

基于数据压缩的多传感器 PHD 滤波算法*

谭顺成¹, 王国宏¹, 徐海全¹, 王娜^{1,2}

(1 海军航空工程学院信息融合技术研究所, 山东烟台 264000;

2 92941 部队, 辽宁葫芦岛 125000)

摘要:针对多传感器多目标跟踪, 提出一种基于数据压缩的多传感器概率假设密度(PHD)滤波算法, 解决串行多传感器 PHD(SMSPHD)滤波计算量过大的问题。算法首先利用数据压缩将多传感器量测数据转换成等效的单传感器量测数据, 然后在此基础上进行 PHD 滤波。仿真结果表明, 该算法可以实现对多目标的有效跟踪; 此外, 随传感器数目的增加, 该算法增加的计算量约为 SMSPHD 滤波算法增加的 4.3%。

关键词:数据压缩; 概率假设密度; 多传感器; 多目标跟踪

中图分类号: TP212 **文献标志码:** A

Multi-sensor PHD Filter Algorithm Based on Data Compression

TAN Shuncheng¹, WANG Guohong¹, XU Haiquan¹, WANG Na^{1,2}

(1 Research Institute of Information Fusion, Naval Aeronautical and Astronautical University, Shandong Yantai 264001, China;

2 No. 92941 Unit, Liaoning Huludao 125000, China)

Abstract: For multi-sensor multi-target tracking, a novel multi-sensor probability hypothesis density (PHD) filter based on data compression was proposed to solve the computation load of the serial multi-sensor PHD (SMSPHD) filter. With the proposed method, firstly, the multi-sensor measurements were equivalently converted to those from a single sensor by using data compression, then, the PHD filter was executed. The simulation results demonstrate that the proposed method can realize the tracking of multiple targets effectively. Moreover, as the increasing of the number of sensors, the added computational complexity of the proposed method is about 4.3% of that of the SMSPHD.

Keywords: data compressing; probability hypothesis density; multi-sensor; multi-target tracking

0 引言

基于多传感器信息融合技术的多目标跟踪算法越来越受到人们的普遍关注^[1-3]。传统的多传感器多目标跟踪算法主要有集中/分布式多传感器联合概率数据互联(MSJFDA)算法^[1,4]、分布式多传感器多假设跟踪(MSMHT)算法^[5-6]等。但是, MSJFDA 和 MSMHT 都是基于概率数据互联的算法, 当目标数目较多或杂波密度较大时, 其算法的复杂度与计算量急剧增长^[7]。因此, 这些算法往往要受到实际应用的限制。

基于随机有限集(RFS)理论的概率假设密度(PHD)滤波, 是杂波环境下进行多目标跟踪的一种有效方法^[7-11]。文献[12]将 PHD 滤波扩展到多传感器系统, 提出了集中式串行处理结构的多传感器多目标跟踪的 PHD(SMSPHD)滤波方法。然而, 这种算

法只是简单的利用各个传感器得到的量测和 PHD 滤波更新方程对各粒子权重进行重复的更新, 因此, 其计算量几乎随传感器数目的增长而成倍增长。

文中针对以上情况, 提出一种基于数据压缩的多传感器 PHD 滤波算法, 其基本思想是先对多传感器量测数据进行数据压缩得到等效的单传感器量测数据, 然后再利用等效的量测数据进行 PHD 滤波。仿真结果表明了该算法的有效性。

1 RFS 框架下的多目标跟踪

1.1 多目标跟踪的 RFS 模型

以 E_s 和 E_o 分别表示状态空间和观测空间, 定义两个随机集的随机过程 $\mathbf{X} = \{\mathbf{X}_k | k \in N\}$ 和 $\mathbf{Z} = \{\mathbf{Z}_k | k \in N^+\}$, 过程 \mathbf{X} 和过程 \mathbf{Z} 分别称为状态过程和

* 收稿日期: 2010-05-22

基金项目: 国家自然科学基金(60972159, 61032001, 61002006); 航空科学基金资助

作者简介: 谭顺成(1985-), 男, 湖南湘潭人, 博士研究生, 研究方向: 雷达数据处理。

量测过程, $\mathbf{X}_k = \{\mathbf{x}_{1,k}, \dots, \mathbf{x}_{M_k,k}\} \subset \mathbf{E}_s$ 和 $\mathbf{Z}_k = \{\mathbf{z}_{1,k}, \dots, \mathbf{z}_{N_k,k}\} \subset \mathbf{E}_o$ 分别表示 k 时刻的多目标状态 RFS 和多目标量测 RFS, 而 $\mathbf{x}_{i,k} (i=1, \dots, M_k)$ 和 $\mathbf{z}_{j,k} (j=1, \dots, N_k)$ 分别表示单目标状态和单目标量测或杂波, M_k 和 N_k 分别为 k 时刻的目标数目和量测数目。

给定 $k-1$ 时刻的多目标状态 RFS \mathbf{X}_{k-1} , 将任意 $\mathbf{x}_{k-1} \in \mathbf{X}_{k-1}$ 在 k 时刻的状态建模为 RFS $S_{k|k-1}(\mathbf{x}_{k-1})$, 当目标持续存在时其取值为 $\{\mathbf{x}_k\}$, 目标消失时为 \emptyset 。则 k 时刻的多目标状态 RFS \mathbf{X}_k 由持续存在目标、衍生目标以及新生目标联合给出, 即:

$$\mathbf{X}_k = \left[\bigcup_{\mathbf{x}_{k-1} \in \mathbf{X}_{k-1}} S_{k|k-1}(\mathbf{x}_{k-1}) \right] \cup \left[\bigcup_{\mathbf{x}_{k-1} \in \mathbf{X}_{k-1}} B_{k|k-1}(\mathbf{x}_{k-1}) \right] \cup \Gamma_k \quad (1)$$

其中: $B_{k|k-1}(\mathbf{x}_{k-1})$ 为从 $\mathbf{x}_{k-1} \in \mathbf{X}_{k-1}$ 衍生新目标的 RFS; Γ_k 为新目标出现的 RFS。任意 $\mathbf{x}_k \in \mathbf{X}_k$ 产生一个 RFS $\Theta_k(\mathbf{x}_k)$, 当目标被检测到其取值为 $\{\mathbf{z}_k\}$, 目标未被检测到时为 \emptyset , 则多目标量测 RFS:

$$\mathbf{Z}_k = K_k \cup \left[\bigcup_{\mathbf{x}_k \in \mathbf{X}_k} \Theta_k(\mathbf{x}_k) \right] \quad (2)$$

其中 K_k 表示虚警或杂波的 RFS。

1.2 PHD 滤波

给定单目标状态向量 \mathbf{x} 和直到 k 时刻所有量测的集合 $Z_{1:k}$, PHD 滤波的预测和更新方程分别如式 (3) 和式 (4) 所示^[8]:

$$v_{k|k-1}(\mathbf{x} | \mathbf{Z}_{1:k-1}) = \gamma_k(\mathbf{x}) + \int \Phi_{k|k-1}(\mathbf{x} | \mathbf{x}_{k-1}) \times v_{k-1|k-1}(\mathbf{x}_{k-1} | \mathbf{Z}_{1:k-1}) d\mathbf{x}_{k-1} \quad (3)$$

$$v_{k|k}(\mathbf{x} | \mathbf{Z}_{1:k}) = \left[v(\mathbf{x}) + \sum_{\mathbf{z} \in Z_k} \frac{\psi_{k,z}(\mathbf{x})}{\kappa_k(\mathbf{z}) + \langle D_{k|k-1}, \psi_{k,z} \rangle} \right] \times v_{k|k-1}(\mathbf{x} | \mathbf{Z}_{1:k-1}) \quad (4)$$

其中: $\Phi_{k|k-1}(\mathbf{x} | \mathbf{x}_{k-1}) = e_{k|k-1}(\mathbf{x}_{k-1}) \times f_{k|k-1}(\mathbf{x} | \mathbf{x}_{k-1}) + b_{k|k-1}(\mathbf{x} | \mathbf{x}_{k-1})$, $v(\mathbf{x}) = 1 - P_D(\mathbf{x})$, $\kappa_k(\mathbf{z}) = \lambda_k c_k(\mathbf{z})$, $\psi_{k,z}(\mathbf{x}) = P_D(\mathbf{x}) g_k(\mathbf{z} | \mathbf{x})$ 。

在 PHD 滤波的预测和更新方程中, $\gamma_k(\cdot)$ 和 $b_{k|k-1}(\cdot | \mathbf{x}_{k-1})$ 分别表示 k 时刻 RFS Γ_k 和 $B_{k|k-1}(\mathbf{x}_{k-1})$ 的 PHD, $e_{k|k-1}(\mathbf{x}_{k-1})$ 表示 $k-1$ 时刻状态为 \mathbf{x}_{k-1} 的目标持续存在到 k 时刻的概率, $P_D(\mathbf{x})$ 为 k 时刻状态为 \mathbf{x} 的目标被检测到的概率, $f_{k|k-1}(\cdot | \cdot)$ 和 $g_k(\cdot | \cdot)$ 分别为单目标的状态转移函数和量测似然函数, λ_k 为杂波数目服从泊松分布的期望值, 而 $c_k(\cdot)$ 为杂波点在整个观测空间上的概率密度分布, 符号 $\langle \cdot, \cdot \rangle$ 为内积, 定义为:

$$\langle v_{k|k}, \varphi \rangle = \int v_{k|k}(\mathbf{x} | \mathbf{Z}_{1:k}) \varphi(\mathbf{x}) d\mathbf{x} \quad (5)$$

2 基于数据压缩的 PHD 粒子滤波算法

2.1 数据压缩

以两个传感器组成的多传感器系统为例, 假设每个传感器都能提供目标的距离和角度信息, 数据压缩的基本过程如下^[1]:

假设 $\mathbf{Z}_k^1 = \{\mathbf{z}_{1,k}^1, \dots, \mathbf{z}_{N_{1,k}^1,k}^1\}$ 和 $\mathbf{Z}_k^2 = \{\mathbf{z}_{1,k}^2, \dots, \mathbf{z}_{N_{2,k}^2,k}^2\}$ 分别表示 k 时刻传感器 1 和传感器 2 的量测集, 其中 $N_{1,k}$ 和 $N_{2,k}$ 为 k 时刻传感器 1 和传感器 2 得到的量测数目, $\mathbf{z}_{i,k}^1 = (\rho_{i,k}^1, \theta_{i,k}^1)^\top (i=1, \dots, N_{1,k})$ 和 $\mathbf{z}_{j,k}^2 = (\rho_{j,k}^2, \theta_{j,k}^2)^\top (j=1, \dots, N_{2,k})$ 分别表示传感器 1 和传感器 2 在 k 时刻的第 i 和第 j 个量测。若:

$$\begin{cases} |\rho_{i,k}^1 - \rho_{j,k}^2| \leq \rho_T \\ |\theta_{i,k}^1 - \theta_{j,k}^2| \leq \theta_T \end{cases}, i=1, \dots, N_{1,k}, j=1, \dots, N_{2,k} \quad (6)$$

则认为传感器 1 的量测 $\mathbf{z}_{i,k}^1$ 与传感器 2 的量测 $\mathbf{z}_{j,k}^2$ 互联, 其中 ρ_T 和 θ_T 为相关波门。如果传感器 1 的某个量测与传感器 2 的多个量测互联, 则采用最近邻域法选取最近的量测点进行互联。

对于任意一组互联的量测 $\mathbf{z}_{i,k}^1$ 与 $\mathbf{z}_{j,k}^2$, 按照下式进行数据压缩, 得到一个等效量测:

$$\begin{cases} \hat{\rho} = \frac{1}{\sigma_{1,\rho}^2 + \sigma_{2,\rho}^2} (\sigma_{2,\rho}^2 \cdot \rho_{i,k}^1 + \sigma_{1,\rho}^2 \cdot \rho_{j,k}^2) \\ \hat{\theta} = \frac{1}{\sigma_{1,\theta}^2 + \sigma_{2,\theta}^2} (\sigma_{2,\theta}^2 \cdot \theta_{i,k}^1 + \sigma_{1,\theta}^2 \cdot \theta_{j,k}^2) \end{cases} \quad (7)$$

和等效的量测误差:

$$\begin{cases} \hat{\sigma}_\rho^2 = \left(\frac{1}{\sigma_{1,\rho}^2} + \frac{1}{\sigma_{2,\rho}^2} \right)^{-1} \\ \hat{\sigma}_\theta^2 = \left(\frac{1}{\sigma_{1,\theta}^2} + \frac{1}{\sigma_{2,\theta}^2} \right)^{-1} \end{cases} \quad (8)$$

其中: $\sigma_{i,\rho}^2$ 和 $\sigma_{i,\theta}^2$ 分别为第 $i (i=1, 2)$ 个传感器的测距和测角方差; $\hat{\sigma}_\rho^2$ 和 $\hat{\sigma}_\theta^2$ 为压缩后的距离和角度方差。该方法可以容易推广到 3 个以上多传感器系统。从式 (7) 和式 (8) 可以看出: 数据压缩的本质是各传感器的量测按精度加权, 压缩后的等效量测提高了精度, 即:

$$\begin{cases} \hat{\sigma}_\rho^2 \leq \min\{\sigma_{1,\rho}^2, \sigma_{2,\rho}^2\} \\ \hat{\sigma}_\theta^2 \leq \min\{\sigma_{1,\theta}^2, \sigma_{2,\theta}^2\} \end{cases} \quad (9)$$

2.2 PHD 粒子滤波算法实现

给定 $k-1$ 时刻粒子集 $\{\mathbf{x}_{k-1}^i, \omega_{k-1}^i\}_{i=1}^{L_{k-1}}$, 基于 PHD 粒子滤波算法的步骤如下所述:

1) 预测: 根据建议分布 $q_k(\cdot | \mathbf{x}_{k-1}^i, \mathbf{Z}_k)$ 和 $p_k(\cdot | \mathbf{Z}_k)$ 进行粒子采样:

$$\mathbf{x}_{k-1}^i \sim \begin{cases} q_k(\cdot | \mathbf{x}_{k-1}^i, \mathbf{Z}_k), i=1, \dots, L_{k-1} \\ p_k(\cdot | \mathbf{Z}_k), i=L_{k-1}+1, \dots, L_{k-1}+J_k \end{cases} \quad (10)$$

并计算各粒子权重:

$$w_{k|k-1}^i = \begin{cases} \frac{\Phi_{k|k-1}(\mathbf{x}_{k|k-1}^i | \mathbf{x}_{k-1}^i)}{q_k(\mathbf{x}_{k|k-1}^i | \mathbf{x}_{k-1}^i, \mathbf{Z}_k)}, & i=1, \dots, L_{k-1} \\ \frac{\gamma_k(\mathbf{x}_{k|k-1}^i)}{J_k p_k(\mathbf{x}_{k|k-1}^i | \mathbf{Z}_k)}, & i=L_{k-1}+1, \dots, L_{k-1}+J_k \end{cases} \quad (11)$$

得到粒子集 $\{\mathbf{x}_{k|k-1}^i, w_{k|k-1}^i\}_{i=1}^{L_{k-1}+J_k}$ 。

2)更新:将 k 时刻的多传感器量测数据进行数据压缩,得到一个等效的量测集 \mathbf{Z}_k 和相应的等效量测误差,进行各粒子的权重更新:

$$w_{k|k}^i = \left[v(\mathbf{x}_{k|k-1}^i) + \sum_{z \in \mathbf{Z}_k} \frac{\psi_{k,z}(\mathbf{x}_{k|k-1}^i)}{C_k(\mathbf{z})} \right] w_{k|k-1}^i \quad (12)$$

$i=1, \dots, L_{k-1}+J_k$

其中:

$$C_k(\mathbf{z}) = \sum_{i=1}^{L_{k-1}+J_k} \psi_{k,z}(\mathbf{x}_{k|k-1}^i) w_{k|k-1}^i \quad (13)$$

3)重采样:对粒子集 $\{\mathbf{x}_{k|k-1}^i, w_{k|k-1}^i / \hat{N}_{k|k}\}_{i=1}^{L_{k-1}+J_k}$ 进行重采样得到新的粒子集 $\{\mathbf{x}_k^i, w_k^i / \hat{N}_{k|k}\}_{i=1}^{L_{k-1}+J_k}$, 其中 $\hat{N}_{k|k} = \sum_{i=1}^{L_{k-1}+J_k} w_{k|k-1}^i$ 。

4)聚类分析:对重采样后的粒子进行聚类分析得到目标状态估计 $\hat{\mathbf{X}}_k$ 。

3 试验仿真

假定在任何观测时间内,目标都在 $[-200, 200] \times [-200, 200]$ 的二维区域内运动,且目标可以在该区域随机出现和消失。总仿真时间为 50 s,每个目标的运动都服从线性高斯模型,即:

$$\mathbf{x}_k = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{x}_{k-1} + \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix} \begin{bmatrix} v_{1,k} \\ v_{2,k} \end{bmatrix} \quad (14)$$

其中: $\mathbf{x}_k = [x_k \dot{x}_k y_k \dot{y}_k]^T$, (x_k, y_k) 和 (\dot{x}_k, \dot{y}_k) 分别表示目标位置、速度信息; $T=1s$ 为传感器扫描周期;过程噪声 $v_{1,k}$ 和 $v_{2,k}$ 是相互独立的零均值高斯噪声,其标准差分别为 1 和 0.1。目标持续存在概率 $e_{k|k-1}$ 与目标状态无关且等于 0.95。假设目标的出现服从密度函数为 $\gamma_k(\mathbf{x}) = 0.2N(\mathbf{x} | \mathbf{x}_0, \mathbf{Q}_b)$ 的泊松模型,这里 $N(\cdot | \mathbf{x}_0, \mathbf{Q}_b)$ 表示均值为 \mathbf{x}_0 , 协方差为 \mathbf{Q}_b 的高斯分布,这里设 $\mathbf{x}_0 = [0 \ 2 \ 0 \ -2]^T$ 和 $\mathbf{Q}_b = \text{diag}([10 \ 5 \ 10 \ 5])$ 。

假设融合中心位于点 (x_s, y_s) , 传感器可提供目标的距离 R_k^i 和方位角 θ_k^i 信息,令 $\mathbf{z}_k^i = [R_k^i, \theta_k^i]^T$, 则

$$\mathbf{z}_k^i = \begin{bmatrix} \sqrt{(x_k - x_s)^2 + (y_k - y_s)^2} \\ \arctan \frac{x_k - x_s}{y_k - y_s} \end{bmatrix} + \begin{bmatrix} w_{1,k}^i \\ w_{2,k}^i \end{bmatrix}, i=1, 2 \quad (15)$$

其中,量测噪声 $w_{1,k}^i$ 和 $w_{2,k}^i$ 是相互独立的零均值高斯噪声,并且量测噪声与过程噪声相互独立。目标检测概率 P_D 设为 0.95, 每一个时刻的杂波均匀分布在 $[-\pi, \pi] \times [0, 200]$ 的观测空间内,其个数服从期望为 10 的泊松分布。目标 1 在 $t=1s$ 出现, $t=40s$ 消失,初始状态为 $[0 \ -4.5 \ 0 \ -2.5]^T$; 目标 2 在 $t=5s$ 出现, $t=30s$ 消失,初始状态为 $[0 \ -2 \ 0 \ 3.5]^T$; 目标 3 在 $t=25s$ 出现, $t=50s$ 消失,初始状态为 $[0 \ 3.5 \ 0 \ -4]^T$ 。

其它仿真参数设置如下:代表一个目标所需的粒子数 $N_0=2000$, 用于搜索新目标的粒子数 $J_k=5000$, 建议分布 q_k 和 p_k 分别取 $f_{k|k-1}$ 和 $N(\cdot | \mathbf{x}_0, \mathbf{Q}_b)$, 假设没有衍生目标产生,即 $b_{k|k-1}=0$, 数据关联中的门概率 $P_G=0.95$, 传感器 1 和传感器 2 的测距和测角标准差分别为 $w_{1,k}^1 = w_{1,k}^2 = 2$ 和 $w_{2,k}^1 = w_{2,k}^2 = 0.05$, 融合中心位于点 $(0, -100)$ 。

图 1 为单传感器 PHD 滤波算法、SMSPHD 滤波算法以及文中算法的多目标跟踪误差比较,其中图 1(a)为单次仿真的多目标跟踪误差,为了更加直观的分析算法的跟踪性能,图 1(b)给出了 30 次仿真过程中各算法均能准确估计目标数目时的多目标跟踪误差平均值。





图 1 多目标跟踪误差

图 2 为三种算法估计的目标数目与真实的目标数目相比较。图 1(a)中某个时刻的 Wasserstein 距离^[13]突然增大表示该时刻估计的目标数目有误(如图 2 所示)或估计的目标状态与真实的目标状态相差较大。从图 1 和图 2

可以看出,与单传感器 PHD 滤波算法和 SMSPHD 滤波算法相比,文中算法能更加准确的估计目标数目和提高目标跟踪精度。

假设单传感器 PHD 滤波算法的计算量为 1,图 3 给出了相同条件下 SMSPHD 滤波算法与文中算法的计算量随传感器数目增长的变化情况。

从图中可以看出,SMSPHD 滤波算法的计算量几乎随传感器的增加而成倍增长,而文中提出的算法仅增加较小的计算量。

4 结论

针对多传感器多目标跟踪问题,文中应用数据压缩将多传感器量测数据转换成等效的单传感器量测数据,然后

在此基础上结合 PHD 滤波提出一种基于数据压缩的多传感器 PHD 滤波算法。仿真结果表明,该算法可以在极大的减小 SMSPHD 滤波算法计算量的同时有效的实现杂波环境下的多目标跟踪。

参考文献:

[1] 何友, 王国宏, 陆大绘, 等. 多传感器信息融合及应用 [M]. 2 版. 北京: 电子工业出版社, 2007.

[2] M Duarte, Y H Hu. Vehicle classification in distributed sensor networks[J]. Journal of Parallel and Distributed Computing, 2004, 64(7): 826-838.




图 2 真实目标数目与各算法估计目标数目




图 3 计算量随传感器数目增长的变化

[3] C David, E Deborah, S Mani. Overview of sensor networks[J]. IEEE Computer, Special Issue in Sensor Networks, 2004,37(8):4-49.

[4] K Chang, C Chong, Y Bar-Shalom. Joint probabilistic data association in distributed sensor networks [J]. IEEE Trans. on Automatic Control, 1986, AC-31(10): 889-897.

[5] S S Blackman. Multiple hypothesis tracking for multiple targets tracking[J]. IEEE Transactions on Aerospace and Electronic Systems Magazine, 2004, 19(1): 5-18.

[6] S W Joo, R Chellappa, A multiple-hypothesis approach for multiobject visual tracking[J]. IEEE Transactions on Image Processing, 2007, 16(11): 2849-2854.

[7] K Panta, B Vo, S Singh. Novel data association schemes for the probability hypothesis density filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2007, 43(2): 556-570.

[8] R Mahler. Multitarget Bayes filtering via first-order multi-target moments[J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.

[9] B Vo, S Singh, A Doucet. Sequential Monte Carlo methods for multi-target filtering with random finite sets[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(4): 1224-1245.

[10] B Vo, W K Ma. The Gaussian mixture probability hypothesis density filter[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091-4104.

[11] L Lin, Y Bar-Shalom, T Kirubarajan. Track labeling and the PHD filter for multitarget tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2006, 42(3): 778-795.

[12] K Punithakumar, T Kirubarajan, A Sinha. Multiple-model probability hypothesis density filter for tracking maneuvering targets [J]. Transactions on Aerospace and Electronic Systems, 2008, 44(1): 87-98.

[13] J Hoffman, R Mahler. Multi-target misses distance via optimal assignment[J]. IEEE Transactions on Systems, Man and Cybernetics, 2004, A-34(3): 327-336.