

基于星凸随机超曲面的扩展目标伽马高斯混合势概率假设密度滤波器

李翠芸[†], 王精毅, 姬红兵, 刘 远

(西安电子科技大学 电子工程学院, 陕西 西安 710071)

摘要: 针对杂波和检测不确定情况下扩展目标形状估计精度低的问题, 提出了一种基于星凸随机超曲面模型(SRHM)的扩展目标伽马高斯混合势概率假设密度(CPHD)滤波器. 该算法在高斯混合概率假设密度滤波的框架下, 首先将目标形状建模为星凸随机超曲面, 然后通过CPHD滤波估计出目标的质心位置和目标数目, 最后通过将已估计的目标质心位置作为目标形状的中心点来结合量测对目标形状进行估计. 其中, 算法通过自适应估计尺度变换因子对形状边界进行约束优化, 解决了星凸随机超曲面模型存在的边界形状不规则的问题. 设计扩展目标个数未知以及含有杂波的实验场景, 实验结果验证了该算法的有效性和可行性.

关键词: 星凸随机超曲面; 势概率假设密度滤波器; 形状估计; 伽马函数; 约束优化

引用格式: 李翠芸, 王精毅, 姬红兵, 等. 基于星凸随机超曲面的扩展目标伽马高斯混合势概率假设密度滤波器. 控制理论与应用, 2019, 36(5): 825 – 830

DOI: 10.7641/CTA.2018.60149

Gamma Gaussian-mixture CPHD filter based on star-convex random hypersurface for extended targets

LI Cui-yun[†], WANG Jing-yi, JI Hong-bing, LIU Yuan

(School of Electronic Engineering, Xidian University, Xi'an Shaanxi 710071, China)

Abstract: In view of the low accuracy of shape estimation in multiple extended target tracking under the circumstances of clutter and detection uncertainty, a Gamma Gaussian-mixture cardinalized probability hypothesis density (CPHD) filter for extended target tracking, which is based on star-convex random hypersurface model (SRHM), is proposed. Firstly, under the Gaussian-mixture CPHD filter framework, the proposed algorithm models the shape of the target as star-convex random hypersurface model. The CPHD filter is then used to estimate the centroid position and the number of targets. Finally, after taking the estimated centroid position as the center of the target's shape, the algorithm estimates the shape of the target through the use of the acquired measurements. The problem of irregular shape boundary, which exists in the star-convex random hypersurface model is solved by adaptively estimating the scaling factor and applying the constrained optimization method to optimize shape boundary in this algorithm. The simulation in clutter environment with the unknown number of extended target validates the effectiveness and feasibility of the proposed algorithm.

Key words: star-convex random hypersurface models; cardinalized probability hypothesis density filter; shape estimation; gamma function; constrained optimization

Citation: LI Cuiyun, WANG Jingyi, JI Hongbing, et al. Gamma Gaussian-mixture CPHD filter based on star-convex random hypersurface for extended targets. *Control Theory & Applications*, 36(5): 825 – 830

1 引言

近年来,随着高分辨率雷达的发展,对扩展目标跟踪算法的研究引起了国内外学者的高度关注^[1-4]. 2008年Koch^[5]提出了一种基于随机矩阵的扩展目标跟踪方法,该方法用随机矩阵来储存扩展目标的形状

和大小信息. 2012年,Granström等人^[6]将随机矩阵和扩展目标概率假设密度(extended-target probability hypothesis density, ET-PHD)滤波器相结合,提出了高斯逆威舍特PHD滤波器. 由于随机矩阵方法在质心状态的预测和更新与目标扩散程度的估计相关联,使得

收稿日期: 2016-03-08; 录用日期: 2018-11-12.

[†]通信作者. E-mail: cyli@xidian.edu.cn.

本文责任编辑: 潘泉.

国家自然科学基金项目(61372003), 国家自然科学基金青年基金项目(61301289)资助.

Supported by the National Natural Science Foundation of China (61372003) and the National Natural Science Foundation Youth Found (61301289).

估计精度受限. 文献[7]表明势概率假设密度(cardinalized probability hypothesis density, CPHD)滤波器解决了PHD估计目标数不准确的缺陷, 故本文在CPHD的基础上, 利用椭圆随机超曲面对扩展目标进行建模, 此种滤波器在扩展目标的质心状态和椭圆扩展形状长短轴的估计精度方面优于基于随机矩阵的伽马高斯混合逆威舍特CPHD滤波器, 但在形状估计方面, 此方法只能估计出目标扩展形状的长短轴.

2011年, Baum等人^[8]提出了星凸随机超曲面模型, 使用该模型对扩展目标建模, 可以跟踪形状不规则的目标, 并有很好的近似程度, 但是在仿真中设定的参数都为先验已知, 不能自适应估计目标形状, 且没有考虑杂波和目标漏检的情况, 并不适用于实际场景. 2016年, Feng等人^[9]提出一种基于箱粒子的势均衡多伯努利扩展目标跟踪算法, 在降低计算复杂度的同时实现了对椭圆目标的有效跟踪, 但该方法对非椭圆目标的估计较差, 限制了应用范围.

针对以上问题, 本文提出了一种基于星凸随机超曲面的扩展目标伽马高斯混合CPHD滤波器, 该算法使用星凸随机超曲面模型对量测进行建模, 将目标状态参数和形状参数一起进行滤波更新, 并且在每一步更新中, 根据量测自适应地估计形状参数, 并对扩展形状进行约束优化, 从而可以在有杂波和漏检情况下准确估计星凸形目标的状态和形状. 仿真实验验证了算法的有效性和可行性.

2 基础理论

2.1 多扩展目标伽马高斯混合CPHD滤波器

伽马函数 $\text{GAM}(\gamma; \alpha, \beta)$ 表示伽马概率密度函数, $\gamma > 0$. 定义在形状参数 $\alpha > 0$ 和逆尺度参数 $\beta > 0$ 的情况下:

$$\text{GAM}(\gamma; \alpha, \beta) = \frac{\beta^\alpha}{\Gamma(\alpha)} \gamma^{\alpha-1} e^{-\beta\gamma}. \quad (1)$$

扩展目标状态集可以看作是一个随机有限集(random finite sets, RFS), 表示为

$$X_k = \{\xi_k^{(i)}\}_{i=1}^{N_k, x}, \quad \xi_k^{(i)} \triangleq \{\gamma_k^{(i)}, x_k^{(i)}\}_{i=1}^{N_k, x},$$

其中: N_k, x 表示目标的数量, $\gamma^{(i)}$ 表示第*i*个目标的量测率, $x^{(i)}$ 表示第*i*个目标的质心运动状态参数, 则该RFS的概率假设密度和势分布分别可以用 $D(\xi_k)$ 和 $P(n)$ 来描述.

目标状态集RFS的预测可表示为

$$D_{k|k-1}(\xi) = D_{k|k-1}^s(\xi) + D_{k|k-1}^b(\xi), \quad (2)$$

$$D_{k|k-1}^s(\xi) = p_{S,k} \sum_{j=0}^{J_{k-1}} w_{k-1}^{(j)} G(\gamma; \alpha_{k|k-1}^{(j)}, \beta_{k|k-1}^{(j)}) \times N(\xi; m_{k|k-1}^{(j)}, P_{k|k-1}^{(j)}), \quad (3)$$

$$D_{k|k-1}^b(\xi) = \sum_{j=1}^{J_{b,k}} w_{b,k}^{(j)} G(\gamma; \alpha_{b,k}^{(j)}, \beta_{b,k}^{(j)}) \times$$

$$N(\xi; m_{b,k}^{(j)}, P_{b,k}^{(j)}), \quad (4)$$

其中: J_{k-1} 表示预测分量的数量, $w_{k-1}^{(j)}$ 表示第*j*个分量的权值, $m_{k|k-1}^{(j)}$ 和 $P_{k|k-1}^{(j)}$ 分别表示第*j*个分量的预测均值和协方差, $\eta_{k-1} > 0$ 表示遗忘因子.

势分布预测可表示为

$$P_{k|k-1}(n) = \sum_{j=0}^n P_{\text{birth}}(n-j) \sum_{l=j}^{\infty} \frac{l!}{j!(l-j)!} \times P_{k-1|k-1}(l) (p_{S,k})^j (1-p_{S,k})^{l-j}. \quad (5)$$

目标状态集RFS的更新可表示为

$$D_{k|k}(\xi) = D_{k|k}^{\text{ND}}(\xi) + \sum_{p \in Z_k} \sum_{W \in p} D_{k|k}^{\text{D}}(\xi, W). \quad (6)$$

势分布更新可表示为

$$P_{k|k}(n) = \begin{cases} \frac{\rho^n G_{k|k-1}^{(n)}(0)}{G_{k|k-1}(\rho)}, & |Z|=0, \\ \sum_{p \in Z} \sum_{W \in p} \psi_{p,W} G_{k|k-1}^{(n)}(0) \frac{(G_1 + G_2)}{\sum_{p \in Z} \sum_{W \in p} \psi_{p,W} l_{p,W}}, & |Z| \neq 0, \end{cases} \quad (7)$$

其中:

$$\begin{cases} G_1 = G_{\text{FA}}(0) \frac{\eta w}{|p|} \frac{\rho^{n-|p|}}{(n-|p|)!} \delta_{n \geq |p|}, \\ G_2 = G_{\text{FA}}^{(|W|)}(0) \frac{\rho^{n-p+1}}{(n-|p|+1)!} \delta_{n \geq |p|-1}. \end{cases} \quad (8)$$

3 星凸随机超曲面多扩展目标伽马高斯混合CPHD滤波器

传统的扩展目标建模一般为椭圆, 条形, 方形等规则形状或是高斯混合模型的拟合, 但这些模型具有难以灵活表征复杂形状等局限性, 因此, 本文采用星凸随机超曲面模型^[8]对扩展目标进行建模, 并且针对该模型的一些缺陷进行了改进.

3.1 算法分析

星凸随机超曲面的量测模型表达式^[8]为

$$z_k = \mathbf{m}_k + s_k r(\mathbf{b}_k, \phi) e(\phi) + \mathbf{v}_k, \quad (9)$$

其中: \mathbf{m}_k 表示目标的质心位置, s_k 为尺度变换因子, 一维径向函数 $r(\mathbf{b}_k, \phi)$ 表示其扩展状态,

$$e(\phi) = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$$

为方向矢量, \mathbf{v}_k 为量测噪声.

由式(8)可得, 尺度变换因子 s_k 反映了径向函数 $r(\mathbf{b}_k, \phi)$ 与目标真实形状的关系, 对目标扩展状态估计影响较大. 文献[8]假设尺度变换因子 s_k 已知, 这种假设不满足实际情况, 特别是对于形状较为复杂的目标适应性较差. 因此对尺度变换因子 s_k 进行自适应估计更符合实际.

将一维径向函数 $r(\mathbf{b}_k, \phi)$ 进行 N 阶傅里叶级数展开, 即

$$r(\mathbf{b}_k, \phi) = \frac{a_k^0}{2} + \sum_{j=1, \dots, N} a_k^j \cos(j\phi) + b_k^j \sin(j\phi), \quad (10)$$

其中 $\mathbf{b}_k = [a_k^0 \ a_k^1 \ b_k^1 \ \dots \ a_k^N \ b_k^N]$, 而 \mathbf{b}_k 和 ϕ 可以表示成如下线性关系:

$$r(\mathbf{b}_k, \phi) = \mathbf{R}(\phi)\mathbf{b}_k, \quad (11)$$

其中:

$$\mathbf{R}(\phi) = [1 \ \cos \phi \ \sin \phi \ \dots \ \cos(N\phi) \ \sin(N\phi)]. \quad (12)$$

由式(10)–(12)可知, 一维径向函数 $r(\mathbf{b}_k, \phi)$ 展开结果可能为负, 即从中心到边界点的距离有可能是负数, 显然不符合基本物理定律. 因此对 $r(\mathbf{b}_k, \phi)$ 进行必要的约束对提高扩展状态估计精度有着重要作用.

3.2 关键步骤

3.2.1 自适应估计尺度变换因子 s_k

为了能够更加准确地估计目标扩展状态, 对尺度变换因子 s_k 进行自适应估计, 具体步骤如下:

步骤 1 初始化尺度变换因子 s_k ; 统计经过CPHD更新得到的质心 m_k 与每一个量测值的距离, 将每一个距离与最大距离的比值作为尺度变换因子 s_k 的初始值, 将初始值代入量测方程(9), 求出尺度变换因子 s_k 的均值与协方差.

步骤 2 将尺度变换因子 s_k 的均值与协方差代入无迹卡尔曼滤波器(unscented kalman filter, UKF)中, 求出新的质心 m'_k .

步骤 3 将质心 m'_k 代入量测方程(9), 求出尺度变换因子 s'_k 的均值与协方差.

步骤 4 进行判断. 若尺度变换因子 s_k 和 s'_k 的均值 $|m_{s'_k} - m_{s_k}| \leq 0.1$, 则迭代终止, 转入步骤5; 否则, 对尺度变换因子 s_k 和 s'_k 求均值作为新的尺度变换因子 s_k , 转步骤2.

步骤 5 输出尺度变换因子 s'_k .

3.2.2 约束优化形状边界

为了满足从中心到边界点的距离 $r(\mathbf{b}_k, \phi)$ 必须为正的条件下, 本文添加以下非线性模型的不等式约束:

$$r(\mathbf{b}_k, \phi) > 0, \quad \forall \phi \in [0, 2\pi). \quad (13)$$

文献[10]中提到了两种约束方法, 采样约束和保守约束. 本文采用保守约束方法:

$$\begin{cases} \hat{x}_{k|k}^s = \arg \min_{\hat{x}_{k|k}^s} (x_k^s - \hat{x}_{k|k}^s)W_k(x_k^s - \hat{x}_{k|k}^s)', \\ \text{s.t. } L_k < c_k(s^*), \end{cases} \quad (14)$$

其中: $c_k(x_k^s)$ 表示约束函数, L_k 表示约束下界. 由于文中对向量 x_k^s 进行无迹变换(unscented transform, UT),

所以可以将其简化为

$$\begin{cases} s_k^P = \arg \min_{s^*} (s^* - s_k)W_k(s^* - s_k)', \\ \text{s.t. } L_k < c_k(s^*), \end{cases} \quad (15)$$

约束均值和协方差为

$$\hat{x}_{k|k}^{s,P} = \sum_{i=1}^{2n+1} \alpha^i s_k^{i,P}, \quad (16)$$

$$\begin{aligned} P_{k|k}^{s,P} &= \sum_{i=1}^{2n+1} \alpha^i (s_k^{i,P} - \hat{x}_{k|k}^{s,P})(s_k^{i,P} - \hat{x}_{k|k}^{s,P})' = \\ &P_{k|k}^s + \lambda(\hat{s}_k^s - \hat{x}_{k|k}^{s,P})(\hat{s}_k^s - \hat{x}_{k|k}^{s,P})', \end{aligned} \quad (17)$$

其中 $0 \leq \lambda \leq 1$, 在仿真中一般取 λ 为0.5.

3.3 算法流程

星凸随机超曲面伽马高斯混合CPHD中扩展目标的状态可以定义为 $\xi_k \triangleq \{\gamma_k, x_k\}$, 其中: γ_k 表示量测率, x_k 表示质心运动状态参数.

预测过程与文献[7]中的预测过程相同.

更新过程可表示为

$$D_{k|k}(\xi_k) = D_{k|k}^{\text{ND}}(\xi_k) + D_{k|k}^{\text{D}}(\xi_k, W), \quad (18)$$

其中 $D_{k|k}^{\text{ND}}(\xi_k)$ 为漏检的概率密度函数;

$$\begin{aligned} D_{k|k}^{\text{D}}(\xi, W) &= \sum_{p \in Z_k} \sum_{W \in p} w_{k|k}^{(j),p,W} G(\gamma; \alpha_{k|k}^{(j),W}, \beta_{k|k}^{(j),W}) \times \\ &N(\xi; \mathbf{m}_{k|k}^{(j),W}, \mathbf{P}_{k|k}^{(j),W}), \end{aligned} \quad (19)$$

式(19)中第1部分可表示为

$$\begin{cases} w_{k|k}^{(j),p,W} = \frac{\bar{w}_{k|k-1}^{(j)} P_D^{(j)} \sigma_{p,W} \frac{\mathcal{L}_k^{(j),W}}{\mathcal{L}_{\text{FA}}^W}}{\sum_{p \in Z_k} \sum_{W \in p} \Psi_{p,W} l_{p,W}}, \\ \mathcal{L}_{\text{FA}}^W = \prod_{z \in W} p_{\text{FA}}(z), \\ \mathcal{L}_k^{(j),\gamma} = \frac{\Gamma(\alpha_{k|k}^{(j),W})(\beta_{k|k}^{(j),W})^{\alpha_{k|k}^{(j),W}}}{\Gamma(\alpha_{k|k}^{(j),W})(\beta_{k|k}^{(j),W})^{\alpha_{k|k}^{(j),W}}}, \\ \mathcal{L}_k^{(j),x} = \prod_{z \in W} N(0; \hat{z}_{nz}^{(j),W}, S_{nz}^{(j),W}); \end{cases} \quad (20)$$

式(19)中第2部分伽马分布参数可表示为

$$\begin{cases} \alpha_{k|k}^{(j),W} = \alpha_{k|k-1}^{(j)} + |W|, \\ \beta_{k|k}^{(j),W} = \beta_{k|k-1}^{(j)} + 1; \end{cases} \quad (21)$$

式(19)中第3部分正态分布参数可表示为

$$\begin{cases} \varepsilon_{k|k-1}^{(j),W} = z_k^{(j)} - (H_k \otimes I_d) \mathbf{m}_{k|k-1}^{(j)}, \\ K_{k|k-1}^{(j),W} = P_{k|k-1}^{(j)} H_k^T (S_{k|k-1}^{(j),W})^{-1}, \\ S_{k|k-1}^{(j),W} = H_k P_{k|k-1}^{(j)} H_k^T + \frac{1}{|W|}, \\ \mathbf{m}_{k|k}^{(j),W} = \mathbf{m}_{k|k-1}^{(j)} + (K_{k|k-1}^{(j),W} \otimes I_d) \varepsilon_{k|k-1}^{(j),W}, \\ \mathbf{P}_{k|k}^{(j),W} = \mathbf{P}_{k|k-1}^{(j)} - K_{k|k-1}^{(j),W} S_{k|k-1}^{(j),W} (S_{k|k-1}^{(j),W})^T, \end{cases} \quad (22)$$

上式中 \otimes 表示克罗内克积.

在星凸模型中, 将量测源代入量测方程中, 得

$$\mathbf{z}_k^{(j)} = s_k^{(j)} r(b_k, \phi_k^{(j)}) \mathbf{e}(\phi_k^{(j)}) + c_k^{(j)} + \mathbf{v}_k^{(j)}, \quad (23)$$

其中 $\phi_k^{(j)} \approx \angle(\mathbf{z}_k^{(j)} - c_k^{(j)}, \mathbf{e}_x)$, 为了减少 $\phi_k^{(j)}$ 对 x_k 的影响, 对上式进行变换, 得到伪量测方程

$$0 = h^*(x_k, \mathbf{v}_k^{(j)}, s_k^{(j)}, \mathbf{z}_k^{(j)}) = (s_k^{(j)})^2 \|\mathbf{R}(\phi_k^{(j)}) b_k\|^2 + 2s_k^{(j)} \mathbf{R}(\phi_k^{(j)}) b_k \times \mathbf{e}^T(\phi_k^{(j)}) \mathbf{v}_k^{(j)} + \|\mathbf{v}_k^{(j)}\|^2 - \|\mathbf{z}_k^{(j)} - c_k^{(j)}\|^2, \quad (24)$$

上式中的函数 h^* 建立了状态 x_k , 尺度变换因子 $s_k^{(j)}$, 量测 $\mathbf{z}_k^{(j)}$ 和量测噪声 $\mathbf{v}_k^{(j)}$ 之间的关系. 将更新得到的目标状态 x_k 代入形状参数矩阵 ζ_k , 并将尺度变换因子 $s_k^{(j)}$ 和量测噪声 \mathbf{v}_k 增广到形状参数矩阵 ζ_k 中, 得到 $\zeta_k^a = [\zeta_k \ s_k^{(j)} \ \mathbf{v}_k^T]$, 维数为 L . 则该向量的均值和协方差矩阵为 $\mu_k^a = [\mu_k \ \mu_s \ \mathbf{0}_2]$, $\mathbf{C}_k^a = \text{blkdiag}\{\mathbf{C}_k, \sigma_s, \mathbf{R}_k\}$ (blkdiag 函数用于生成指定对角元素矩阵, 其参数可为矩阵或者向量). 由于量测模型为非线性, 因此本文对向量 μ_k^a 进行 UT 变换, 则 χ_i 为变换后第 i 个 Sigma 点. 则有

$$\left\{ \begin{array}{l} z_i = h^*(\chi_i), \\ \hat{z}_{\text{nz}} = \sum_{i=0}^{2L+1} W_m^{(i)} z_i, \\ \mathbf{S}_{\text{nz}} = \sum_{i=0}^{2L+1} W_c^{(i)} (z_i - \hat{z}_{\text{nz}})(z_i - \hat{z}_{\text{nz}})^T, \\ \mathbf{C}_{\text{zx}} = \sum_{i=0}^{2L+1} W_c^{(i)} (\chi_i - m_k^a)(z_i - \hat{z}_{\text{nz}})^T, \\ \mathbf{K} = \mathbf{C}_{\text{zx}} (\mathbf{S}_{\text{nz}})^{-1}, \\ \mu_k^a = \mu_k^a + \mathbf{K} (0 - \hat{z}_{\text{nz}}), \\ \mathbf{C}_k^a = \mathbf{C}_k^a - \mathbf{K} \mathbf{S}_{\text{nz}} \mathbf{K}^T, \\ \mu_{k|k}^{(j)} = \mu_k^a(1 : \text{length}(\zeta_k)), \\ \mathbf{C}_{k|k}^{(j)} = \mathbf{C}_k^a(1 : \text{length}(\zeta_k)), \end{array} \right. \quad (25)$$

状态集的势分布更新参考文献 [7].

本文所提算法与文献 [7] 的椭圆随机超曲面伽马高斯混合 CPHD (ERHM-GGM-CPHD) 算法相比, 由于 ERHM-GGM-CPHD 将目标的形状参数增广到状态矩阵中, 只使用一次 UKF 滤波就可估计出目标的运动状态和形状参数, 但是当两个相邻时刻目标的位置距离很远时, 会出现无法准确估计出目标的运动状态和形状参数的情况. 所以本文算法并未将目标的形状参数增广到状态矩阵中, 而是使用 CPHD 滤波更新出目标的状态, 然后将更新得到的质心和预测的形状参数再进行 UKF 滤波更新, 从而估计出目标的形状参数.

4 仿真实验与分析

为了验证本文所提算法的有效性和可行性, 本文进行两个实验仿真. 仿真 1 对比星凸形状自适应估计算法和非自适应算法的跟踪性能, 同时对比星凸形状

估计中约束优化和未约束优化时算法的估计性能, 从而验证本文所提的自适应算法相比较非自适应算法能够更好的估计出目标扩展状态并且约束优化的方法可确保算法形状估计的准确性和稳定性; 仿真 2 对比本文所提滤波算法 (SRHM-GGM-CPHD) 与 ERHM-GGM-CPHD [5] 和新椭圆随机超曲面伽马高斯混合 CPHD 算法 (NERHM-GGM-CPHD) 性能, 从而验证所提算法相比较椭圆随机超曲面算法能够较好的估计出目标形状的同时, 对目标的质心位置估计以及目标数估计均有所提升. 其中 NERHM-GGM-CPHD 是在文献 [7] 准确的基础上使用本文算法流程, 即先使用 CPHD 滤波更新得到目标的运动状态, 然后再使用 UKF 滤波更新得到目标的形状参数.

4.1 仿真实验 1

在本实验中, 观测区域为 $x \in [-140 \text{ m}, 140 \text{ m}]$, $y \in [-140 \text{ m}, 140 \text{ m}]$, 整个过程持续 50 s. 目标形状大小为长半轴 $a = 1.5 \text{ m}$, 短半轴 $b = 1 \text{ m}$. 目标产生量测的泊松率均为 $\lambda = 20$, 杂波泊松率 $N_{\text{FA}} = 20$, 新生目标数 $J_b = 3$, 权重 $w_{b,k}^{(j)} = 0.1$, 目标存活概率 $p_s = 0.99$, 检测概率 $P_D = 0.99$. 本文所提算法采用 11 阶傅里叶级数展开对目标的外形进行描述.

图 1 中, 蓝色, 红色虚线为两种算法得到的扩展目标形状, 其中非自适应估计算法中设置尺度变换因子为经验值 $s_k \sim u(0.9, 0.08)$. 可以看出本文方法的估计结果更接近于目标的真实形状.




图 1 自适应方法目标形状估计局部放大图

Fig. 1 Local amplification figure of the target shape estimation with adaptive method

图 2 给出了约束对比下某个目标一次仿真估计中目标扩展形状估计的局部放大图, 图 3 是取出图 2 中的第二个时刻的形状估计曲线并将其转换到一维坐标中, 横轴为角度 ($0 \sim 2\pi$), 纵轴为边界到中心点的距离. 从图 2 可看出在未加约束的情况下, 形状估计出现了边界到中心距离为负的情况, 将扩展目标的形状转换到一维曲线上后, 即从图 3 可以看出, 纵轴出现了小于零的值, 这是不符合基本物理定律的情况, 但是对它的形状进行约束后, 可使形状变为正常, 在一维曲

线上可看出所有边界到中心的距离都为正. 由于本文所提算法与对比算法的区别主要体现在形状估计中加入了缩放因子的自适应以及对形状进行了约束优化, 其目的是提高目标扩展状态的估计精度, 增强估计的稳定性, 对于目标的质心位置以及目标数目更新结果并无影响, 因此两种算法的OSPA距离和目标数估计结果一致.

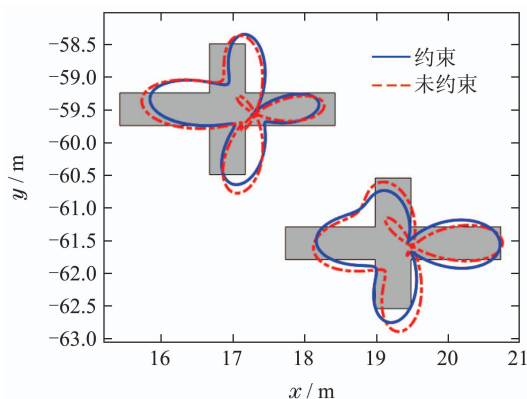


图2 约束优化方法目标形状估计局部放大图

Fig. 2 Local amplification figure of the target shape estimation with constrained optimization method




图3 约束优化对比形状估计的一维曲线

Fig. 3 One-dimensional figure of the shape estimation using constrained optimization method

算法运行时间上, 100次蒙特卡洛实验所提算法与对比算法时间比约为1.002: 1, 运算效率基本一致. 这是由于所提算法相比对比算法只是增加了对缩放因子的自适应估计和形状约束, 而这些过程自身计算复杂度较低, 因而对计算效率并无太大影响.

4.2 仿真实验2

在本实验中, 观测区域为 $x \in [-140 \text{ m}, 140 \text{ m}]$, $y \in [-140 \text{ m}, 140 \text{ m}]$, 整个过程持续50 s. 目标1与目标2在21 s时刻交叉, 真实目标的椭圆扩展形状的长半轴 $a = 2 \text{ m}$, 短半轴 $a = 1 \text{ m}$. 目标产生量测的泊松率均为 $\lambda = 20$, 杂波泊松率 $N_{\text{FA}} = 10$, 新生目标数 $J_b = 4$, 权重 $w_{b,k}^{(j)} = 0.1$, 目标存活概率 $p_s = 0.99$, 检测概率 $P_D = 0.99$.

目标1和目标2在第21时刻交叉时, 3种方法都不

能区分, 这是因为它们都使用了基于距离划分的量测划分方法. 在交叉时, 距离划分算法会将非常接近的目标产生的量测划分到一个集合中, 认为集合中的量测是由一个目标产生的. 从图4中可以看出本文提出的算法比ERHM-GGM-CPHD滤波器在质心位置估计更优, NERHM-GGM-CPHD算法对于质心位置的估计方面效果达到了与SRHM-GGM-CPHD一样的效果. 本文算法先利用CPHD对目标质心状态进行更新, 然后将更新后的质心位置代入星凸量测方程(21)中进行目标质心和形状估计, 与传统利用预测质心位置代入量测方程进行质心和形状估计的算法相比, 由于CPHD更新后的质心位置比预测的质心位置更加准确, 则当进行量测更新时, 量测方程中的参数得到更准确的估计, 因此相比传统估计算法质心估计性能得到大幅度提升. 图4中在22 s时刻和32 s时刻出现小尖峰是因为在目标新生的第2个时刻会出现目标漏跟的现象, 总体上, 对目标的质心位置和形状的估计精度要优于ERHM-GGM-CPHD算法. 算法运行时间上100次蒙特卡洛实验SRHM-GGM-CPHD、ERHM-GGM-CPHD和NERHM-GGM-CPHD时间比约为1.0025: 1.0001: 1. 由于SRHM-GGM-CPHD算法和NERHM-GGM-CPHD算法将目标运动状态和扩展状态分开估计, 一定程度上降低了算法计算量. 同时由于星凸随机超曲面算法相比较椭圆随机超曲面算法在目标扩展状态描述上更为复杂, 因而计算时间有所增加, 但幅度略小, 影响不大.

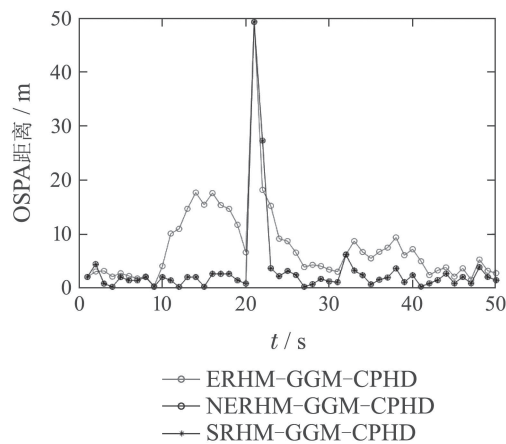


图4 OSPA距离对比

Fig. 4 The comparison of OSPA distance

5 结论

针对扩展目标联合估计运动状态和目标外形的问题, 本文提出了一种基于星凸随机超曲面的扩展目标伽马高斯混合CPHD滤波器. 首先通过CPHD滤波更新出目标的状态, 然后采用UKF对更新得到的质心和预测得到的形状参数进行滤波更新, 从而估计出目标的形状参数, 同时采用了自适应估计和约束优化的方法来提高目标形状的估计精度. 仿真结果表明, 所提

算法在星凸随机超曲面模型下目标跟踪效果良好. 算法对星凸形状的改进优化, 使得算法更加具有实际意义. 下一步将对新生目标漏跟问题进行深入研究.

参考文献:

- [1] HU Q, JI H B, ZHANG Y Q. Tracking of maneuvering non-ellipsoidal extended target with varying number of sub-objects. *Mechanical Systems and Signal Processing*, 2018, 99(1): 262 – 284.
- [2] LAN J, LI X R. Tracking of extended object or target group using random matrix: New model and approach. *IEEE Transactions on Aerospace and Electronic Systems*, 2016, 52(6): 2973 – 2989.
- [3] BEARD M, REUTER S, GRANSTRÖM K, et al. Multiple extended target tracking with labeled random finite sets. *IEEE Transactions on Signal Processing*, 2016, 64(7): 1638 – 1653.
- [4] ZEA A, FAION F, BAUM M, et al. Level-set random hypersurface models for tracking nonconvex extended objects. *IEEE Transactions on Aerospace and Electronic Systems*, 2016, 52(6): 2990 – 3007.
- [5] KOCH J W. Bayesian approach to extended object and cluster tracking using random matrices. *IEEE Transactions on Aerospace and Electronic Systems*, 2008, 44(3): 1042 – 1059.
- [6] GRANSTRÖM K, ORGUMER U. A PHD filter for tracking multiple extended targets using random matrices. *IEEE Transactions on Signal Processing*, 2012, 60(11): 5657 – 5671.
- [7] LI Cuiyun, LIN Jinpeng, JI Hongbing. A Gamma Gaussian mixture CPHD filter for extended target tracking based on ellipse random hypersurface models. *Control and Decision*, 2015, 30(9): 1551 – 1558. (李翠芸, 林锦鹏, 姬红兵. 一种基于椭圆RHM的扩展目标Gamma高斯混合CPHD滤波器. 控制与决策, 2015, 30(9): 1551 – 1558.)
- [8] BAUM M, HANEBECK U D. Shape tracking of extended objects and group targets with star-convex RHM. *Proceedings of the 14th International Conference on Information Fusion*. Chicago: IEEE, 2011: 1 – 8.
- [9] WEI S, FENG X X, KONG Y B. CBMeMber filter for extended object tracking using box particle. *Proceedings of IEEE International Conference on Computer Communication and the Internet*. Wuhan: IEEE, 2016: 454 – 458.
- [10] LAN J, LI X R. State estimation with nonlinear inequality constraints based on unscented transformation. *Proceedings of the 14th International Conference on Information Fusion*. Chicago: IEEE, 2011: 1 – 8.
- [11] LI Cuiyun, WANG Rong, JI Hongbing. Multiple extended-target tracking based on variational Bayesian cardinality-balanced multi-target multi-Bernoulli. *Control Theory & Applications*, 2015, 32(2): 187 – 195. (李翠芸, 王荣, 姬红兵. 基于变分贝叶斯势均衡多目标多伯努利滤波的多扩展目标跟踪算法. 控制理论与应用, 2015, 32(2): 187 – 195.)
- [12] ZHANG Guanghua, LIAN Feng, HAN Chongzhao, WANG Tingting. Convergence analysis for the Gaussian mixture implementation of the CBMeMber filter. *Control Theory & Applications*, 2016, 33(10): 1405 – 1411. (张光华, 连峰, 韩崇昭, 王婷婷. 一种势均衡多目标多伯努利滤波高斯混合实现的收敛性分析. 控制理论与应用, 2016, 33(10): 1405 – 1411.)
- [13] CHEN Hui, DU Jinrui, HAN Chongzhao. An adaptive tracking algorithm for irregular shape extended target. *Control Theory & Applications*, 2018, 35(8): 1111 – 1119. (陈辉, 杜金瑞, 韩崇昭. 一种自适应不规则形状扩展目标跟踪算法. 控制理论与应用, 2018, 35(8): 1111 – 1119.)

作者简介:

李翠芸 博士, 副教授, 硕士生导师, 研究方向为非线性滤波方法、数字图像处理、红外弱小目标检测与跟踪等, E-mail: cyli@xidian.edu.cn;

王精毅 硕士研究生, 研究方向为多目标跟踪方法、随机集理论, E-mail: wangjingyi0101@126.com;

姬红兵 博士, 教授, 博士生导师, 研究方向为多传感器多目标跟踪方法、光电信息处理、微弱信号检测与识别等, E-mail: hbji@xidian.edu.cn;

刘远 硕士研究生, 研究方向为多目标跟踪方法、随机集理论, E-mail: 514466782@qq.com.