

多元假设检验 GMPHD 轨迹跟踪

黄志蓓^{①②} 孙树岩^① 吴健康^①

^①(中国科学院研究生院信息学院 北京 100190)

^②(中国科学院电子学研究所 北京 100190)

摘要: 由于在军事和民事领域逐步广泛的应用, 数目不定的多目标跟踪技术正受到越来越多的关注。概率假设密度(PHD)滤波方法, 特别是具有闭式递归的高斯混合概率假设密度(GMPHD)技术, 在噪声和漏警等影响下仍能形成优越的群目标跟踪性能。然而 PHD 滤波器并不能实现多目标航迹跟踪, 而与其与传统数据互联的结合, 复杂度高且跟踪效果不尽如人意。在该文中, 各目标的航迹信息以假设形式表述, 数据互联则是通过使用经典的多元假设检测方法判决假设矩阵实现。其与 GMPHD 的结合不仅实现了数据互联和轨迹管理, 还因为积累时间信息大大降低了杂波干扰的影响。实验结果证明, 该算法可以对多个目标所形成的轨迹实施正确跟踪, 同时, 计算量大幅度降低带来了跟踪系统可实现性的提高。

关键词: 多目标航迹跟踪; 贝叶斯滤波; 概率假设密度; 高斯混合模型; 多元假设检验

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2010)06-1289-06

DOI: 10.3724/SP.J.1146.2008.01387

Multiple Hypotheses Detection with Gaussian Mixture Probability Hypothesis Density Filter for Multi-target Trajectory Tracking

Huang Zhi-bei^{①②} Sun Shu-yan^① Wu Jian-kang^①

^①(School of Information Science and Engineering, Graduate University of Chinese Academy of Sciences, Beijing 100190, China)

^②(Institute of Electronics, Chinese Academy of Sciences, Beijing 100190, China)

Abstract: Multi-target tracking is becoming one of most focusing research topics because of the modern military affair requirements as well as civil developments. Among all the techniques, Probability Hypothesis Density(PHD) filtering approach, especially Gaussian Mixture PHD(GMPHD) filter, which has a closed form recursion, has shown its advantages in tracking unknown number of targets despite the impact of noise and missing detection etc. Existing PHD trajectory tracking methods combining PHD filter, which can not estimate the trajectories of multi-target alone, with traditional data association, are computationally expensive and almost intractable. In this paper, a brand new multi-target trajectory tracking algorithm based on random finite set theory is brought forward by adopting classical signal detection technique along with GMPHD filter. Using hypotheses representing the trajectory information, data association is accomplished through the hypothesis matrix judging on the same basement as track managing function. The simulation results suggest that this algorithm not only significantly alleviates the heavy computing load, but also performs multi-target trajectory tracking effectively in the meantime.

Key words: Multi-target trajectory tracking; Bayesian filtering; Probability Hypothesis Density(PHD); Gaussian mixture model; Multiple hypotheses detection

1 引言

在多目标跟踪场景中, 不仅各目标状态会随时间变化, 而且目标数目也会随着新目标的出现、旧目标的消失而改变。因此, 每个时刻多目标跟踪的任务就是在噪声和杂波的干扰下联合估计目标的

数目和目标的状态。现有的多目标轨迹跟踪方法需要传统的数据互联理论和滤波技术共同完成。传统方法如多假设跟踪(Multiple Hypotheses Tracking, MHT)^[1-4]、联合概率数据互联(Joint Probabilistic Data Association, JPDA)^[5]和最近邻(Nearest Neighbor, NN)^[4]等, 对于未知且时变的目标, 目标数目的不确定性让传统的状态空间方法难以处理。另外, 随着目标和量测数量的增长, 数据互联的数

2008-10-27 收到, 2010-04-22 改回

国家自然科学基金(60772154)资助项目

通信作者: 黄志蓓 zhphuang@gmail.com

目和计算复杂度也随之呈指数级增长。

Mahler 是第一个系统地使用有限集合统计 (Finite Set Statistics, FISST)^[6-8] 理论对数目随机的多目标跟踪建立数学描述并给出求解的方法。把目标的状态和传感器的量测表达为随机有限集合 (Random Finite Set, RFS) 的形式, 就可以直接套用贝叶斯滤波理论框架对时变的、受到各种干扰的目标个数和目标状态进行联合估计。但是有限集合统计还是面临着一个难题—计算复杂度。为了解决这一难题, Mahler 提出了以概率假设密度 (Probability Hypothesis Density, PHD)^[8,9] 作为目标的一阶估计。虽然已经大大简化了计算过程, 然而 PHD 递推中还是因为涉及多重积分故不存在闭式解。通常的解决方案是使用序列蒙特卡罗方法计算后验概率, 例如 Sidenblad^[10] 和 Vo 等^[11] 所实现的粒子 PHD 滤波器。但是这种方法容易在粒子的聚类数目不等于真实目标数目时作出错误的状态估计, 而且计算量依然很大。最近 Vo 等证明了在一定条件下, 若系统符合高斯混合 (Gaussian Mixture, GM) 模型, PHD 递推方程存在闭式解^[12], 进一步简化了运算因而实现简便。

但是在对多个目标进行跟踪时, 无论是以粒子滤波方法实现的 PHD 滤波还是高斯混合 PHD (GMPHD) 滤波, 甚至是使用部分高阶矩信息的 CPHD (Cardinalized PHD) 滤波^[9-11,13], 由于 RFS 形式的随机变量不涉及顺序或身份信息, 所以无法完成轨迹跟踪。Lin 和 Bar-Shalom 等人^[14] 提出的 TLPHDRC (Track Labeling PHD in a Resolution Cell) 方式, 将监测区域分割为数个有限解析单元, 并对每个单元中的目标使用一个跟踪器估计状态。Vo 等人^[15] 则结合 PHD 滤波和 MHT 技术 (MHT-with-PHD) 跟踪数目不定的多目标轨迹。无论是哪个方法都具有相当大的计算复杂度。本文利用经典信号检测理论中的多元假设检验方法保存轨迹信息, 同时使用 GMPHD 滤波估计目标数目和状态, 很好地实现了多个目标轨迹跟踪的同时, 减小了对计算能力的要求, 大幅度缩短了算法运算时间。

本文的第 2 节给出随机有限集合、概率假设密度及其在高斯混合模型下的数学定义和 GMPHD 滤波的数学模型, 第 3 节引入基于 GMPHD 和多元假设检验的航迹跟踪方法, 实验仿真结果将在第 4 节给出, 最后是结论。

2 GMPHD 理论框架

在多目标情形下, 时刻 k 得到的目标状态和量

测可表示为有限集合的形式: $X_k = \{x_{k,1}, \dots, x_{k,M(k)}\} \in \mathcal{F}(\mathcal{X})$, $Z_k = \{z_{k,1}, \dots, z_{k,N(k)}\} \in \mathcal{F}(\mathcal{Z})$, 其中, $\mathcal{F}(\mathcal{X})$ 和 $\mathcal{F}(\mathcal{Z})$ 分别为在空间 \mathcal{X} 和 \mathcal{Z} 上形成的所有子集组成的集合; $M(k)$ 和 $N(k)$ 分别是第 k 个时刻目标数量和接收到的量测数量, 由于新目标的出现、旧目标的消失、杂波和漏警等情况的存在, 它们也是时变的随机变量。这时多目标的跟踪问题就转化成了 (多目标) 状态空间为 $\mathcal{F}(\mathcal{X})$ 、观测空间为 $\mathcal{F}(\mathcal{Z})$ 的滤波问题。

如果只是简单照搬单目标跟踪的使用后验概率密度估计目标状态的模式, 就需要在 $\mathcal{F}(\mathcal{X})$ 上进行多重积分, 由于维度的不确定性, 计算上很难处理。类同于常增益的卡尔曼滤波方法, 如果只使用均值进行递推, 就能大大简化计算。对于在 \mathcal{X} 上的 RFS X , 若概率分布为 P , 其一阶矩是在 \mathcal{X} 上被称为强度的非负函数 v , 且满足: 对于每个在 \mathcal{X} 上的区域 $S \subseteq \mathcal{X}$, 有

$$\int |X \cap S| P(dX) = \int_S v(x) dx \quad (1)$$

即 v 在某一区域 S 上的积分是位于该区域内的 RFS X 元素数目的数学期望。 v 被称为概率假设密度 (PHD)^[8,10]。在一定假设下, 多目标的预测方程和更新方程就可以转化为 PHD 递推方程。由于 PHD 是建立在单一目标状态空间 \mathcal{X} 上的函数, 所以较需要在 $\mathcal{F}(\mathcal{X})$ 上运算的多目标贝叶斯递归方程来说, 计算量会变小很多。而 PHD 函数的局部极大值就是集合 X 中多变量强度最集中的点, 因此可以用来估计集合中参量的状态。

可以证明, 在线性高斯模型系统条件下, 如果先验概率为高斯混合分布, 那么在 PHD 递推过程中所有后续产生的预测后验强度和后验强度都符合高斯混合模型。计算出高斯混合的预测后验强度 $h_{k+1|k}$ 和后验强度 h_k 后, 相应的目标数量就可以由各自的强度积分得到, 而对目标的状态估值直接就是各自强度的均值^[12]。即, 若系统满足以下假设:

假设 1 每个目标的运动和量测都是彼此独立的。

假设 2 杂波服从泊松分布, 并且它与实际目标产生的量测不相关。

假设 3 多目标的预测概率分布是泊松分布。

假设 4 系统的动态方程和观测方程是线性高斯模型。

$$f_{k+1|k}(\mathbf{x}_{k+1} | \mathbf{x}_k) = N(\mathbf{x}_{k+1}; \mathbf{F}_k \mathbf{x}_k, \mathbf{Q}_k) \quad (2)$$

$$g_k(\mathbf{z} | \mathbf{x}_k) = N(\mathbf{z}; \mathbf{H}_k \mathbf{x}_k, \mathbf{R}_k) \quad (3)$$

其中 $N(\mathbf{x}; \mathbf{m}, \mathbf{C})$ 为均值 \mathbf{m} , 协方差矩阵为 \mathbf{C} 的高斯分布, \mathbf{x}_k 为第 k 个时刻的目标状态, \mathbf{z} 为观测值,

F_k 、 H_k 是系统转移函数和测量函数, Q_k 、 R_k 是系统噪声和观测噪声的协方差。

假设 5 新目标 RFS 的强度是高斯混合形式:

$$b_k(\mathbf{x}_k) = \sum_{i=1}^{J_{b,k}} w_{b,k}^{(i)} N(\mathbf{x}_k; \mathbf{m}_{b,k}^{(i)}, \mathbf{C}_{b,k}^{(i)}) \quad (4)$$

其中除了均值和方差外, $w_{b,k}^{(i)}$ 为权重因子, $J_{b,k}$ 为新生高斯项的个数。

假设 6 旧目标的存在概率 $P_{S,k+1}$ 和目标检测概率 $P_{D,k}$ 的大小与状态无关。

$$P_{D,k}(\mathbf{x}_k) = P_{D,k} \quad (5)$$

$$P_{S,k+1|k}(\mathbf{x}_k) = P_{S,k+1} \quad (6)$$

假设 7 后验强度也满足高斯混合分布:

$$v_k(\mathbf{x}) = \sum_{i=1}^{J_k} w_k^{(i)} N(\mathbf{x}; \mathbf{m}_k^{(i)}, \mathbf{C}_k^{(i)}) \quad (7)$$

则 PHD 预测强度是由继续存在的旧目标 RFS 的强度和新产生目标 RFS 的强度叠加而成。

$$v_{k+1|k}(\mathbf{x}) = v_{S,k+1|k}(\mathbf{x}) + b_{k+1}(\mathbf{x}) \quad (8)$$

其中式(8)中前一项为旧目标 RFS 的强度:

$$v_{S,k+1|k}(\mathbf{x}) = P_{S,k+1} \sum_{j=1}^{J_k} w_k^{(j)} N(\mathbf{x}; \mathbf{m}_{S,k+1|k}^{(j)}, \mathbf{C}_{S,k+1|k}^{(j)}) \quad (9)$$

$$\mathbf{m}_{S,k+1|k}^{(j)} = \mathbf{F}_k \mathbf{m}_k^{(j)} \quad (10)$$

$$\mathbf{C}_{S,k+1|k}^{(j)} = \mathbf{Q}_k + \mathbf{F}_k \mathbf{C}_k^{(j)} \mathbf{F}_k^T \quad (11)$$

在更新阶段, 进一步将预测强度合并表示为高斯混合形式:

$$v_{k+1|k}(\mathbf{x}) = \sum_{j=1}^{J_{k+1|k}} w_{k+1|k}^{(j)} N(\mathbf{x}; \mathbf{m}_{k+1|k}^{(j)}, \mathbf{C}_{k+1|k}^{(j)}) \quad (12)$$

那么系统的后验强度也是高斯混合。

$$v_{k+1}(\mathbf{x}) = (1 - P_{D,k+1}) v_{k+1|k}(\mathbf{x}) + \sum_{z \in \mathbf{Z}_{k+1}} v_{D,k+1}(\mathbf{x}; z) \quad (13)$$

式(13)中后一部分量测 RFS 的强度由 $|\mathbf{Z}_{k+1}|$ 个单独产生的量测 $z \in \mathbf{Z}_{k+1}$ 强度相加而成。

$$v_{D,k+1}(\mathbf{x}; z) = \sum_{j=1}^{J_{k+1|k}} w_{k+1|k}^{(j)}(z) N(\mathbf{x}; \mathbf{m}_{k+1|k+1}^{(j)}, \mathbf{C}_{k+1|k+1}^{(j)}) \quad (14)$$

$$w_{k+1|k}^{(j)}(z) = \frac{P_{D,k+1} w_{k+1|k}^{(j)} q_{k+1}^{(j)}(z)}{\mathcal{K}_{k+1}(z) + P_{D,k+1} \sum_{i=1}^{J_{k+1|k}} w_{k+1|k}^{(i)} q_{k+1}^{(i)}(z)} \quad (15)$$

其中 $\mathcal{K}_{k+1}(z)$ 为 $k+1$ 时刻的杂波强度, 其余的参数计算如下:

$$q_{k+1}^{(j)}(z) = N(z; \mathbf{H}_{k+1} \mathbf{m}_{k+1|k}^{(j)}, \mathbf{R}_{k+1} + \mathbf{H}_{k+1} \mathbf{C}_{k+1|k}^{(j)} \mathbf{H}_{k+1}^T) \quad (16)$$

$$\mathbf{m}_{k+1|k+1}^{(j)}(z) = \mathbf{m}_{k+1|k}^{(j)} + \mathbf{K}_{k+1}^{(j)} (z - \mathbf{H}_{k+1} \mathbf{m}_{k+1|k}^{(j)}) \quad (17)$$

$$\mathbf{C}_{k+1|k+1}^{(j)} = [\mathbf{I} - \mathbf{K}_{k+1}^{(j)} \mathbf{H}_{k+1}] \mathbf{C}_{k+1|k}^{(j)} \quad (18)$$

$$\mathbf{K}_{k+1}^{(j)} = \mathbf{C}_{k+1|k}^{(j)} \mathbf{H}_{k+1}^T (\mathbf{H}_{k+1} \mathbf{C}_{k+1|k}^{(j)} \mathbf{H}_{k+1}^T + \mathbf{R}_{k+1})^{-1} \quad (19)$$

3 多元假设 GMPHD 轨迹跟踪

由于 PHD 滤波是针对随机集合形式的变量进行的计算, 同时, 提取 PHD 峰值估计点目标状态。由此可知, 估计值亦为集合形式, 因此不包含任何的有关目标身份或者顺序信息, 也就无法将同一目标在不同时刻产生的量测或估计值连接起来从而形成航迹。另外, 对于状态估计而言, 每一个 PHD 的峰值都只是当前这一帧数据而言的局部极大点, 并不包含穿越时间域的全局信息, 因此也不能像 MHT 一样, 用最大全局似然函数获得轨迹信息。本文使用经典信号检测理论中的多元假设保存不同时刻的轨迹状态, 结合使用 GMPHD 滤波的峰值信息估计目标状态和数目, 从而实现多目标的航迹跟踪。过程如下。

对于多元假设, 若待判决假设集合 $\mathbf{H}_{k|k-1}$ 为第 k 个时刻 $J_{k|k-1}$ 个假设子集组成的集合为

$$\mathbf{H}_{k|k-1} = \mathbf{H}_{k|k-1}^{(1)} \cup \dots \cup \mathbf{H}_{k|k-1}^{(J_{k|k-1})} = \bigcup_i [h_1^{(i)}, h_2^{(i)}, \dots, h_{1+|Z_k|}^{(i)}] \quad (20)$$

式中的 $\mathbf{H}_{k|k-1}^{(i)}$ ($k \geq 1, i=1, \dots, J_{k|k-1}$) 为 k 时刻代表着第 i 个轨迹的待判决的扩展假设子集, 其中的第 j 个二元假设 $h_j^{(i)}$ 的描述为

$$h_j^{(i)} = \begin{cases} 1, & \text{后验强度中的第 } j \text{ 个高斯分量} \\ \left(\text{参数为 } [\mathbf{m}_k^{(j)}, \mathbf{C}_k^{(j)}, w_k^{(j)}] \right) & \text{属于第 } i \text{ 条轨迹} \\ 0, & \text{其它} \end{cases}$$

其中 $j=1, \dots, 1+|Z_k|$, \mathbf{H}_0 为零假设, 即无轨迹。

在跟踪起始时刻, $k=0$, 设先验强度是 h_0 是 J_0 个高斯分量混合而成:

$$h_0(\mathbf{x}) = \sum_{j=1}^{J_0} w_0^{(j)} N(\mathbf{x}; \mathbf{m}_0^{(j)}, \mathbf{C}_0^{(j)}) \quad (21)$$

每个分量都对应着一个可能的目标, 由此初始化假设集合 $\mathbf{H}_0 = \mathbf{H}_0^{(1)} \cup \dots \cup \mathbf{H}_0^{(J_0)}$, 其中的每个假设子集都只包含单假设: $\mathbf{H}_0^{(i)} = [h_i^{(i)}]$, 即第 i 个分量就对应着第 i 条轨迹, $i=1, \dots, J_0$ 。同时初始化该假设的状态集合 $\mathbf{M}_0^{(i)} = [\mathbf{m}_0^{(i)}]$, 代表第 i 条轨迹的起点位置。

在没有收到一帧新的观测数据之前, GMPHD 滤波器先使用预测方程式(8)-式(11)对下一时刻的目标状态参数进行预测并更新假设集合 $\mathbf{H}_0 = \mathbf{H}_0 \cup \left[\bigcup_i \mathbf{H}_{b,1}^{(i)} \right], i=1, \dots, J_{b,1}$ 。新增的 $J_{b,1}$ 个假设集合代表着预测可能产生的 $J_{b,1}$ 个新轨迹。在预测阶段并不对假

设进行判决。

更新阶段, 接收到 $k=1$ 时的量测值后, 使用 GMPHD 更新方程式(13)–式(19)计算后验强度并针对各高斯分量构建该时刻的树状待判决假设集合 $\mathbf{H}_{1|0} = \bigcup_i \mathbf{H}_{1|0}^{(i)}$, 其中的每个假设子集是由前一时刻每个根假设所生成的 $1+|\mathbf{Z}_1|$ 个子假设(对应 $1+|\mathbf{Z}_1|$ 个高斯项)构成: $\mathbf{H}_{1|0}^{(i)} = [h_1^{(i)}, h_2^{(i)}, \dots, h_{1+|\mathbf{Z}_1|}^{(i)}]$ 。然后根据高斯混合分布中的权重因子对子集中每个二元假设 $h_j^{(i)}$ 进行判决, 若该假设为真, 则在集合中保存该假设并用相应高斯均值输出, 即将第 i 条轨迹的状态更新为 $\mathbf{M}_1^{(i)} = [m_1^{(i)}, m_0^{(i)}]$ 。因此, 若不考虑漏检或目标消失等情况, 判决结束后, 每个假设矩阵应该只有一个子假设 $h_j^{(i)}$ 为真, 第 j 个高斯分量的后验均值就是第 i 条轨迹在 $k=1$ 时刻的目标状态估计。重复预测和更新步骤直至跟踪结束。

之所以能够使用权重因子对假设实现判决是因为 $w_k^{(j)}$ 表征着量测和预测值之间的相似程度(见式(15)), 实质上也就表示着某高斯项和某一轨迹间的似然比大小。每次接收到新量测后, 更新方程针对每一个预测状态目标计算 $1+|\mathbf{Z}_k|$ 个权重因子, 其中的 $|\mathbf{Z}_k|$ 个因子是预测值和 $|\mathbf{Z}_k|$ 个量测的似然, 剩余的一个因子表示和 \emptyset (即由于目标已消失或因漏警未接收到量测)的似然。结合 GMPHD 方法, 判决扩展假设集合中的二元假设是否为真的判决准则为

$$w_k^{(j)} > w_{th} \text{ 且 } w_k^{(j)} > w_k^{(j')}, j \neq j'; j, j' = 1, \dots, 1+|\mathbf{Z}_k| \quad (22)$$

对于前一个条件 $w_k^{(j)} > w_{th}$ 是 GMPHD 简化计算的要求, 否则随着迭代的不断进行, 计算负担会越来越重; 而后一个条件实际为多元假设中的最大似然估计, 即使用 $1+|\mathbf{Z}_k|$ 个权重因子中的最大项的均值对第 i 条轨迹在 k 时刻的状态进行估计。

另外出于对漏警的考虑, 若扩展假设子集 $\mathbf{H}_k^{(i)}$ 中无一假设为真, 此时仍然进行 GMPHD 滤波, 但不对更新的后验强度进行分量剪裁, 亦不做任何输出。如果迭代了 n 次(n 是预先设定的允许漏检上限)后, 还没有判决准则被满足, 则表示该目标确实已消失, 轨迹终结。

4 实验和仿真

这一节给出了线性动态模型下二维多目标航迹跟踪的仿真结果。目标的监测区域是 $[-4000, 4000] \times [-4000, 4000]$ 。待估目标状态为其位置的二维坐标和相应的速度, 量测也是其位置的二维坐标。定义系统模型的式(2)和式(3)中各参数分别为(采样时间 $T=1$)

$$\mathbf{F}_k = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{Q}_k = \begin{bmatrix} 6.25 & 12.5 & 0 & 0 \\ 12.5 & 25 & 0 & 0 \\ 0 & 0 & 6.25 & 12.5 \\ 0 & 0 & 12.5 & 25 \end{bmatrix}$$

$$\mathbf{H}_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \mathbf{R}_k = \begin{bmatrix} 100 & 0 \\ 0 & 100 \end{bmatrix}$$

场景 1 的实验参数设定如下。在跟踪起始阶段和跟踪过程中, 有 10–20 个目标随机产生, 新生目标(泊松 RFS)的新生率为 0.05, 新目标在小区域 $[-1000, 1000] \times [-1000, 1000]$ 内产生。旧目标继续存在的概率为 $P_{S,k}=0.98$, 目标检测概率为 $P_{D,k}=0.99$ 。每帧接收到 200 个杂波。剪裁判决门限为 $w_{th}=0.5$ 。允许漏警的帧数 $n=2$ 。跟踪时长为 100 个采样周期。

图 1 为多目标航迹跟踪在二维坐标系中的仿真结果。由图可见, 尽管受到了较大的杂波影响, 多元假设 GMPHD 航迹跟踪器很好地估计了多个目标所形成的轨迹。而且, 本文提出的算法只在极个别点上产生错误, 并且大部分为漏警。这是由于判决准则使用的权重因子包含着当前时刻接收到的所有的量测信息, 因此绝大多数时间能够实现正确判决。个别漏警的出现主要是由于大杂波干扰使得轨迹权重因子的数值变小, 没有形成正确判决, 导致有效性略有降低。尽管如此, 从图中仍可看出算法中积累时间信息处理漏警情况非常有效, 丢失了轨迹的目标状态估计基本上都能重新实现正确的跟踪。

在 MATLAB 环境下(AMD2.21 GHz), 本文提出的多元假设 GMPHD 航迹跟踪算法需要的 CPU 运算时间为 9.125 s, 相比较于文献[14]中提出的




图1 x 、 y 轴的实际轨迹(直线)和多元假设检测 GMPHD 跟踪器估计(圆圈)效果

TLPHDRC 所需要的 468 s 缩减很多。大幅度运算时间的缩短直观地体现了本文提出的算法已大大减轻了对计算性能的要求。

为了比较多元假设 GMPHD 算法和传统的多目标轨迹跟踪方法 MHT 以及 MHT-with-PHD 的跟踪效果,重复以上实验。场景 2 的参数设置与文献[15]中相同:随机产生的目标数目在 10 个以下,每帧数据 20 个杂波,区域为 $[-40,60] \times [-40,60]$,跟踪时长为 40 个采样周期。图 2 中分别表示的是使用 MHT-with-PHD, MHT 和本文提出的多元假设 GMPHD 算法对场景 2 中的目标形成的点迹跟踪(直线为真实轨迹,圆圈为跟踪结果)。从图中可以直观的看出,错误检测情况,特别是虚警,在 MHT-with-PHD 算法和 MHT 算法中的出现频率都比本文的算法频繁很多,对多目标轨迹跟踪的准确程度也和本文算法相差很多。

Hoffman 和 Mahler^[16]证明了 Wasserstein 距离是衡量多目标错检性能的最佳数值表征。若多目标状态集合 $X = \{x_1, \dots, x_{|\bar{X}|}\}$, 估计值集合 $\bar{X} = \{\tilde{x}_1, \dots, \tilde{x}_{|\bar{X}|}\}$, 则 Wasserstein 距离定义为

$$d_p^W(\bar{X}, X) = \min_C \sqrt[p]{\sum_{i=1}^{|\bar{X}|} \sum_{j=1}^{|\bar{X}|} C_{i,j} \|\tilde{x}_i - x_j\|^p} \quad (23)$$

其中转移矩阵 $C = \{C_{i,j}\}$ 满足 $C_{i,j} \geq 0$, $\sum_{i=1}^{|\bar{X}|} C_{i,j} = \frac{1}{|\bar{X}|}$

且 $\sum_{j=1}^{|\bar{X}|} C_{i,j} = \frac{1}{|\bar{X}|}$ 。在本文中 p 取 2。场景 2 中本文

算法的 Wasserstein 距离的平均值为 68.5501。而图 3 所示的是本文算法对估计的目标数量与其真实值之间的误差,误差的绝对值平均为 0.1910。传统 MHT 方法的这两个参数分别为 1.7486 和 224.0479^[15]。由此可以看出无论是和 MHT-with-PHD, 还是和传统的 MHT 方法相比较,本文算法的跟踪效果都更准确。

5 结论

本文提出了一种 GMPHD 滤波器和经典信号检测技术结合的方法,能够在大量杂波干扰和漏警等影响下,准确地对多个目标形成的轨迹实现实时、正确的跟踪。本算法通过初始、扩展、剪裁及终结各树状假设集合以实现轨迹管理,同时,具有闭式解的 GMPHD 滤波很好地估计了目标的数量和状态。无论是与传统的轨迹跟踪方法还是和近期提出的 PHD 数据互联滤波技术相比较而言,本文所实现的轨迹跟踪算法有效减少了计算负担、缩短了跟踪时间、提升了跟踪的准确率。

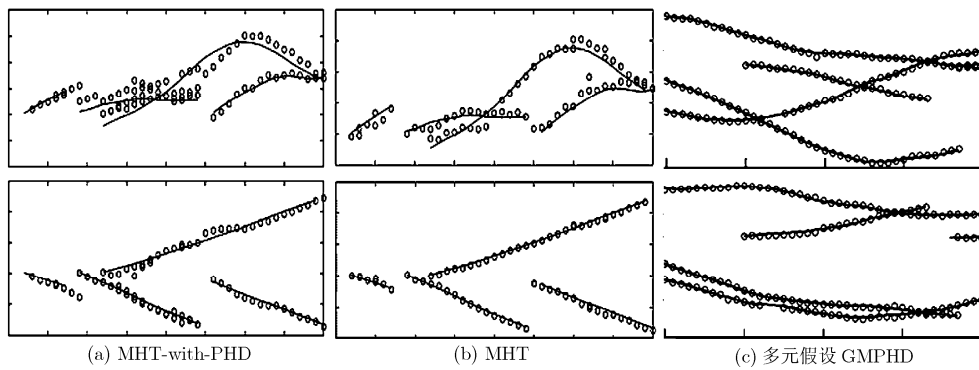


图 2 本文算法和 MHT-with-PHD 算法的跟踪效果比较




图 3 场景 2 的目标数量估计值和真实值间的误差

参考文献

[1] Bar-Shalom Y. Dimensionless score function for multiple hypothesis tracking[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007 43(1): 392-400.

[2] Blackman S. Multiple hypothesis tracking for multiple target tracking[J]. *IEEE Aerospace and Electronic Systems*, 2004,

- 19(1): 5-18.
- [3] Fortunato E, Kremer W, and Mori S, *et al.* Generalized Murty's algorithm with application to multiple hypothesis tracking[C]. Information Fusion, 2007 10th International Conference, Canada, July, 2007: 1-8.
- [4] Hall David L and Llinas James. Handbook of Multisensor Data Fusion[M]. FL: CRC Press, 2001: 211-241.
- [5] Fortmann T E, Bar-Shalom Y, and Scheffe M. Sonar tracking of multiple targets using joint probabilistic data association[J]. *IEEE Journal of Oceanic Engineering*, 1983, 8(7): 173-184.
- [6] Mahler R P S. Statistical Multisource-Multitarget Information Fusion[M]. Norwood, MA, Artech House, 2007: 343-394.
- [7] Mahler R P S. An introduction to multisource-multitarget statistics and its applications. Technical Monograph, Lockheed Martin, Eagan MN, 2000.
- [8] Mahler R P S. Multitarget Bayes filtering via first-order multitarget moments[J]. *IEEE Transaction on Aerospace and Electronic Systems*, 2003, 39(4): 1152-1178.
- [9] Mahler R P S. PHD filter of higher order in target number[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(4): 1523-1543.
- [10] Sidenbladh H. Multi-target particle filtering for the probability hypothesis density[C]. Proc. International Conference on Information Fusion, Cairns, Australia, 2003: 800-806.
- [11] Vo B N, Singh S, and Doucet A. 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.
- [12] Vo B N and Ma W K. The Gaussian mixture probability hypothesis density filter[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4091-4104.
- [13] Vo B T, Vo B, and Cantoni A. Analytic implementations of the Cardinalized Probability Hypothesis Density Filter[J]. *IEEE Transactions on Signal Processing*, 2007, 55(7): 3553-3567.
- [14] Lin L, Bar-Shalom Y, and Kirubarajan T. Track labeling and PHD filter for multitarget tracking[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2006, 42(3): 778-795.
- [15] Panta K, Vo B N, and Singh S. Novel data association schemes for probability hypothesis density filter[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(2): 556-570.
- [16] Hoffinan J and Mahler R. Multi-target miss distance via optimal assignment[J]. *IEEE Transactions on Systems, Man, and Cybernetics-Part A*, 2004, 34(3): 327-336.
- 黄志蓓: 女, 1973 年生, 博士生, 研究方向为信息隐藏、多目标跟踪和信息融合。
- 孙树岩: 男, 1984 年生, 硕士生, 研究方向为多目标跟踪、信息融合和虚拟现实技术。
- 吴健康: 男, 1947 年生, 教授, 研究方向为传感器网络和虚拟现实技术等。