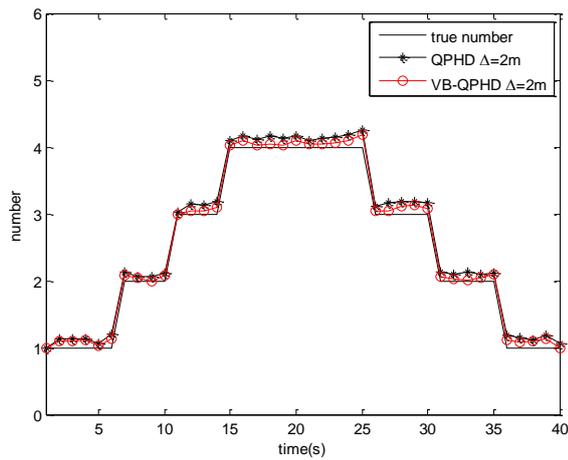


图 2 VBQPHD 滤波与 QPHD 滤波目标数估计

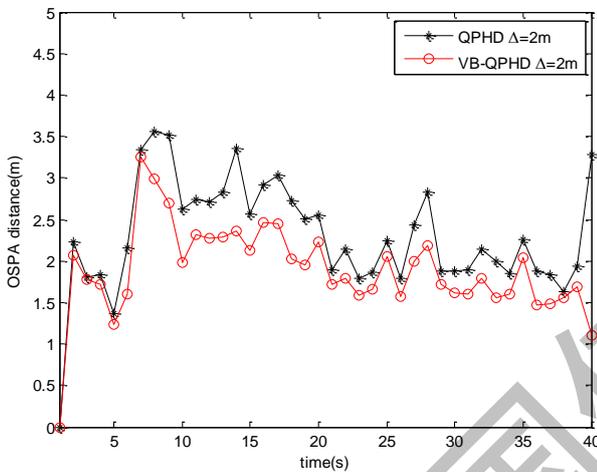


图 3 VBQPHD 滤波与 QPHD 滤波 OSPA 距离

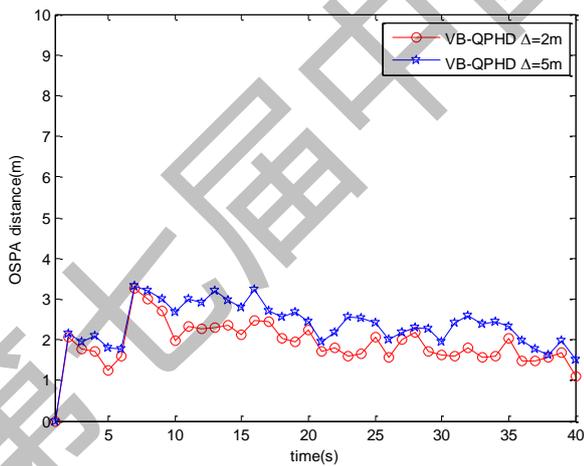


图 4 VBQPHD 滤波在 $\Delta = 2m$ 与 $\Delta = 5m$ 时 OSPA 距离

结论

量化量测下的多目标跟踪技术是多传感器数据融合系统的一个重要组成部分, 本文将变分贝叶

斯方法与随机集理论相结合, 通过对多目标状态和未知量化噪声方差进行同时估计, 很好地处理了量化量测下的多目标跟踪问题。实验结果表明, 所提方法性能优于直接利用量化量测进行跟踪的性能, 并能得到很好的状态估计结果。

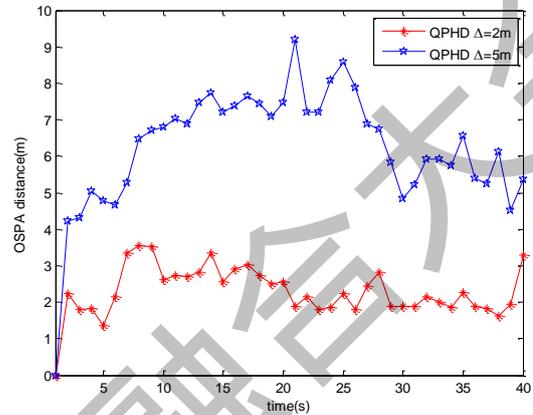


图 5 QPHD 滤波在 $\Delta = 2m$ 与 $\Delta = 5m$ 时 OSPA 距离

参考文献

- [1] E. Waltz, J. Llinas. *Multisensor data fusion* [M]. Boston: Artech house, 1990.
- [2] Bar Shalom Y. *Tracking and data association*[M]. Academic Press Professional, 1987.
- [3] Z. Duan, V. P. Jilkov, X. R. Li. State estimation with quantized measurements: Approximate MMSE approach [C]. *11th Intl. Conf. on Info. Fusion*, 2008: 1-6.
- [4] V. P. Jilkov, Z. Duan, X. R. Li. State Estimation with Quantized Measurements: Multiple Model Approach. *Proc. of ICIF 2007*: 1-7.
- [5] S. L. Sun, J. Y. Lin, L. H. Xie, W. D. Xiao. Quantized Kalman filtering [C]. *IEEE 22nd International Symposium on Intelligent Control*, USA, IEEE, 2006: 7-12.
- [6] I. R. Goodman. *Mathematics of data fusion* [M]. Springer Science & Business Media, 1997.
- [7] R. Mahler. Multi-target Bayes filtering via first-order multi-target moments [J]. *IEEE Trans. Aerosp. Electron. Syst.*, 2003, 39(4): 1152-1178.
- [8] B. N. Vo, W. K. Ma. The Gaussian mixture probability hypothesis density filter [J]. *IEEE Trans. on Signal Process.*, 2006, 54(11): 4091-4104.
- [9] S. Sarkka. Recursive noise adaptive kalman filtering by variational bayesian approximations [J]. *IEEE Trans. on Automatic Control*, 2009, 54(3): 596-600.

[10] J. Yang, H. Ge. Adaptive probability hypothesis density filter based on variational Bayesian approximation for multi-target tracking [J]. *IET Radar Sonar Navig.* 2013, 7(9): 959–967.

[11] B. Widrow, I. Kollar, M. C. Liu. Statistical theory of quantization [J]. *IEEE Transactions on Instrumentation and Measurement*, 1996, 45(2):353-361.

作者简介:

王明杰 (1988-), 男, 内蒙古, 博士研究生, 研究方向: 量化量测多目标跟踪, 随机集滤波。

E-mail: dtwmingjie@163.com

通讯作者: 姬红兵 (1963-), 男, 教授。

E-mail: hbji@xidian.edu.cn

基金项目:

国家自然科学基金 (61372003)

第七届中国信息融合大会