

基于 GIW-PHD 的扩展目标联合跟踪与分类算法

樊鹏飞, 李鸿艳

(空军工程大学信息与导航学院, 陕西西安 710077)

摘要: 在使用估计器对扩展目标进行跟踪时, 算法的精度会受到系统演化模型选择的影响. 针对该问题, 本文提出将扩展目标的形态信息直接作为目标的类别信息, 每一类别确定了目标相关的运动模型, 在多模型 (Multiple Model, MM) 高斯逆威沙特概率假设密度 (Gaussian Inverse Wishart PHD, GIW-PHD) 滤波器的基础上, 实现对扩展目标的联合跟踪与分类. 仿真实验通过比较所提算法与 GIW-PHD、MM-GIW-PHD 两种滤波方法的性能, 验证了本文所提算法的有效性.

关键词: 扩展目标; 形态信息; 类别信息; 高斯逆威沙特概率假设密度 (GIW-PHD); 联合跟踪与分类

中图分类号: TN953 **文献标识码:** A **文章编号:** 0372-2112 (2018)07-1562-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2018.07.004

Joint Tracking and Classification of Extended Object Based on the GIW-PHD Filter

FAN Peng-fei, LI Hong-yan

(Information and Navigation College, Air Force Engineering University, Xi'an, Shaanxi 710077, China)

Abstract: When using the estimator for the extended object tracking, the algorithm accuracy is affected by the choice of the system evolution model. In this paper, we propose to take the extension information directly as the class-based information of the extended object, where each class determines the relevant motion models. Then we propose a joint tracking and classification algorithm based on the Multiple Model (MM) Gaussian Inverse Wishart Probability Hypothesis Density (GIW-PHD) filter. Simulation results demonstrated the efficiency of the proposed algorithm, compared with the performance of the GIW-PHD and MM-GIW-PHD filtering methods.

Key words: extended objects; extension information; class-based information; Gaussian Inverse Wishart Probability Hypothesis Density (GIW-PHD); joint tracking and classification

1 引言

在现代战场监视系统中, 目标的跟踪与分类问题已经成为两个重要的组成部分, 多年来许多方法被提出来用于解决这两个问题. 联合目标跟踪与分类 (Joint Tracking and Classification, JTC) 自从 1991 年被首次提出讨论后, 受到了越来越多的关注. 事实上, 目标的跟踪器和分类器是相互耦合的, 目标类别信息能够确定更精确的目标运动模型, 提高目标跟踪精度, 反过来目标状态信息也有助于目标分类性能, 两类问题可以放在统一的框架下进行处理^[1,2]. 许多方法已经被提出用以解决目标的联合跟踪与分类问题.

随着观测传感器分辨率的提高, 现代传感器可以

从一个目标获得多个观测点, 这些观测点不仅包含了目标的运动学信息, 同时还提供了目标的形态信息, 目标在这种情况下被称作扩展目标 (Extended Object, EO)^[3]. 近年来, 扩展目标跟踪已有了大量研究成果^[4,5]. 对于扩展目标的联合跟踪与分类问题, 研究却鲜有报道. 兰剑和李晓榕将扩展目标形态信息作为属性信息, 在随机矩阵框架下实现了对椭圆扩展目标的联合跟踪与分类^[6]; 之后他们利用多个椭圆近似拟合非椭圆扩展目标, 建立可以描述类别相关的包含先验信息的系统模型, 实现了对非椭圆扩展目标的联合跟踪与分类^[7]. 文献[8]在贝叶斯风险框架下, 通过最小化目标状态估计与类别决策的贝叶斯风险来解决扩展

目标的联合跟踪与分类问题. 文献[9]建立了基于支持函数和扩展高斯映射的扩展目标模型,用以分别描述平滑扩展目标和非平滑扩展目标,将类别信息加入到支持函数中,改善扩展目标的跟踪与分类性能. 上述的联合跟踪与分类算法是在单目标贝叶斯滤波基础上,针对无杂波、无漏检和单目标的情况. Mahler 利用随机有限集对目标状态集和观测集进行建模,实现了在杂波条件下和关联不确定情况下的最优多目标贝叶斯滤波器^[10]. 概率密度假设 (Probability Hypothesis Density, PHD) 是定义在状态空间上随机有限集的一阶矩,使用 PHD 滤波器近似最优多目标贝叶斯滤波器可以使复杂度得到有效降低^[11]. 之后 Mahler 推导给出了使用 PHD 滤波器跟踪扩展目标的递归式^[12],文献[13]给出了该理论的一种实现方式,即高斯逆 Wishart PHD (Gaussian Inverse Wishart PHD, GIW-PHD) 滤波器,为扩展目标的联合跟踪与分类问题提供了一个新的数学理论框架. 文献[14]利用从远距离分辨率 (High Range Resolution, HRR) 雷达获得的纵向距离像 (Down Range Extend) 作为扩展目标的属性信息,加入到多模高斯混合 PHD 滤波器中,实现了对多扩展目标状态的估计. 该方法主要集中在扩展形态的建模上,忽视了扩展目标“产生多个量测”的特性.

针对上述情况,本文提出了一种基于 GIW-PHD 滤波器的扩展目标联合跟踪与分类算法 (GIW-PHD-JTC),将目标的扩展形态信息直接作为目标的属性信息,仅使用获得的位置量测信息完成对扩展目标的跟踪,推导并给出新的递推表达式. 在此基础上,将多模型方法引入到 GIW-PHD-JTC 算法中,即 MM-GIW-PHD-JTC 算法. 仿真实验给出了本文方法和传统 GIW-PHD 以及其多模型方法的性能对比结果,进一步说明了提出方法的优越性.

2 问题描述及系统建模

本文的目的是将类别信息加入到 GIW-PHD 滤波器当中,在每一时刻通过预测和更新状态集的目标强度 (PHD),即 $D_{k|k-1}(\cdot)$ 和 $D_{klk}(\cdot)$,利用得到的观测集 Σ 估计扩展目标的状态集 Ξ .

2.1 运动模型

在 k 时刻存在 $N_{x,k}$ 个扩展目标,其状态集为 $\Xi_k = \{\xi_k^{(i)}, i=1, \dots, N_{x,k}\}$, $\xi_k^{(i)} = (\mathbf{x}_k^{(i)}, \mathbf{X}_k^{(i)})$,其中扩维状态 $\xi_k^{(i)}$ 包括运动状态 $\mathbf{x}_k^{(i)}$ 和扩展形态 $\mathbf{X}_k^{(i)}$. 假设共有 C 类扩展目标,其类别集为 $\Theta = \{1, 2, \dots, C\}$. 每一类扩展目标有自己的运动模型集 $\{M_1^{c_i}, \dots, M_{r(c_i)}^{c_i}\}$, $r(c_i)$ 为 c_i 类扩展目标的模型集的个数. c_i 类扩展目标的运动学模型被定义为

$$\mathbf{x}_{c_i,k}^{(i)} = (\mathbf{F}_{c_i,k|k-1}^r \otimes \mathbf{I}_d) \mathbf{x}_{c_i,k-1}^{(i)} + \mathbf{w}_{c_i,k}^{r,(i)} \quad (1)$$

式中 d 为物理空间维数, $\mathbf{F}_{c_i,k|k-1}^r$ 为 c_i 类目标一维物理空间上的第 r 个状态转移矩阵模型, $\mathbf{I}_d \in \mathbb{R}^{d \times d}$ 为单位矩阵; $\mathbf{w}_{c_i,k}^{r,(i)}$ 为零均值高斯过程噪声,方差为 $\mathbf{D}_{c_i,k|k-1}^{r,(i)} = \mathbf{Q}_{c_i,k|k-1}^{r,(i)} \otimes \mathbf{X}_{c_i,k}^{(i)}$, $\mathbf{Q}_{c_i,k|k-1}^{r,(i)}$ 为一维物理空间中过程噪声的协方差矩阵, \otimes 为克罗内克积.

2.2 量测模型

传感器获得的观测集为 $\Sigma_k = \{\mathbf{z}_k^{(j)}\}_{j=1}^{N_{z,k}}$, $N_{z,k}$ 为量测的个数. 量测模型被定义为

$$\mathbf{z}_k^{(j)} = (\mathbf{H}_k \otimes \mathbf{I}_d) \mathbf{x}_{c_i,k}^{(i)} + \mathbf{e}_{c_i,k}^{(j)} \quad (2)$$

式中 \mathbf{H}_k 为量测矩阵, $\mathbf{e}_{c_i,k}^{(j)}$ 为均值为零、方差为 $\mathbf{X}_{c_i,k}^{(j)}$ 的高斯白噪声.

2.3 形态模型

随机矩阵 \mathbf{X}_k 是 $d \times d$ 维对称正定矩阵,它可以表征扩展目标的形态特征,包括大小、形状和朝向. 扩展形态演化模型被定义为^[15]

$$p(\mathbf{X}_k | \mathbf{X}_{k-1}) = \mathcal{W}(\mathbf{X}_k; \delta_{k|k-1}, \mathbf{X}_{k-1} / \delta_{k|k-1}) \quad (3)$$

式中 $\mathcal{W}(\mathbf{Y}; a, \mathbf{C})$ 为对称正定矩阵 \mathbf{Y} 服从 Wishart 分布的概率密度函数, $\delta_{k|k-1}$ 作为自由度描述了模型演化的不确定性.

联合跟踪与分类实质上是混合状态空间模型来描述系统的状态方程,并利用混合估计理论来处理连续值的运动状态和离散值的目标类型数据,实现目标跟踪和分类的同时进行. 本文将直接使用扩展目标的形态信息作为属性信息,作为先验类别信息加入到 GIW-PHD 滤波器中. 对称正定矩阵与椭圆有如下关系^[16]:

引理 1 $d \times d$ 维对称正定矩阵 \mathbf{X} 通过最多 $\frac{d(d-1)}{2}$ 次 Givens 变换转化为对角矩阵,对角矩阵的元素为 \mathbf{X} 的特征值.

根据引理 1,描述扩展目标形态的随机矩阵 \mathbf{X}_k 可以分解为

$$\mathbf{X}_k = \mathbf{E}_k \mathbf{Z}^p \mathbf{E}_k^\top \quad (4)$$

式中,对角矩阵 \mathbf{Z}^p 的元素分别为椭型的长短轴, \mathbf{E}_k 为旋转矩阵 (行列式为 ± 1 的正交矩阵),表征了椭型的朝向,被定义为

$$\mathbf{E}_k = \begin{bmatrix} \cos \varphi_k & -\sin \varphi_k \\ \sin \varphi_k & \cos \varphi_k \end{bmatrix} \quad (5)$$

式中 φ_k 为椭型的方向角.

对于扩展目标,大小和形状往往是先验已知的^[6],例如,某一类飞机、舰船的现状和大小,因为这种形态信息是实际存在的,也可以通过纵向距离像和横向距离像获得. 表征形态大小的对角矩阵 \mathbf{Z}^p 与目标类别具有一一对应的关系,且是固定不变的,因此 \mathbf{Z}^p 才是本质上具有意义的可区分类别的属性信息,而扩展目标的朝

向是随机、不确定的,需要进行在线估计, \mathbf{E}_k 的估计将在第 4.3 节进行讨论.

在 $\mathbf{Z}^p = f(\mathbf{X}_k)$ 和式(3)的基础上,第 c_i 类扩展目标的伪量测先验信息 \mathbf{Z}^p 可以被建模为

$$p(\mathbf{Z}_{c_i}^p | \mathbf{X}_{c_i,k}) = \mathcal{N}(\mathbf{Z}_{c_i}^p; \delta_{c_i,k}^p, \mathbf{E}_{c_i,k}^{-1} \mathbf{X}_{c_i,k} \mathbf{E}_{c_i,k}^{-T} / \delta_{c_i,k}^p) \quad (6)$$

式中 $\delta_{c_i,k}^p$ 同样描述了伪量测模型演化的不确定性. 参数 $\delta_{k|k-1}$ 和 $\delta_{c_i,k}^p$ 为经验性参数,机动性小的模型选择较大的 $\delta_{k|k-1}$ 和 $\delta_{c_i,k}^p$, 机动性大的模型选择较小的 $\delta_{k|k-1}$ 和 $\delta_{c_i,k}^p$.

3 理论基础

Mahler 在文献[12]中给出了标准的基于 PHD 的扩展目标跟踪递归方程式. 扩展目标 PHD 滤波器的预测方程为

$$D_{k|k-1}(\xi_k) = \int p_S(\xi_k) p_{k|k-1}(\xi_k | \xi_{k-1}) \times D_{k-1}(\xi_{k-1}) d\xi_{k-1} + D_k^b(\xi_k) \quad (7)$$

式中 $p_S(\cdot)$ 为扩维状态的存活概率, $p_{k|k-1}(\cdot)$ 为状态转移密度, $D_k^b(\cdot)$ 为新生目标的 PHD.

扩展目标 PHD 滤波器的更新方程为

$$D_{k|k}(\xi_k) = L_{\Sigma_k}(\xi_k) D_{k|k-1}(\xi_k) \quad (8)$$

式中的量测伪似然函数 $L_{\Sigma_k}(\cdot)$ 被定义为

$$L_{\Sigma_k}(\xi_k) = 1 - (1 - e^{-\gamma(\xi_k)}) p_D(\xi_k) + e^{-\gamma(\xi_k)} p_D(\xi_k) \times \sum_{p \in \Sigma_k} \omega_p \sum_{W \in p} \frac{\gamma(\xi_k)^{|W|}}{d_W} \cdot \prod_{z_k \in W} \frac{g_{z_k}(\xi_k)}{\lambda_k c_k(z_k)} \quad (9)$$

式中 $\lambda_k = \beta_{FA,k} S$ 为监测区域 S 内杂波的期望数目, $c_k(z_k) = 1/S$ 为均匀分布, $p \in \Sigma_k$ 为观测集 Σ_k 的划分, $W \in p$ 是第 p 种划分中的非空量测子集, ω_p 和 d_W 是每种划分和量测子集的非负权重系数; $g_{z_k}(\xi_k)$ 为单目标产生一个量测的似然函数,在模型(2)的基础上被定义为

$$g_{z_k}(\xi_k) = \mathcal{N}(z_k; (\mathbf{H}_k \otimes \mathbf{I}_d) \mathbf{x}_k, \mathbf{X}_k) \quad (10)$$

4 改进算法

在前两节的基础上,假设 $k-1$ 时刻 c_i 类扩展目标状态集的目标强度近似为归一化的混合高斯逆 Wishart 分布的形式^[13], 即:

$$D_{c_i,k-1}(\xi_{k-1}) \approx \sum_{j=1}^{J_{c_i,k-1}} w_{c_i,k-1}^{(j)} \mathcal{N}(\mathbf{x}_{c_i,k-1}; \mathbf{m}_{c_i,k-1}^{(j)}, \mathbf{P}_{c_i,k-1}^{(j)} \otimes \mathbf{X}_{c_i,k-1}) \times \mathcal{IW}(\mathbf{X}_{c_i,k-1}; \mathbf{v}_{c_i,k-1}^{(j)}, \mathbf{V}_{c_i,k-1}^{(j)}) \quad (11)$$

式中, $J_{c_i,k-1}$ 为 GIW 项的个数, $w_{c_i,k-1}^{(j)}$, $\mathbf{m}_{c_i,k-1}^{(j)}$, $\mathbf{P}_{c_i,k-1}^{(j)}$ 分别为第 j 个 GIW 项的权重、高斯均值和方差; $\mathcal{IW}(\mathbf{X}; \mathbf{v}, \mathbf{V})$ 是逆 Wishart 分布的概率密度函数, \mathbf{v} 和 \mathbf{V} 分别是其自

由度和逆标度矩阵.

GIW 项的修剪与合并以及最终的状态提取方法使用传统的方法,可参考文献[13],本文的核心是研究扩展目标的联合跟踪与分类算法,量测的划分不是重点,本文采用文献[13]中的距离划分,文中不再赘述. 预测和更新的详细步骤如下.

4.1 预测

作为属性信息的伪量测未影响到预测步骤,因此这里的预测步骤与文献[13]中相似,即

$$D_{c_i,k|k-1}(\xi_k) = \sum_{j=1}^{J_{c_i,k-1}} w_{c_i,k|k-1}^{(j)} \mathcal{N}(\mathbf{x}_{c_i,k}; \mathbf{m}_{c_i,k|k-1}^{(j)}, \mathbf{P}_{c_i,k|k-1}^{(j)} \otimes \mathbf{X}_{c_i,k}) \times \mathcal{IW}(\mathbf{X}_{c_i,k}; \mathbf{v}_{c_i,k|k-1}^{(j)}, \mathbf{V}_{c_i,k|k-1}^{(j)}) + D_{c_i,k}^b(\xi_k) \quad (12)$$

式中,

$$w_{c_i,k|k-1}^{(j)} = p_S(\xi_k) w_{c_i,k-1}^{(j)} \quad (13)$$

$$\mathbf{m}_{c_i,k|k-1}^{(j)} = (\mathbf{F}_{c_i,k|k-1} \otimes \mathbf{I}_d) \mathbf{m}_{c_i,k-1}^{(j)} \quad (14)$$

$$\mathbf{P}_{c_i,k|k-1}^{(j)} = \mathbf{F}_{c_i,k|k-1} \mathbf{P}_{c_i,k-1}^{(j)} \mathbf{F}_{c_i,k-1}^T + \mathbf{Q}_{c_i,k|k-1} \quad (15)$$

$$\mathbf{v}_{c_i,k|k-1}^{(j)} = e^{-T/\tau} \mathbf{v}_{c_i,k-1}^{(j)} \quad (16)$$

$$\mathbf{V}_{c_i,k|k-1}^{(j)} = \frac{\mathbf{v}_{c_i,k-1}^{(j)} - d - 1}{\mathbf{v}_{c_i,k|k-1}^{(j)} - d - 1} \mathbf{V}_{c_i,k-1}^{(j)} \quad (17)$$

$$D_{c_i,k}^b(\xi_k) = \sum_{j=1}^{J_{c_i,k}} w_{c_i,bk}^{(j)} \mathcal{N}(\mathbf{x}_{c_i,k}; \mathbf{m}_{c_i,bk}^{(j)}, \mathbf{P}_{c_i,bk}^{(j)} \otimes \mathbf{X}_{c_i,k}) \times \mathcal{IW}(\mathbf{X}_{c_i,k}; \mathbf{v}_{c_i,bk}^{(j)}, \mathbf{V}_{c_i,bk}^{(j)}) \quad (18)$$

预测后完整的目标强度可以写为

$$D_{c_i,k|k-1}(\xi_k) = \sum_{j=1}^{J_{c_i,k-1}} w_{c_i,k|k-1}^{(j)} \mathcal{N}(\mathbf{x}_{c_i,k}; \mathbf{m}_{c_i,k|k-1}^{(j)}, \mathbf{P}_{c_i,k|k-1}^{(j)} \otimes \mathbf{X}_{c_i,k}) \times \mathcal{IW}(\mathbf{X}_{c_i,k}; \mathbf{v}_{c_i,k|k-1}^{(j)}, \mathbf{V}_{c_i,k|k-1}^{(j)}) \quad (19)$$

式中 $J_{c_i,k|k-1} = J_{c_i,k-1} + J_{c_i,bk}$.

4.2 更新

更新后的目标强度为

$$D_{c_i,k|k}(\xi_k) = D_{c_i,k|k-1}^{ND}(\xi_k) + \sum_{p \in \Sigma_k} \sum_{W \in p} D_{c_i,k|k}^D(\xi_k) \quad (20)$$

式中, $D_{c_i,k|k-1}^{ND}(\xi_k)$ 处理未检测到的情况,

$$D_{c_i,k|k-1}^{ND}(\xi_k) = \sum_{j=1}^{J_{c_i,k-1}} w_{c_i,k|k-1}^{(j)} \mathcal{N}(\mathbf{x}_{c_i,k}; \mathbf{m}_{c_i,k|k-1}^{(j)}, \mathbf{P}_{c_i,k|k-1}^{(j)} \otimes \mathbf{X}_{c_i,k}) \times \mathcal{IW}(\mathbf{X}_{c_i,k}; \mathbf{v}_{c_i,k|k-1}^{(j)}, \mathbf{V}_{c_i,k|k-1}^{(j)}) \quad (21)$$

$$w_{c_i,k|k-1}^{(j)} = (1 - (1 - e^{-\gamma(c_i, \xi^0)}) p_D^{(c_i, \xi^0)}) w_{c_i,k-1}^{(j)} \quad (22)$$

$$\xi_{k|k-1}^{(j)} = \xi_{k-1}^{(j)} \quad (23)$$

由于检测部分的结果推导比较复杂,这里仅简要给出部分关键推导内容.

因为伪量测集 $\{\mathbf{Z}_{c_i}^p\}_{c_i=1}^C$ 可以作为先验信息在每一时刻获得,所以每一时刻得到的可利用的量测集包括伪量测集和真实观测集,即 $\mathbf{Z}_k = \{\mathbf{Z}_k, \{\mathbf{Z}_{c_i}^p\}_{c_i=1}^C\}$. 则每一时

刻在每一个量测集中,式(9)中的似然函数乘积利用目标和属性的组合量测似然函数代替为

$$\prod_{z_i \in W} \frac{g(z_k, \mathbf{Z}^P | \xi_k, c_i)}{\lambda_k c_k(z_k)} = \beta_{FA,k}^{-|W|} p(\mathbf{Z}_k | \xi_k, c_i) \\ = \beta_{FA,k}^{-|W|} p(\boldsymbol{\Sigma}_k, \mathbf{Z}^P | \xi_k, c_i) \quad (24)$$

位置信息与属性信息相互独立,式(24)中似然函数可写为

$$p(\boldsymbol{\Sigma}_k, \mathbf{Z}^P | \xi_k, c_i) \\ = p(\mathbf{Z}^P | \xi_k, c_i) p(\boldsymbol{\Sigma} | \xi_k, c_i) \\ = p(\mathbf{Z}_i^P | \mathbf{X}_{c_i,k}) \prod_{z_i \in W} g(z_k | \mathbf{x}_{c_i,k}) \\ \propto \mathcal{W}(\mathbf{Z}_i^P; \delta_{c_i,k}^P, \mathbf{E}_{c_i,k}^{-1} \mathbf{X}_{c_i,k} \mathbf{E}_{c_i,k}^{-T} / \delta_{c_i,k}^P) \\ \times \text{etr} \left(-\frac{1}{2} \mathbf{Z}_k^W \mathbf{X}_{c_i,k}^{-1} \right) \times \mathcal{N}(\bar{\mathbf{z}}_k^W; \tilde{\mathbf{H}} \mathbf{x}_{c_i,k}, \frac{\mathbf{X}_{c_i,k}}{|W|}) \quad (25)$$

式中, \mathbf{Z}_k^W 和 $\bar{\mathbf{z}}_k^W$ 分别为量测子集 W 的散布矩阵和量测集中心, $|W|$ 为量测集 W 中的量测个数, 散布矩阵 \mathbf{Z}_k^W 计算公式为

$$\mathbf{Z}_k^W = \sum_{z_i^W \in W} (z_k^{(j)} - \bar{\mathbf{z}}_k^W)(z_k^{(j)} - \bar{\mathbf{z}}_k^W)^T \quad (26)$$

将预测 PHD 式(19)与式(25)相乘, 得

$$\mathcal{W} \left(\mathbf{Z}_i^P; \delta_{c_i,k}^P, \frac{\mathbf{E}_{c_i,k}^{-1} \mathbf{X}_{c_i,k} \mathbf{E}_{c_i,k}^T}{\delta_{c_i,k}^P} \right) \\ \times \text{etr} \left(-\frac{1}{2} \mathbf{Z}_{c_i,k}^W \mathbf{X}_{c_i,k}^{-1} \right) \\ \times \mathcal{N} \left(\bar{\mathbf{z}}_{c_i,k}^W; \tilde{\mathbf{H}} \mathbf{x}_{c_i,k}, \frac{\mathbf{X}_{c_i,k}}{|W|} \right) \\ \times \mathcal{N}(\mathbf{x}_{c_i,k}; \mathbf{m}_{c_i,k|k-1}^{(j)}, \mathbf{P}_{c_i,k|k-1}^{(j)} \otimes \mathbf{X}_{c_i,k}) \\ \times \mathcal{G}(\mathbf{X}_{c_i,k}; \mathbf{v}_{c_i,k|k-1}^{(j)}, \mathbf{V}_{c_i,k|k-1}^{(j)}) \\ = \mathcal{W} \left(\mathbf{Z}_i^P; \delta_{c_i,k}^P, \frac{\mathbf{E}_{c_i,k}^{-1} \mathbf{X}_{c_i,k} \mathbf{E}_{c_i,k}^{-T}}{\delta_{c_i,k}^P} \right) \\ \text{etr} \left(-\frac{1}{2} \mathbf{Z}_{c_i,k}^W \mathbf{X}_{c_i,k}^{-1} \right) \\ \times \mathcal{G}(\mathbf{X}_{c_i,k}; \mathbf{v}_{c_i,k|k-1}^{(j)}, \mathbf{V}_{c_i,k|k-1}^{(j)}) \\ \times \mathcal{N}(\bar{\mathbf{z}}_{c_i,k}^W; \tilde{\mathbf{H}} \mathbf{m}_{c_i,k|k-1}^{(j)}, \mathbf{S}_{c_i,k|k-1}^{(j,W)} \mathbf{X}_{c_i,k}) \\ \times \mathcal{N}(\mathbf{x}_{c_i,k}; \mathbf{m}_{c_i,k|k-1}^{(j,W)}, \mathbf{P}_{c_i,k|k-1}^{(j,W)} \otimes \mathbf{X}_{c_i,k}) \quad (27)$$

式(27)通过高斯函数相乘公式可以得到, 式中

$$\mathbf{m}_{c_i,k|k-1}^{(j,W)} = \mathbf{m}_{c_i,k|k-1}^{(j)} \\ + (\mathbf{K}_{c_i,k|k-1}^{(j,W)} \otimes \mathbf{I}_d) (\bar{\mathbf{z}}_{c_i,k}^W - \tilde{\mathbf{H}} \mathbf{m}_{c_i,k|k-1}^{(j)}) \quad (28)$$

$$\mathbf{P}_{c_i,k|k-1}^{(j,W)} = \mathbf{P}_{c_i,k|k-1}^{(j)} - \mathbf{K}_{c_i,k|k-1}^{(j,W)} \mathbf{S}_{c_i,k|k-1}^{(j,W)} (\mathbf{K}_{c_i,k|k-1}^{(j,W)})^T \quad (29)$$

$$\mathbf{K}_{c_i,k|k-1}^{(j,W)} = \mathbf{P}_{c_i,k|k-1}^{(j)} \mathbf{H}^T (\mathbf{S}_{c_i,k|k-1}^{(j,W)})^{-1} \quad (30)$$

至此, 我们已经得到了 GIW 项中更新后的高斯分布项, 接下来更新逆 Wishart 分布项, 将式(27)前四项相乘得到

$$\mathcal{W} \left(\mathbf{Z}_i^P; \delta_{c_i,k}^P, \frac{\mathbf{E}_{c_i,k}^{-1} \mathbf{X}_{c_i,k} \mathbf{E}_{c_i,k}^T}{\delta_{c_i,k}^P} \right) \text{etr} \left(-\frac{1}{2} \mathbf{Z}_{c_i,k}^W \mathbf{X}_{c_i,k}^{-1} \right) \\ \times \mathcal{G}(\mathbf{X}_{c_i,k}; \mathbf{v}_{c_i,k|k-1}^{(j)}, \mathbf{V}_{c_i,k|k-1}^{(j)})$$

$$\cdot \mathcal{N}(\bar{\mathbf{z}}_{c_i,k}^W; \tilde{\mathbf{H}} \mathbf{m}_{c_i,k|k-1}^{(j)}, \mathbf{S}_{c_i,k|k-1}^{(j,W)} \mathbf{X}_{c_i,k}) \\ \propto \frac{|\mathbf{E}_{c_i,k}^{-1} \mathbf{X}_{c_i,k} \mathbf{E}_{c_i,k}^T / \delta_{c_i,k}^P|^{-\frac{1}{2} \delta_{c_i,k}^P} |\mathbf{Z}_{c_i,k}^P|^{\frac{1}{2} (\delta_{c_i,k}^P - d - 1)}}{2^{\frac{1}{2} \delta_{c_i,k}^P d} \Gamma \left(\frac{1}{2} \delta_{c_i,k}^P \right)} \\ \times \text{etr} \left(-\frac{1}{2} \delta_{c_i,k}^P (\mathbf{E}_{c_i,k}^T \mathbf{Z}_{c_i,k}^P \mathbf{E}_{c_i,k}) \mathbf{X}_{c_i,k}^{-1} \right) \\ \times \text{etr} \left(-\frac{1}{2} \delta \mathbf{V}_{c_i,k|k-1}^{(j)} \mathbf{X}_{c_i,k}^{-1} \right) \text{etr} \left(-\frac{1}{2} \mathbf{Z}_{c_i,k}^W \mathbf{X}_{c_i,k}^{-1} \right) \\ \times \text{etr} \left(-\frac{1}{2} (\bar{\mathbf{z}}_{c_i,k}^W - \tilde{\mathbf{H}} \mathbf{m}_{c_i,k|k-1}^{(j)}) \right. \\ \cdot (\bar{\mathbf{z}}_{c_i,k}^W - \tilde{\mathbf{H}} \mathbf{m}_{c_i,k|k-1}^{(j)})^T (\mathbf{S}_{c_i,k|k-1}^{(j,W)} \mathbf{X}_{c_i,k})^{-1} \left. \right) \\ \propto \delta_{c_i,k}^P \frac{|\mathbf{V}_{c_i,k|k-1}^{(j)}|^{\frac{1}{2} (v_{c_i,k|k-1}^{(j)} - d - 1)}}{|\mathbf{V}_{c_i,k|k-1}^{(j,W)}|^{\frac{1}{2} (v_{c_i,k|k-1}^{(j,W)} - d - 1)}} \\ \cdot \frac{\Gamma_d \left[\frac{1}{2} (v_{c_i,k|k-1}^{(j,W)} - d - 1) \right] |\mathbf{Z}_{c_i,k}^P|^{\frac{1}{2} (\delta_{c_i,k}^P - d - 1)}}{\Gamma_d \left[\frac{1}{2} (v_{c_i,k|k-1}^{(j)} - d - 1) \right] \Gamma \left(\frac{1}{2} \delta_{c_i,k}^P \right)} \\ \times \mathcal{G}(\mathbf{X}_{c_i,k}; \mathbf{v}_{c_i,k|k-1}^{(j,W)}, \mathbf{V}_{c_i,k|k-1}^{(j,W)}) \quad (31)$$

式中

$$v_{c_i,k|k-1}^{(j,W)} = v_{c_i,k|k-1}^{(j)} + |W| + \delta_{c_i,k}^P \quad (32)$$

$$\mathbf{V}_{c_i,k|k-1}^{(j,W)} = \mathbf{V}_{c_i,k|k-1}^{(j)} + \mathbf{N}_{c_i,k|k-1}^{(j,W)} + \mathbf{Z}_{c_i,k}^W + \delta_{c_i,k}^P \mathbf{E}_{c_i,k}^T \mathbf{Z}_{c_i,k}^P \mathbf{E}_{c_i,k} \\ (33)$$

$$\mathcal{L}_{c_i,k}^{(j,W)} = \pi^{-\frac{|W|d}{2}} (|W| \mathbf{S}_{c_i,k|k-1}^{(j,W)})^{-\frac{1}{2}} \\ \cdot \delta_{c_i,k}^P \frac{|\mathbf{Z}_{c_i,k}^P|^{\frac{1}{2} (\delta_{c_i,k}^P - d - 1)}}{\Gamma \left(\frac{1}{2} \delta_{c_i,k}^P \right)} \\ \times \frac{|\mathbf{V}_{c_i,k|k-1}^{(j)}|^{\frac{1}{2} (v_{c_i,k|k-1}^{(j)} - d - 1)}}{|\mathbf{V}_{c_i,k|k-1}^{(j,W)}|^{\frac{1}{2} (v_{c_i,k|k-1}^{(j,W)} - d - 1)}} \\ \cdot \frac{\Gamma_d \left[\frac{1}{2} (v_{c_i,k|k-1}^{(j,W)} - d - 1) \right]}{\Gamma_d \left[\frac{1}{2} (v_{c_i,k|k-1}^{(j)} - d - 1) \right]} \quad (34)$$

式中, 新息矩阵和新息因子分别为

$$\mathbf{N}_{c_i,k|k-1}^{(j,W)} = (\mathbf{S}_{c_i,k|k-1}^{(j,W)})^{-1} (\bar{\mathbf{z}}_{c_i,k}^W - \tilde{\mathbf{H}} \mathbf{m}_{c_i,k|k-1}^{(j)}) \\ (\bar{\mathbf{z}}_{c_i,k}^W - \tilde{\mathbf{H}} \mathbf{m}_{c_i,k|k-1}^{(j)})^T \quad (35)$$

$$\mathbf{S}_{c_i,k|k-1}^{(j,W)} = \mathbf{H} \mathbf{P}_{c_i,k|k-1}^{(j)} \mathbf{H}^T + \frac{1}{|W|} \quad (36)$$

更新后检测部分的权重为

$$w_{c_i,k|k-1}^{(j,W)} = \frac{\omega_p}{d_W} e^{-\gamma(\xi_{c_i,k})} \left| \frac{\gamma(\xi_{c_i,k})}{\beta_{FA,k}} \right|^{|W|} \\ \cdot p_D(\xi_{c_i,k}) \mathcal{L}_{c_i,k}^{(j,W)} w_{c_i,k|k-1}^{(j)} \quad (37)$$

$$\text{式中, } \omega_p = \frac{\prod_{W \in \mathcal{P}} d_W}{\sum_{p' \subseteq \Sigma, W' \in p'} \prod d_{W'}} \quad (38)$$

$$d_w = \delta_{|W|,1} + \sum_{i=1}^C \sum_{l=1}^{J_{c_i,k-1}} e^{-\gamma(\xi_{c_i,k})} \left(\frac{\gamma(\xi_{c_i,k})}{\beta_{FA,k}} \right)^{|W|} \cdot p_D(\xi_{c_i,k}) \mathcal{L}_{c_i,k}^{(l,W)} w_{c_i,k|k-1}^{(l)} \quad (39)$$

更新后第 c_i 类扩展目标的 GIW 项共有 $J_{c_i,k|k} = J_{c_i,k|k-1} + J_{c_i,k|k-1} \sum_{p=1}^P |P_p|$, 其中 $|P_p|$ 为第 p 个划分中包含的量测子集 W 的个数.

4.3 E_k 的估计

在上述的推导中, 旋转矩阵 E_k 表示扩展目标的朝向. 实际上, 扩展目标的朝向可能是任何方向, 它并不是先验已知的. 在这一节中, 我们通过对式(5)中方向角的估计来在线估计旋转矩阵 E_k . 式(26)中散布矩阵 Z_k^W 为量测集 $\{z_k \in W\}$ 的协方差矩阵, 根据主成分分析的原理, 散布矩阵 Z_k^W 最大的特征向量对应着量测集中方差最大的方向. 另外, 在 1.2 节量测模型的基础上, 椭圆扩展目标的长轴方向可近似认为是量测集中数据变化最大的方向. 图 1 为利用主成分分析法估计方向角的结果, 在式(10)量测似然模型的基础上, 随机产生 20 个量测, 真实方向角为 $\varphi_k = \pi/4 \text{rad}$, 描述椭圆的随机矩阵为 $X_k = E_k \text{diag}(50^2, 10^2) E_k^T$, 估计的方向角为 $\hat{\varphi}_k = 0.7787 \text{rad}$, 估计值比真实值偏差了 -0.85% .




图1 方向估计

对旋转矩阵 E_k 的估计如表 1 所述.

表 1 E_k 的估计方法

序号	估计方法
1	计算式(26)中的散布矩阵 Z_k^W
2	求出 Z_k^W 中最大的特征值所对应的特征向量, 记为 r_{\max}
3	r_{\max} 与 x 轴的夹角即扩展目标方向角的估计值, 即 $\hat{\varphi}_k = \arctan(r_{\max}(2)/r_{\max}(1))$
4	由式(5)计算 E_k

4.4 MM-GIW-PHD-JTC 算法

前三节我们已经给出了基于 GIW-PHD 滤波器的联合跟踪与分类算法, 然而, 前面的方法中属性信息 Z^P 的加入仅仅影响了多扩展目标的数目和形态的估计,

对应于式(32)(33)和式(37). 原有的机动算法假设所有目标的运动都遵循同一个预先设定的模型集, 即运动模型集是类别无关的^[17], 而事实上, 正如引言所叙述的, 目标类别信息能够确定更精确的目标运动模型, 每一类目标的模型集是不同的, 即目标的运动模型集是类别相关的, 因此 JTC 有助于建立更为精确的目标运动模型, 以此提高目标的跟踪精度. 本节我们将结合多模型算法, 实现对机动扩展目标的联合跟踪与分类.

MM-GIW-PHD-JTC 算法的一个循环流程如下: 假设在 $k-1$ 时刻, 已经得到了 c_i 类扩展目标的后验目标强度 $D'_{c_i,k-1}(\xi_{k-1})$ 、第 j 个 GIW 项的模型概率 $\mu_{c_i,k-1}^{(j),r}$ ($r' = 1, \dots, r(c_i)$) 和马尔科夫模型转移概率矩阵 $[\pi_{rr'}]_{r=1, \dots, r(c_i)}$. c_i 类扩展目标的 $r(c_i)$ 个基于模型各 GIW-PHD 滤波器滤波结果如下

$$D'_{c_i,k-1}(\xi_{k-1}) \approx \sum_{j=1}^{r(c_i)} w_{c_i,k-1}^{(j),r} \mathcal{N}(x_{c_i,k-1}; m_{c_i,k-1}^{(j),r}, P_{c_i,k-1}^{(j),r} \otimes X_{c_i,k-1}) \times \mathcal{KW}(X_{c_i,k-1}; v_{c_i,k-1}^{(j),r}, V_{c_i,k-1}^{(j),r}) \quad (40)$$

式中 $r = 1, \dots, r(c_i)$.

(1) 输入交互(混合)

交互后的输入到 PHD 滤波器的存活目标强度为

$$\tilde{D}'_{c_i,k-1}(\xi_{k-1}) \approx \sum_{r=1}^{r(c_i)} \mu_{c_i,k-1}^{(j),r} D'_{c_i,k-1}(\xi_{k-1}) \quad (41)$$

式中

$$\begin{cases} \mu_{c_i,k-1}^{(j),r} = \frac{1}{c_{k-1}^{r'}} \pi_{rr'} \mu_{c_i,k-1}^{(j),r} \\ c_{k-1}^{r'} = \sum_{r=1}^{r(c_i)} \pi_{rr'} \mu_{c_i,k-1}^{(j),r} \end{cases} \quad (42)$$

(2) 滤波

在 3.1 节的基础上, 按照式(1)的模型进行预测. 更新步骤将式(39)变为如下表达式

$$d_w = \delta_{|W|,1} + \sum_{i=1}^C \sum_{r=1}^{r(c_i)} \sum_{l=1}^{J_{c_i,k-1}} \left(e^{-\gamma(\xi_{c_i,k})} \left(\frac{\gamma(\xi_{c_i,k})}{\beta_{FA,k}} \right)^{|W|} \cdot p_D(\xi_{c_i,k}) \mathcal{L}_{c_i,k}^{(l,W)} w_{c_i,k|k-1}^{(l),r} \right) \quad (43)$$

其他参数计算方法不变. 更新后得到的第 c_i 类扩展目标的基于第 r 个模型的目标强度为 $D'_{c_i,k|k}(\xi_k)$.

(3) 模型概率更新

第 r 个模型的第 j 个 GIW 项的似然函数为

$$A_r^j = |2\pi S_{c_i,k|k-1}^{(j,W)}|^{-\frac{|W|}{2}} \cdot \exp \left(-\frac{1}{2} (\bar{z}_{c_i,k}^W - \tilde{H} m_{c_i,k|k-1}^{(j),r})^T \cdot (S_{c_i,k|k-1}^{(j,W)})^{-1} (\bar{z}_{c_i,k}^W - \tilde{H} m_{c_i,k|k-1}^{(j),r}) \right) \quad (44)$$

根据贝叶斯概率公式, 各模型概率更新为

$$\mu_{c_i,k}^{(j),r} = A_r^j \mu_{c_i,k-1}^{(j),r} / C_k \quad (45)$$

式中, C_k 为第 c_i 类目标 GIW 项的归一化常数, 即

$$C_k = \sum_{r=1}^{r(c_i)} \Lambda_i^j \mu_{c_i, k-1}^{(j), r} \quad (46)$$

(4) 融合估计

更新后第 c_i 类目标的后验 PHD 为

$$D_{c_i, k|k}(\xi_k) = \sum_{j=1}^{J_{c_i, k|k}} w_{c_i, k|k}^{(j)} \mathcal{N}(x_{c_i, k|k}; \mathbf{m}_{c_i, k|k}^{(j)}, \mathbf{P}_{c_i, k|k}^{(j)} \otimes \mathbf{X}_{c_i, k|k}) \times \mathcal{D}\mathcal{W}(\mathbf{X}_{c_i, k|k}; \mathbf{v}_{c_i, k|k}^{(j)}, \mathbf{V}_{c_i, k|k}^{(j)}) \quad (47)$$

式中 GIW 项的权重、状态均值、协方差、自由度和逆标度矩阵分别为

$$w_{c_i, k|k}^{(j)} = \sum_{r=1}^{r(c_i)} \mu_{c_i, k}^{(j), r} w_{c_i, k|k}^{(j), r} \quad (48)$$

$$\mathbf{m}_{c_i, k|k}^{(j)} = \sum_{r=1}^{r(c_i)} \mu_{c_i, k}^{(j), r} \mathbf{m}_{c_i, k|k}^{(j), r} \quad (49)$$

$$\mathbf{P}_{c_i, k|k}^{(j)} = \sum_{r=1}^{r(c_i)} \mu_{c_i, k}^{(j), r} \times [\mathbf{P}_{c_i, k|k}^{(j), r} + (\mathbf{m}_{c_i, k|k}^{(j)} - \mathbf{m}_{c_i, k|k}^{(j), r})(\mathbf{m}_{c_i, k|k}^{(j)} - \mathbf{m}_{c_i, k|k}^{(j), r})^T] \quad (50)$$

$$\mathbf{v}_{c_i, k|k}^{(j)} = \sum_{r=1}^{r(c_i)} \mu_{c_i, k}^{(j), r} \mathbf{v}_{c_i, k|k}^{(j), r} \quad (51)$$

$$\mathbf{V}_{c_i, k|k}^{(j)} = \sum_{r=1}^{r(c_i)} \mu_{c_i, k}^{(j), r} \mathbf{V}_{c_i, k|k}^{(j), r} \quad (52)$$

最后, 提取第 c_i 类多目标的状态为

$$\hat{\xi}_{c_i, k} = \{\xi_{c_i, k}^{(j)}\} = \{\mathbf{m}_{c_i, k|k}^{(j)}, \mathbf{P}_{c_i, k|k}^{(j)}, \mathbf{V}_{c_i, k|k}^{(j)} \mid w_{c_i, k|k}^{(j)} > 0.5\} \quad (53)$$

完整的全目标后验 PHD 为

$$D_{k|k}(\xi_k) = \sum_{i=1}^c D_{c_i, k|k}(\xi_k) \quad (54)$$

每一时刻完整的滤波过程见图 2.

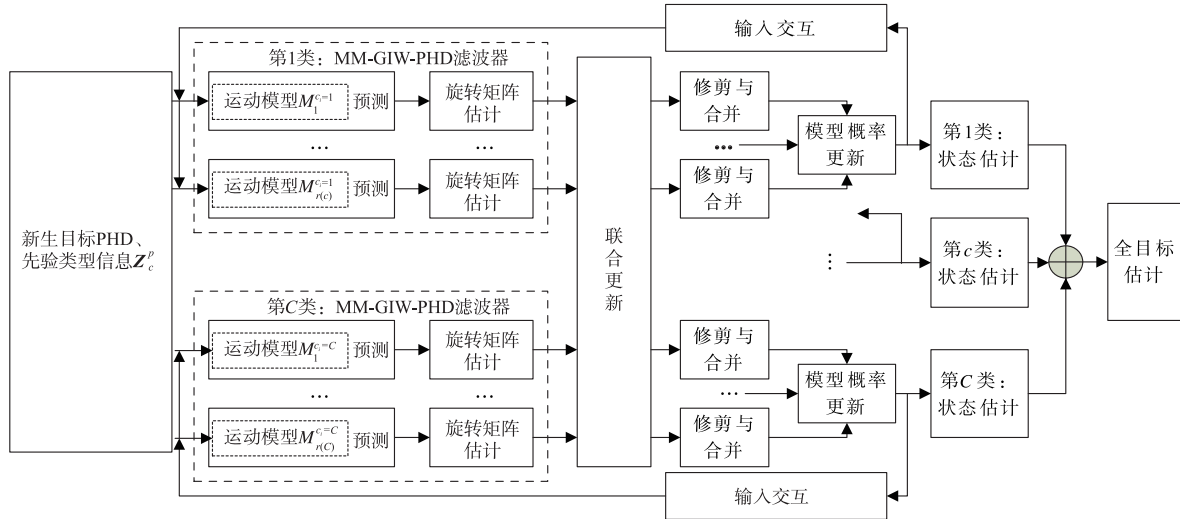


图2 MM-GIW-PHD-JTC算法框图

5 仿真验证

5.1 场景及参数设置

在仿真场景中, 假设存在两类扩展目标, 即类别集为 $\Theta = \{1, 2\}$, 见表 2.

表 2 扩展目标信息

目标类别	目标长轴 A/m	目标短轴 a/m	最大加速度 $m \cdot s^{-2}$
1	20	5	0.2
2	10	2.5	5

则可以使用的类别先验信息为

$$\begin{cases} \mathbf{Z}_{c_1}^p = \text{diag}([20^2 & 5^2]) \\ \mathbf{Z}_{c_2}^p = \text{diag}([10^2 & 2.5^2]) \end{cases}$$

为验证本文所提出的 MM-GIW-PHD-JTC 算法, 四

个扩展目标被考虑: 属于第一个类别的目标 1 和目标 2 以及属于第二个类别的目标 3 和目标 4. 四个目标分别第 1s、21s、51s 以及 81s 出现. 目标 1 和 2 为两个非机动目标, 做匀速直线运动. 目标 3 先匀速后加速, 目标 4 先加速后匀速.

第一类目标所确定的运动模型为 CV 模型, 第二类目标所确定的运动模型有两个状态, 第一个状态是标准差为 $0.2m \cdot s^{-1/2}$ 的 CV 模型, 第二个状态是标准差为 $5m \cdot s^{-1/2}$ 、时间常数为 $\tau = 15s$ 的 Singer 机动模型, 这两个运动模型的转移概率为 $[0.98, 0.02; 0.1, 0.9]$. 限于篇幅, CV 模型和 Singer 模型的状态转移矩阵以及量测噪声协方差矩阵参考文献 [18]. 采样时间 $T = 1s$, 杂波数目的期望为 20. 下面考虑滤波器初始条件的设置. 依照目标可能出现的位置, 将式 (18) 中新生 PHD 的参数定义为

$$\begin{cases} \mathbf{m}_{c_1, bk}^{(1)} = [250, 250, 0, 0, 0, 0]^T \\ \mathbf{m}_{c_1, bk}^{(2)} = [300, 100, 0, 0, 0, 0]^T \\ \mathbf{m}_{c_2, bk}^{(1)} = [300, 280, 0, 0, 0, 0]^T \\ \mathbf{m}_{c_2, bk}^{(2)} = [250, 280, 0, 0, 0, 0]^T \\ \mathbf{P}_{c_i, bk}^{(j)} = \text{diag}([100^2 \quad 25^2 \quad 25^2]) \\ v_{c_i, bk}^{(j)} = 7 \\ \mathbf{V}_{c_i, bk}^{(j)} = \text{diag}([1 \quad 1]) \\ J_{c_i, bk} = 4 \end{cases}$$

使用所提 MM-GIW-PHD-JTC 算法进行滤波, 并与基于 CV 模型的 GIW-PHD 算法、基于 CV 模型和 Singer 模型的 MM-GIW-PHD 算法进行比较。

5.2 仿真结果

图 3 ~ 图 5 分别为所提算法与 GIW-PHD、MM-GIW-PHD 滤波算法对扩展目标的状态估计结果, 图中用棕色的点线标识出较为明显的有偏差状态估计。本文所提出的 MM-GIW-PHD-JTC 算法能够很好地估计不同类别扩展目标的状态如图 3, 而在第二类目标出现即 50s 之后, 由于存在机动情况, GIW-PHD 滤波算法对状态的估计出现较大偏差见图 4。在前 50s, MM-GIW-PHD 相对于其他两种滤波算法, 估计出现了较大偏差如图 5。状态估计图只是直观上给了一个滤波方法的比较结果, 接下来从目标数目估计和 OSPA 距离两方面对三种滤波方法进行比较。




图3 MM-GIW-PHD-JTC滤波器状态估计图




图4 GIW-PHD滤波器状态估计图

图 6 和图 7 分别为 50 次 Monte Carlo 实验后三种算法的目标数目估计结果和 OSPA 距离结果, OSPA 距离




图5 MM-GIW-PHD滤波器状态估计图

是多目标跟踪中的一种评价估计误差距离的准则, 用于衡量算法估计精度, 计算式如下^[18]:

$$d_p^c(X, Z) = \left(\frac{1}{n} \left(\min_{\pi \in \Pi} \sum_{i=1}^m d^{(c)}(x_i, z_{\pi(i)})^p + c^p(n-m) \right) \right)^{1/p} \quad (55)$$

实验中设定参数 $p=2, c=100$ 。

从图 6 和图 7 可以看出, 所提算法在目标数目估计和位置估计上有更好的精度。在前 50s 两个目标做非机动运动时, MM-GIW-PHD 算法对目标数目的估计会受到较大影响, 对目标数目估计有较大波动, 而 MM-GIW-PHD-JTC 算法修正了这一缺陷, 通过改变式 (43) 中的 d_w 弱化第二类目标 PHD 的权重, 从而减小 MM 算法在非机动情况时较大的估计误差, 很好地收敛到真实的目标个数。50s 之后, GIW-PHD 算法由于对模式的不匹配, 导致估计误差增大, 而所提 MM-GIW-PHD-JTC 算法仍然可以较好的估计目标的状态和数目。

表 3 给出了 MM-GIW-PHD-JTC、GIW-PHD、MM-GIW-PHD 三种滤波算法性能的具体参数, 与图 6 和图 7 相对应, 改进算法与 MM-GIW-PHD 算法在性能上相比于 GIW-PHD 算法都有很大的提升, 而改进算法在目标数目估计和定位误差方面具有更好的性能, 另外相比

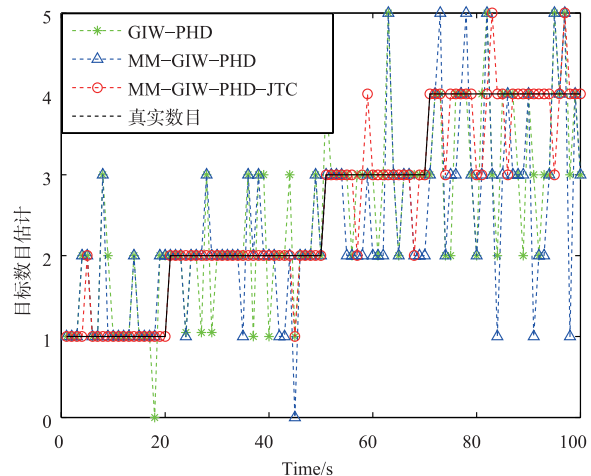


图6 平均目标数目估计图

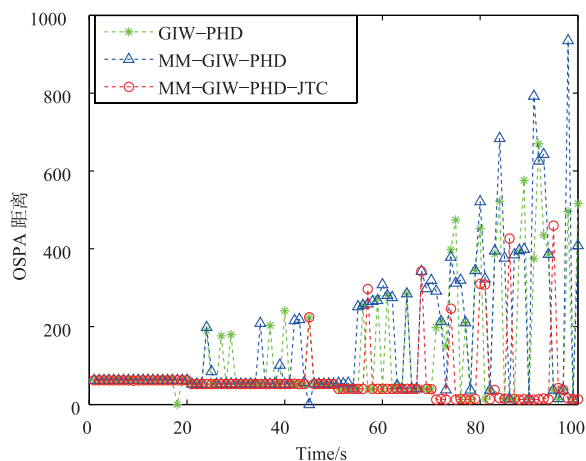


图7 平均OSPA距离图

于 MM-GIW-PHD 算法,改进算法具有更高的鲁棒性和数值稳定性.在时间开销上,改进算法增加了原 GIW-PHD 算法时间开销的 52.11%.

表 3 不同方法的滤波性能对比

算法	时间平均 数目估计	时间平均 OSPA/m	时间平均 开销/s
MM-GIW-PHD-JTC	2.29	38.51	1.08
GIW-PHD	2.02	72.64	0.71
MM-GIW-PHD	2.22	43.72	0.85

6 结论

本文在 GIW-PHD 滤波算法的基础上,将扩展目标的形态信息直接作为属性信息,加入到滤波算法中,给出了新的递推表达式.并在此基础上加入多模型算法,以充分利用目标类别信息能够确定更精确的目标运动模型这一优势,实现了对扩展目标的联合跟踪与分类.实验通过比较 GIW-PHD、MM-GIW-PHD 两种滤波方法,验证了所提算法能够提供更加精确和可靠的目标数目估计,具有实现更好的多目标跟踪能力.

参考文献

[1] 杨威,付耀文,龙建乾,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):1440-1448.
YANG Wei,FU Yao-wen, LONG Jian-qian, et al. The FIS-ST-based tracking techniques: A survey[J]. Acta Electronica Sinica, 2012, 40(7): 1440-1448. (in Chinese)

[2] 单甘霖,梅卫,王春平.联合目标跟踪与分类技术的进展及存在问题[J].兵工学报,2007,28(6):733-738.
SHAN Gan-lin, MEI Wei, WANG Chun-ping. Advance and challenge in joint target tracking and classification[J]. Acta Armamentarii, 2007, 28(6): 733-738. (in Chinese)

[3] LUNDQUIST C, ORGUNER U, GUSTAFSSON F. Extended target tracking using polynomials with applications to road-map estimation[J]. IEEE Transactions on Signal Processing, 2011, 59(1): 15-26.

[4] 顾新锋,简涛,何友,等.局部均匀背景中距离扩展目标的 GLRT 检测器及性能分析[J].电子学报,2013,41(12):2367-2373.
GU Xin-feng, JIAN Tao, HE You, et al. GLRT detector of range-spread target in local homogeneous background and its performance analysis[J]. Acta Electronica Sinica, 2013, 41(12): 2367-2373. (in Chinese)

[5] 简涛,苏峰,何友,等.复合高斯杂波下距离扩展目标的自适应检测[J].电子学报,2012,40(5):990-994.
JIAN Tao, SU Feng, HE You, et al. Adaptive range-spread target detectors for compound-Gaussian clutter[J]. Acta Electronica Sinica, 2012, 40(5): 990-994. (in Chinese)

[6] LAN J, LI X R. Joint tracking and classification of extended object using random matrix[A]. Proceedings of the 16th International Conference on Information Fusion[C]. Istanbul: IEEE, 2013. 1550-1557.

[7] LAN J, LI X R. Joint tracking and classification of non-ellipsoidal extended object using random matrix[A]. Proceedings of the 16th International Conference on Information Fusion[C]. Istanbul: IEEE, 2013. 1557-1565.

[8] CAO W, LAN J, LI X R. Extended object tracking and classification based on recursive joint decision and estimation[A]. Proceedings of the 16th International Conference on Information Fusion[C]. Istanbul: IEEE, 2013. 1670-1677.

[9] SUN L, LAN J, LI X R. Joint tracking and classification of extended object based on support functions[A]. Proceedings of the 17th International Conference on Information Fusion[C]. Salamanca: IEEE, 2014. 1-8.

[10] MAHLER R P S. Statistical Multisource-Multitarget Information Fusion[M]. Norwood, MA: Artech House, 2007.

[11] MAHLER R P S. Multitarget Bayes filtering via first-order multitarget moments[J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.


[12] MAHLER R P S. PHD filters for nonstandard targets, I: Extended targets[A]. Proceedings of the 8th International Conference on Information Fusion[C]. Pennsylvania: IEEE, 2009. 925-921.

[13] GRANSTROM K, ORGUNER U. A PHD filter for tracking multiple extended targets using random matrices[J]. IEEE Transactions on Signal Processing, 2012, 60(11): 5657-5671.

[14] MAGNANT C, GIREMUS A, GRIVEL E, et al. Multi-target tracking using a PHD-based Joint tracking and classification algorithm[A]. IEEE Radar Conference[C]. Phila-

- delphia:IEEE,2016. 1 – 6.
- [15] KOCH J W. Bayesian approach to extended object and cluster tracking using random matrices[J]. IEEE Transactions on Aerospace and Electronic Systems,2008,44(3): 1042 – 1059.
- [16] 张贤达. 矩阵分析与应用[M]. 北京:清华大学出版社, 2004. 214 – 218.
ZHANG Xian-da. Matrix Analysis and Applications[M]. Beijing: Tsinghua University Press, 2004. 214 – 218. (in Chinese)
- [17] 万九卿,梁旭,马志峰. 基于自适应观测模型交互多模型粒子滤波的红外机动目标跟踪[J]. 电子学报,2011, 39(3):602 – 608.
WAN Jiu-qing, LIANG Xu, MA Zhi-feng. Infrared maneuvering target tracking based on IMM-PF with adaptive observation model[J]. Acta Electronica Sinica, 2011, 39(3):602 – 608. (in Chinese)
- [18] 刘妹琴,兰剑. 目标跟踪前沿理论与应用[M]. 北京:科学出版社,2015. 106 – 109.
LIU Mei-qin, LAN Jian. Tracking Frontier Theory and Application[M]. Beijing: China Science Press, 2015. 106 – 109. (in Chinese)

作者简介



樊鹏飞 男. 1994 年出生,山西大同人. 空军工程大学信息与导航学院硕士研究生,从事信息融合、扩展目标跟踪方面的有关研究.
E-mail:13072972016@163.com



李鸿艳 女. 1971 年出生,陕西西安人. 空军工程大学信息与导航学院副教授、硕士生导师,主要从事信息融合与组网雷达情报处理、目标跟踪等方面的有关研究.
E-mail:lihongyan77@sohu.com