

基于随机有限集的多扩展目标跟踪研究进展

单博炜[†], 杨小军

(长安大学 信息工程学院, 西安 710064)

摘 要: 对基于随机有限集的多扩展目标跟踪方法的研究现状和进展进行综述. 首先给出扩展目标的数学模型; 然后给出扩展目标形状估计的 3 种方法: 随机矩阵法, 随机超平面法和高斯过程法; 接着给出多扩展目标的随机有限集滤波器的算法及优缺点; 最后介绍多扩展目标跟踪的主要应用, 并对其未来的发展方向做进一步展望.

关键词: 扩展目标; 随机有限集; 随机矩阵

中图分类号: TP273 **文献标志码:** A

Development of multiple extended object tracking based on random finite set

SHAN Bo-wei[†], YANG Xiao-jun

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

Abstract: An elaborated overview of current research and development in multiple extended object tracking based on the random finite set method is provided. A clear definition and mathematic model of the extended object is given. Then, three shape estimation methods of the extend object including the random matrix, random hypersurface and gaussian process are provided. Then, the algorithms of the random finite set filter of the multiple extended object are given. Finally, the advantage and disadvantage of the tracking algorithm are presented, and current applications and further research prospects are also introduced in the conclusion.

Keywords: extended object; random finite set; random matrix

0 引 言

目标跟踪问题是信息融合研究的核心问题之一, 广泛存在于航空航天、电子信息、控制工程及机器人等科学、技术领域^[1]. 多目标跟踪(MTT)需要使用传感器的观测数据持续地对多个动态目标的状态进行估计. 传统的 MTT 方法在跟踪多个目标时, 需要进行数据关联, 并且只能处理目标数目固定的情况. 近年来提出的随机有限集(RFS)^[2]方法使用随机集对多目标状态和观测进行建模, 不需要进行数据关联, 并且可以处理目标数目发生变化的各种复杂情况(新生、死亡、合并和衍生等). 随着传感器分辨率的提高, 观测目标占据传感器单个分辨单元的“小目标”假设不再适用, 需要对占据传感器多个分辨单元的扩展目标进行跟踪. 解决扩展目标跟踪问题既要估计出目标的动力学参数, 也要估计出目标的轮廓. 本文的目标包括 3 个方面:

- 1) 对扩展目标跟踪问题的基本概念、模型和算法进行介绍;
- 2) 对最近十几年来基于 RFS 方法的多扩展目标跟踪问题的发展进行总结;
- 3) 对扩展目标在民用及国防领域的应用进行总结, 并指出其未来发展方向.

1 多扩展目标定义与模型

本节给出扩展目标的定义、形状模型、传感器观测个数和目标动力学模型. 扩展目标是指占据传感器多个分辨单元或有多个反射回波的目标.

1.1 扩展目标的形状模型

对于扩展目标, 人们无法用一个无大小的点进行建模, 而必须考虑其空间的几何形状. 依据模型的复杂程度, 可以将扩展目标的形状模型分为如下 3 类:

- 1) 一维形状. 使用一个不考虑粗细, 仅考虑长度

收稿日期: 2016-09-27; 修回日期: 2016-12-22.

基金项目: 国家自然科学基金项目(61473047); 陕西省科学技术研究发展计划项目(2015JM6356); 大学生创新创业训练项目(201610710143); 中央高校基本科研业务费专项资金项目(310824162021).

作者简介: 单博炜(1978—), 男, 讲师, 从事信息融合、目标跟踪的研究; 杨小军(1971—), 男, 教授, 从事多源信息融合、统计信号处理等研究.

[†]通讯作者. E-mail: bwshan@chd.edu.cn

的一维棒状形状对扩展目标建模是最为简化的形状模型. 文献[3-4]建立了一维棒状形状的扩展目标模型.

2) 二维规则形状. 使用一个规则的几何形状, 例如矩形、圆形、椭圆等进行建模^[5]. 该方法比一维模型更为精确, 然而模型也更为复杂. 文献[5]使用矩形对汽车进行了建模.

3) 二维任意形状. 由任意形状模型可以得到扩展目标最为精确的形状信息, 具有最大的通用性, 然而该方法也是最复杂的. 文献[6]使用包含多个参数的曲线对目标形状进行了建模, 文献[7]使用多个椭圆的组合对目标形状进行了建模.

1.2 扩展目标的观测个数模型

因为每个目标可能产生多个观测, 因此需要使用一个概率模型对每个目标产生的观测数目进行建模. 当前文献中主要提出了如下两类观测模型:

1) 泊松模型 (Poisson model). 文献[3-4]指出, 观测数目服从泊松分布, 其中泊松率 γ 是目标状态的函数, 即将扩展目标观测建模为一个泊松点过程. 当泊松率未知时, 由于泊松分布的共轭先验分布为伽马分布, 可以使用贝叶斯迭代的方法估计出多个扩展目标的每一个泊松率.

2) 多伯努利模型 (multi-bernouli model). 文献[8]指出, 观测数目服从多伯努利分布, 即扩展目标含有 L 个反射点, 这些反射点相互独立, 且第 l 个反射点被观测到的概率为 p_D^l . 每个反射点的观测过程可以被描述为一个伯努利 RFS^[5], 每个扩展目标的观测可以被描述为一个多伯努利 RFS^[5]. 如果所有反射点的观测概率都相等, 即 $\forall l, p_D^l = p_D$, 则观测数目服从参数为 L 和 p_D 的二项分布; 如果 L 已知, 则未知参数 p_D 的共轭先验分布为贝塔分布.

1.3 扩展目标的动力学模型

目标的动力学模型描述了目标状态如何随时间演化, 目标状态包括位置、速度、加速度和转弯率等. 文献[9]给出了点目标的动力学模型. 扩展目标动力学可以完全参照点目标动力学模型进行描述, 当有多个扩展目标时, 假设目标之间互相独立演化.

2 多扩展目标形状估计方法

本节介绍 3 种估计扩展目标形状的方法, 即随机矩阵 (random matrix) 方法、随机超平面 (random hypersurface) 方法和高斯过程 (gaussian processing) 方法.

2.1 随机矩阵方法

随机矩阵模型假定目标的形状可以用一个椭圆近似, 观测按照高斯分布围绕在目标几何中心的周围. 这种假设尽管看起来很简化, 但在很多场景中 (例如对行人进行跟踪^[10]) 很实用. 文献[11]最早提出的随机矩阵方法中将扩展目标状态建模为一个动力学状态向量 \mathbf{x}_k (包含位置、速度信息) 和一个形状矩阵 X_k 的组合. X_k 是一个对称正定的 $d \times d$ 矩阵, 用以描述目标的大小、形状和方向信息, 其中 d 是目标状态的维数, X_k 表示具有大小、形状和方向的椭球. 假定观测数目为 n_k , 观测集合 $\mathbf{Z}_k = \{\mathbf{z}_k^j\}_{j=1}^{n_k}$, 则观测集合的似然函数为

$$p(\mathbf{Z}_k | n_k, \mathbf{x}_k, X_k) = \prod_{j=1}^{n_k} p(\mathbf{z}_k^j | \mathbf{x}_k, X_k). \quad (1)$$

设目标生成的观测服从高斯分布, 即

$$p(\mathbf{z}_k^j | \mathbf{x}_k, X_k) = \mathcal{N}(\mathbf{z}_k^j; H\mathbf{x}_k, X_k). \quad (2)$$

其中: $\mathcal{N}(\cdot, \cdot)$ 表示高斯分布, H 是观测模型函数.

目标状态的分布为

$$p(\mathbf{x}_k, X_k | \mathbf{Z}^k) = p(\mathbf{x}_k, X_k | \mathbf{Z}^k) p(X_k, \mathbf{Z}^k) = \mathcal{N}(\mathbf{x}_k; m_{k|k}, P_{k|k} \otimes X_k) \times \mathcal{IW}(X_k; v_{k|k}, V_{k|k}). \quad (3)$$

其中: 形状矩阵是逆 Wishart 分布 $\mathcal{IW}(\cdot, \cdot)$, 动力学状态是高斯分布; $m_{k|k}$ 和 $P_{k|k} \otimes X_k$ 分别为高斯分布的平均值和协方差, \otimes 表示 Kronecker 乘积; $v_{k|k}$ 是逆 Wishart 自由度, $V_{k|k}$ 是逆 Wishart 参数矩阵.

文献[11]最早使用随机矩阵方法对扩展目标的动力学状态和物理扩展进行估计. 文献[12]将随机矩阵框架应用于扩展目标的 PHD 框架中, 推导出了高斯逆 Wishart PHD 滤波器, 随后又将其应用于 CPHD 滤波器, 提出伽马高斯逆 Wishart PHD 滤波器^[13]. 文献[14]在随机矩阵框架下使用变分贝叶斯方法给出了一个新的观测更新算法来跟踪扩展目标. 文献[15]使用随机矩阵方法研究了扩展目标扭曲变形时的跟踪算法. 文献[16]在随机矩阵框架下提出了一个扩展目标的高斯逆 Wishart 伯努利滤波器来跟踪超宽带传感器网络中的扩展目标. 文献[16]还使用随机矩阵方法对非椭球体扩展目标的机动运动进行了跟踪. 文献[17]等基于随机矩阵, 建立了跟踪多扩展目标的滤波器.

2.2 随机超平面方法

文献[18]提出了一种对扩展目标形状进行估计的方法, 即随机超平面模型 (RHM). RHM 的特点是: 使用一组参数表示形状轮廓; 使用高斯分布表示状态动力学和形状参数; 使用非线性 Kalman 滤波器进

行观测更新. 与随机矩阵模型的区别在于, RHM不再将扩展目标形状局限于椭圆, 而是使用更一般的星凸(star convex)形状来近似目标轮廓.

RHM首先定义半径函数 $r(\mathbf{p}_k, \phi)$, 其中 \mathbf{p}_k 是形状参数向量, ϕ 是相对于目标几何中心 d_k 的轮廓点的角度; 然后基于半径函数定义一个适当的参数化的星凸形状. 形状参数向量 \mathbf{p}_k 可以通过傅里叶级数展开定义, 即

$$r(\mathbf{p}_k, \phi) = R(\phi) \cdot \mathbf{p}_k. \quad (4)$$

其中

$$R(\phi) = \left[\frac{1}{2}, \cos \phi, \sin \phi, \dots, \cos(N_F \phi), \sin(N_F \phi) \right], \quad (5)$$

$$\mathbf{p}_k = [a_k^{(0)}, a_k^{(1)}, b_k^{(1)}, \dots, a_k^{(N_F)}, b_k^{(N_F)}]^T. \quad (6)$$

状态向量 \mathbf{x}_k 包含了形状参数 \mathbf{p}_k 、位置 d_k 和动力学参数 c_k , 有

$$\mathbf{x}_k = [\mathbf{p}_k^T, d_k^T, c_k^T]^T.$$

RHM的观测方程写成极坐标的形式为

$$\mathbf{z}_k = s_k \cdot r_k(\mathbf{p}_k, \phi_k) + d_k + v_k. \quad (7)$$

其中: $s_k \in [0, 1]$ 指定了观测源与中心的相对距离, ϕ 给出了观测向量的角度, v_k 是观测噪声.

假设状态的先验概率密度函数服从高斯分布, 有

$$p(\mathbf{x}) = \mathcal{N}(\mathbf{x}; m, P), \quad (8)$$

使用Kalman滤波器, 可以得到均值 m^+ 和协方差矩阵 P^+ 的后验密度

$$m^+ = m + \text{Cov}[z, \mathbf{x}]P^{-1}(z - E[z]), \quad (9)$$

$$P^+ = P + \text{Cov}[\mathbf{x}, z]\text{Cov}[z, z]^{-1}\text{Cov}[z, \mathbf{x}]. \quad (10)$$

文献[18]给出了圆形和椭圆形状的RHM; 文献[19]给出了对称目标的RHM; 文献[20]对于星凸形状的RHM给出了用于非线性滤波器更新步的一个闭式的似然函数.

2.3 高斯过程方法

文献[21]给出了一种基于高斯过程(GP)的方法. 该方法通过一个高斯过程自动学习目标形状, 从而能够对任意形状的目标给出其轮廓的解析表达式. 一个高斯过程

$$f(\underline{u}) \sim \mathcal{GP}(x(\underline{u}, k(\underline{u}, \underline{u}')))) \quad (11)$$

是一个随机过程. 其中: $x(\underline{u})$ 是均值函数, $k(\underline{u}, \underline{u}')$ 是协方差函数, $f(\underline{u})$ 服从多变量高斯分布. 这里取极坐标的角度 $\theta = u$, 半径 $r = x$ 来描述扩展目标轮廓.

为了同时估计目标的运动和形状, 需要使用GP

的状态空间模型来扩展目标的动力学模型, 扩展后的状态向量为

$$\underline{x}_t = [\underline{x}_t^k \quad (\underline{x}_t^f)^T]^T, \quad (12)$$

其中

$$\underline{x}_t^k = [x_t^c \quad y_t^c \quad v_t]^T. \quad (13)$$

运动状态 \underline{x}_t^k 中包含目标中心位置 (x_t^c, y_t^c) 和速度 v_t , GP的均值函数 \underline{x}_t^f 表示极坐标的半径长度.

GP的协方差函数采用如下对称周期函数:

$$k(\theta, \theta') = \sigma_f^2 e^{-\frac{2 \sin^2 \left(\frac{l(\theta - \theta')}{2} \right)}{l^2}} + \sigma_r^2. \quad (14)$$

其中: l 是一个长度标量, σ_f 是信号振幅的先验方差, σ_r 是高斯先验的方差.

采用EKF进行迭代的预测和更新, 从而可以计算出式(12)、(13)中的状态向量.

文献[21]将基于高斯过程的扩展目标跟踪算法与随机矩阵、随机超平面算法进行了对比实验, 发现该算法可以对多种复杂形状的轮廓给出更为精确的估计结果.

上述3种方法中, 随机矩阵方法仅使用椭圆对扩展目标形状进行近似, 虽然这一方法较为简化, 但在很多实际场景中都能够满足要求, 并且易于实现, 因此被众多研究者采用. 随机超平面方法不再将目标形状局限在椭圆, 能够描述更为一般的星凸形状, 所产生的代价是需要更大的计算量. 高斯过程方法能够对任意形状的目标给出轮廓估计, 从而对扩展目标形状跟踪达到最高精度, 缺点在于实现起来较为困难且计算量最大.

3 随机有限集滤波器算法设计

对多个目标进行跟踪, 主要存在以下难点:

- 1) 目标数目未知, 且其随时间变化;
- 2) 观测可能丢失, 例如在每个时间步, 并非所有的目标都产生观测;
- 3) 存在杂波观测, 即观测并非由目标产生;
- 4) 观测源未知, 即每个观测和产生该观测的目标难以做到一一对应, 需要进行数据关联.

RFS算法将目标集合和观测集合都建模为RFS.

设 $\mathbf{x}_k^{(i)}$ 表示 k 时刻第 i 个目标的状态, $N_{x,k}$ 表示 k 时刻的目标数目. k 时刻所有目标组成的集合 X_k 为

$$X_k = \{\mathbf{x}_k^{(i)}\}_{i=1}^{N_{x,k}}. \quad (15)$$

传感器扫描后得到 $N_{z,k}$ 个观测 $\mathbf{z}_k^{(j)}$, 则 k 时刻所有观测组成的集合 Z_k 为

$$Z_k = \{\mathbf{z}_k^{(j)}\}_{j=1}^{N_{z,k}}. \quad (16)$$

设 \mathbf{Z}_k 为从1时刻到 k 时刻的所有观测的集合,有

$$\mathbf{Z}^k = \{\mathbf{Z}_i\}_{i=1}^k. \quad (17)$$

RFS跟踪的目标就是对于给定的 \mathbf{Z}^k 估计出 X_k 及其个数. 为了实现这一目标,需要进行预测和更新.

1) 预测. 使用目标的运动模型进行预测,同时考虑目标的新生、死亡、合并、衍生等情况.

2) 更新(Update). 基于贝叶斯原理,使用目标的观测对目标的状态进行更新,同时考虑虚警、漏检、噪声等情况. 观测模型 $h(\cdot)$ 与扩展目标的形状相关,扩展目标的形状模型如1.1节所指出的,既有很简单的模型也有较为复杂的模型,具体选择哪种是计算复杂度与估计精确性之间权衡的结果.

对于多个目标的RFS跟踪,可以构建出贝叶斯迭代过程:根据随机集运动模型,使用随机集转移密度来预测状态的先验概率,然后根据随机集观测模型,使用随机集似然函数更新出状态的后验概率.对上述过程迭代计算,就可以估计出目标的状态.

对于扩展目标,需要将多个观测和目标进行关联,因此需要定义观测集的伪似然函数

$$L_{\mathbf{Z}_k}(\mathbf{x}) = 1 - (1 - e^{-\gamma(\mathbf{x})})p_D(\mathbf{x}) + e^{-\gamma(\mathbf{x})}p_D(\mathbf{x}) \times \sum_{p \subset \mathbf{Z}_k} w_p \sum_{W \in p} \frac{\gamma(\mathbf{x})^{|W|}}{d_W} \cdot \prod_{z \in W} \frac{\phi_{\mathbf{Z}_k}(\mathbf{x})}{\lambda_k c_k(\mathbf{Z}_k)}. \quad (18)$$

其中: $1 - (1 - e^{-\gamma(\mathbf{x})})p_D(\mathbf{x})$ 部分处理未检测到的目标,其余部分处理检测到的目标;观测的期望数目为 $\gamma(\mathbf{x})$; λ_k 是杂波观测的平均数, $c_k(\mathbf{Z}_k)$ 是杂波观测的空间分布;标记 $p \subset \mathbf{Z}_k$ 表示将观测集合 \mathbf{Z}_k 进行 p 个划分,得到非空的单元 W ; w_p 和 d_W 是应用于划分 p 和单元 W 上的非负的系数; $\phi_{\mathbf{Z}_k}(\mathbf{x})$ 是单个目标生成的观测的似然函数,一般选用高斯函数.

4 多扩展目标跟踪的RFS方法

4.1 观测划分

由于每个扩展目标都会产生多个观测,为了解决数据关联问题,必须进行如下两个步骤:

- 1) 将观测集合划分为非空的子集,称为单元;
- 2) 将每一个单元关联到目标.

每一个划分产生的单元包含了来自同一目标的所有观测,因此,为了完成数据关联,需要考虑所有可能的划分. 对于一个包含 N 个观测元素的集合,可能的划分数是第 N 个 Bell 数,当 N 很大时会导致计算量过大而无法进行.

文献[22]表明,可以使用聚类的方法仅找到划分的子集,而不必考虑所有可能的划分. 这是由于扩展

目标的观测在空间上一般分布在目标的周围,因此在空间上距离较近的观测来自于同一目标的可能性更大. 这样处理将使得更新步骤在计算复杂度上大大降低.

式(18)的计算量极大,因此实际构造滤波器时通常采用一些更为简化的近似方法. 本文将给出这些近似方法的例子.

4.2 基于PHD方法的多扩展目标滤波器

多目标概率密度函数的一阶矩被称为概率假设密度(PHD),通过传递PHD可以使得计算大大简化. PHD是一个定义在目标状态 $\mathbf{x} \in \chi_0$ 上的强度函数 $D_{k|k}(\mathbf{x})$,其最大值对应于目标位置. 给定目标状态空间 χ_0 中的任一区域 S (即 $S \subseteq \chi_0$),积分

$$N_{k|k}^S = \int_S D_{k|k}(\mathbf{x}) d\mathbf{x} \quad (19)$$

是区域 S 中的目标数目.

文献[22]给出了多个扩展目标的GM-PHD滤波器,为了描述扩展目标的观测,建立了观测的伪似然函数,使用观测的伪似然函数来更新PHD强度,该模型被称为扩展目标的高斯混合PHD滤波器(ET-GM-PHD). 文献[12]给出了在随机矩阵(random matrix)扩展目标模型下的多扩展目标PHD滤波器,模型称为高斯逆Wishart-PHD滤波器(GIW-PHD),其中的PHD强度 $D_{k|k}(\cdot)$ 被近似为一个混合形式的高斯逆Wishart分布

$$D_{k|k}(\xi_k) \approx \sum_{j=1}^{J_{k|k}} w_{(j)}^{(k|k)} \mathcal{N}(\mathbf{x}_k; m_{(j)}^{(k|k)}, P_{(j)}^{(k|k)} \otimes X_k) \times \mathcal{IW}(X_k; v_{(j)}^{(k|k)}, V_{(j)}^{(k|k)}). \quad (20)$$

其中: $J_{k|k}$ 是分量的数量, $w_{(j)}^{(k|k)}$ 是第 j 个分量的权重, $m_{(j)}^{(k|k)}$ 和 $P_{(j)}^{(k|k)} \otimes X_k$ 是第 j 个分量的高斯均值和协方差, $v_{(j)}^{(k|k)}$ 和 $V_{(j)}^{(k|k)}$ 是逆Wishart自由度和参数矩阵,标记 $\mathcal{IW}(\cdot, \cdot)$ 表示逆Wishart分布. 模型中扩展目标PHD滤波器的更新方程为

$$D_{k|k}(\xi_k | \mathbf{Z}^k) = L_{\mathbf{Z}_k}(\xi_k) D_{k|k-1}(\xi_k | \mathbf{Z}^{k-1}), \quad (21)$$

其中 $L_{\mathbf{Z}_k}(\cdot)$ 是式(18)定义的观测集的伪似然函数. 文献[5]给出了多模型高斯混合PHD滤波器,模型将汽车和自行车建模为矩形和棒状,并进行了跟踪.

4.3 基于CPHD方法的多扩展目标滤波器

CPHD滤波器除了传递PHD之外,同时传递势分布 $P_{k|k}(n)$. 与PHD滤波器相比,CPHD滤波器对势估计更为精确. 文献[13]给出了Gamma Gaussian inverse Wishart(GGIW)的扩展目标CPHD滤波器实现,模型被称为GGIW-ET-CPHD滤波器. 其中PHD强度 $D_{k|k}(\cdot)$ 被近似为一个混合形式的GGIW分布,

即

$$D_{k|k}(\xi_k) \approx \sum_{j=1}^{J_{k|k}} w_{k|k}^{(j)} \mathcal{GGIW}(\xi_k; \zeta_{k|k}^{(j)}). \quad (22)$$

其中: $J_{k|k}$ 是分量的数量, $w_{k|k}^{(j)}$ 是第 j 个分量的权重, $\zeta_{k|k}^{(j)}$ 是第 j 个分量的密度参数, 标记 $\mathcal{GGIW}(\cdot)$ 表示伽马高斯逆 Wishart 分布.

4.4 基于标签多伯努利方法的多扩展目标滤波器

LMB RFS 是一个带标记的 RFS, 其状态空间为 \mathbf{X} , 离散的标记空间为 \mathbf{L} , 状态服从的分布为

$$\pi(\mathbf{X}) = \Delta(\mathbf{X})w(\mathbf{L}(\mathbf{X})) [p(\cdot)]^{\mathbf{X}}. \quad (23)$$

其中

$$\Delta(\mathbf{X}) = \begin{cases} 1, & |\mathbf{L}(\mathbf{X})| = |\mathbf{X}|; \\ 0, & |\mathbf{L}(\mathbf{X})| \neq |\mathbf{X}|; \end{cases} \quad (24)$$

$$w(\mathbf{L}) = \prod_{i \in \mathbf{L}} (1 - r^{(i)}) \prod_{l \in \mathbf{L}} \frac{1_L(l)r^{(l)}}{1 - r^{(l)}}; \quad (25)$$

$$p(x, l) = p^{(l)}(x). \quad (26)$$

其中: $r^{(l)}$ 和 $p^{(l)}(\cdot)$ 分别是标记 $l \in \mathbf{L}$ 的存在概率和概率密度. LMB 分布通常简记为 $\pi(\mathbf{X}) = (r^{(l)}, p^{(l)})_{l \in \mathbf{L}}$.

文献 [2, 8] 给出多伯努利 (MB) 滤波器来跟踪多目标. 文献 [23] 提出了广义带标签的多伯努利滤波器 (GLMB). 文献 [24] 给出了计算复杂度更低的带标签的多伯努利滤波器 (LMB). 文献 [25] 首先用 GLMB 滤波器跟踪了扩展目标. 文献 [26] 使用 GGIW 分布, 基于 LBM 对多扩展目标进行了跟踪. 文献 [27] 使用高斯混合实现了多扩展目标的多伯努利滤波器.

4.5 方法的优缺点

多扩展目标跟踪的随机有限集方法和传统的 MTT 方法相比, 优点在于: 不需要进行数据关联; 可以处理目标数目发生变化的各种复杂情况 (新生、死亡、合并和衍生等); 结合多种形状估计方法可以对扩展目标的形状进行较为精确的估计; 通过传递势参数和标记参数实现对目标数目进行精确估计. 缺点主要有: 需要对观测集合进行聚类划分, 跟踪的精度和聚类划分算法相关; 算法的计算复杂度较大; 当目标较为接近时跟踪的误差较大等.

5 多扩展目标跟踪的 RFS 方法的应用

多扩展目标跟踪的 RFS 算法已在众多实际场景中得到应用, 按传感器不同可以将应用分为以下 3 类:

1) 在光学传感器上的应用. 文献 [5] 使用激光探测与测量 (LiDAR) 对车辆一类的扩展目标实现跟踪, 算法使用矩形对车辆进行建模, 使用扩展目标的 PHD 滤波器对目标进行跟踪. 文献 [10] 使用摄像机

对行人一类的扩展目标实现跟踪, 使用椭圆对行人建模, 使用 GGIW-PHD 滤波器进行行人的跟踪. 文献 [19] 使用 RGB-D 传感器跟踪了轨道车辆, 使用对称的矩形对轨道车辆建模.

2) 在雷达上的应用. 文献 [27] 使用 X 波段雷达对扩展目标进行了跟踪, 算法使用矩形对船舶建模, 采用扩展目标 PHD 滤波器获得船舶状态信息.

3) 在声呐上的应用. 文献 [28] 使用图像声呐跟踪了扩展目标, 使用图像处理算法进行特征提取和目标分类从而获得目标的观测, 然后使用 PHD 滤波器对非稳态的水下目标进行跟踪.

6 结论与展望

本文对基于 RFS 的多扩展目标跟踪问题进行了系统地概括, 对于当前主要的 RFS 多扩展目标跟踪技术及其各种实现进行了较为全面的总结和梳理.

未来的发展方向主要有:

1) 对算法本身进行改进, 降低势估计的误差和 OSPA 的误差.

2) 引入先进的聚类和数据挖掘算法, 以提高观测集合划分时的精度和计算效率.

3) 为了应对多扩展目标跟踪算法复杂度的提高, 引入 GPU 加速或分布式并行算法来提高计算效率^[29].

4) 在当前大数据和丰富的传感器的背景下, 将多扩展目标滤波器与机器学习方法相结合值得进一步研究. 文献 [30] 将 PMHT 与机器学习中的 EM 算法相结合, 从扩展目标中估计出速度、方向和转向速度. 机器学习中的高斯过程算法被文献 [21] 用来自动学习扩展目标的形状. 当前众多的机器学习方法能够为扩展目标跟踪的发展提供更为丰富的研究课题.

5) 当前研究的扩展目标主要是二维扩展, 如果能够发展出扩展目标的三维扩展模型, 则将能够更加准确和真实地描述目标, 从而获得更多的扩展目标信息.

参考文献 (References)

- [1] Bar-Shalom Y, Li X R, Kirubarajan T. Estimation with applications to tracking and navigation: Theory algorithms and software[M]. Hoboken, NJ: John Wiley & Sons, 2004.
- [2] Mahler R. Statistical multisource-multitarget information fusion[M]. Norwood, MA: Artech House, 2007: 1-48.
- [3] Gilholm K, Salmond D. Spatial distribution model for tracking extended objects[J]. IEE Proceedings — Radar, Sonar and Navigation, 2005, 152(5): 364-371.
- [4] Gilholm K, Godsill S, Maskell S, et al. Poisson models for extended target and group tracking[C]. Proc SPIE 5913.

- San Diego, 2005: 230-241.
- [5] Granstrom K, Reuter S, Meissner D, et al. A multiple model PHD approach to tracking of cars under an assumed rectangular shape[C]. The 17th Conf on Information Fusion. Salamanca: IEEE, 2014: 1-8.
- [6] Baum M, Hanebeck U D. Shape tracking of extended objects and group targets with star-convex RHMs[C]. The 14th Conf on Information Fusion. Chicago: IEEE, 2011: 1-8.
- [7] Lan J, Li X R. Tracking of maneuvering non-ellipsoidal extended object or target group using random matrix[J]. IEEE Trans on Signal Processing, 2014, 62(9): 2450-2463.
- [8] Ristic B, Vo B T, Vo B N, et al. A tutorial on bernoulli filters: Theory, implementation and applications[J]. IEEE Trans on Signal Processing, 2013, 61(13): 3406-3430.
- [9] Li X R, Jilkov V. Survey of maneuvering target tracking — Part I: Dynamic models[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1333-1364.
- [10] Reuter S, Dietmayer K. Pedestrian tracking using random finite sets[C]. The 14th Conf on Information Fusion. Chicago: IEEE, 2011: 1-8.
- [11] Koch J W. Bayesian approach to extended object and cluster tracking using random matrices[J]. IEEE Trans on Aerospace and Electronics Systems, 2008, 44(3): 1042-1059.
- [12] Granstrom K, Orguner U. A PHD filter for tracking multiple extended targets using random matrices[J]. IEEE Trans on Signal Processing, 2012, 60(11): 5657-5671.
- [13] Lundquist C, Granstrom K, Orguner U. An extended target CPHD filter and a Gamma Gaussian inverse Wishart Implementation[J]. IEEE J of Selected Topics in Signal Processing, 2013, 7(3): 472-483.
- [14] Orguner U. A variational measurement update for extended target tracking with random matrices[J]. IEEE Trans on Signal Processing, 2012, 60(7): 3827-3834.
- [15] Lan J, Li X R. Tracking of extended object or target group using random matrix — Part I: New model and approach[C]. The 15th Conf on Information Fusion. Singapore: IEEE, 2012: 2177-2184.
- [16] Eryildirim A, Guldogan M B. A bernoulli filter for extended target tracking using random matrices in an UWB sensor network[J]. IEEE Sensors J, 2016, 16(11): 4362-4373.
- [17] 韩玉兰, 朱洪艳, 韩崇昭. 采用随机矩阵的多扩展目标滤波器[J]. 西安交通大学学报, 2015, 49(7): 98-104. (Han Y L, Zhu H Y, Han C Z. A multi-target filter based on random matrix[J]. J of Xi'an Jiaotong University, 2015, 49(7): 98-104.)
- [18] Baum M, Hanebeck U D. Extended object tracking with random hypersurface models[J]. IEEE Trans on Aerospace and Electronic Systems, 2014, 50(1): 149-159.
- [19] Faion F, Zea A, Baum M, et al. Symmetries in bayesian extended object tracking[J]. ISIF J of Advances in Information Fusion, 2015, 10(1): 13-30.
- [20] Steinbring J, Baum M, Zea A, et al. A closed-form likelihood for particle filters to track extended objects with star-convex RHMs[C]. 2015 IEEE Int Conf on Multisensor Fusion and Integration for Intelligent Systems(MFI). Diego: IEEE, 2015: 25-30.
- [21] Wahlstrom N, Ozkan E. Extended target tracking using Gaussian processes[J]. IEEE Trans on Signal Processing, 2015, 63(16): 4165-4178.
- [22] Granstrom K, Lundquist C, Orguner O. Extended target tracking using a Gaussian-mixture PHD filter[J]. IEEE Trans on Aerospace and Electronic Systems, 2012, 48(4): 3268-3286.
- [23] Vo B N, Vo B T, Phung D. Labeled random finite sets and the Bayes multi-target tracking filter[J]. IEEE Trans on Signal Processing, 2014, 62(24): 6554-6567.
- [24] Reuter S, Vo B T, Vo B N, et al. The labeled multi-bernoulli filter[J]. IEEE Trans on Signal Processing, 2014, 62(12): 3246-3260.
- [25] Beard M, Vo B T, Vo B N. Bayesian multi-target tracking with merged measurements using labelled random finite sets[J]. IEEE Trans on Signal Processing, 2015, 63(6): 1433-1447.
- [26] Beard M, Reuter S, Granstrom K, et al. Multiple extended target tracking with labeled random finite sets[J]. IEEE Trans on Signal Processing, 2016, 64(7): 1638-1653.
- [27] Granstrom K, Natale A, Braca P, et al. PHD extended target tracking using an incoherent X-band radar: Preliminary real-world experimental results[C]. The 17th Conf on Information Fusion. Salamanca: IEEE, 2014: 1-8.
- [28] Krout D W, Kooiman W, Okopal G, et al. Object tracking with imaging sonar[C]. The 15th Conf on Information Fusion. Singapore: IEEE, 2012: 2400-2405.
- [29] Henriksen S, Wills A, Schon T B, et al. Parallel implementation of particle MCMC methods on a GPU[J]. IFAC Proceedings Volumes, 2012, 45(16): 1143-1148.
- [30] Bordonaro S, Willett P, Bar-Shalom Y, et al. Extracting speed, heading and turn-rate measurements from extended objects using the EM algorithm[C]. 2015 IEEE Aerospace Conf. Big Sky, MT: IEEE, 2015: 1-12.

(责任编辑: 曹洪武)