

高斯混合概率假设密度无序估计分布式融合

孔云波[†], 冯新喜, 乔向东, 刘 钊

(空军工程大学 信息与导航学院, 陕西 西安 710077)

摘要: 针对分布式传感器网络中多目标随机集状态混合无序估计问题, 本文提出了一种基于高斯混合概率假设密度无序估计分布式融合算法. 在高斯混合概率假设密度滤波器的框架下, 首先基于概率假设密度递推滤波特性, 建立适用于多目标随机集状态混合无序估计的最新可利用估计判别机制, 然后利用扩展协方差交叉融合算法对经过最新可利用估计判别机制获得的无序概率假设密度强度估计进行融合处理, 针对融合过程中高斯分量快速增长的问题, 在保证信息损失最小的前提下, 对融合过程的不同环节实施高斯混合分量裁剪操作, 给出了一种多级分层分量裁剪算法. 最后, 仿真实验验证了文中所提的算法的有效性和可行性.

关键词: 高斯混合模型; 分布式融合; 协方差交叉; 分量裁剪; 无序估计

中图分类号: TN953

文献标识码: A

Distributed fusion with out-of-sequence estimates based on Gaussian mixture probability hypothesis density

KONG Yun-bo[†], FENG Xin-xi, QIAO Xiang-dong, LIU Zhao

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

Abstract: To deal with the problem of distributed fusion of out-of-sequence estimates based on multi-target filtering with random finite sets, we propose a distributed fusion algorithm of out-of-sequence estimates based on Gaussian mixture probability hypothesis density. In the frame of Gaussian mixture probability hypothesis density, we present a newest available local estimate discrimination mechanism for the out-of-sequence estimates problem based on the recursive filtering of probability hypothesis density. Then, the intensity of the probability hypothesis density acquired through the newest available local estimate discrimination mechanism is fused by using the generalized covariance intersection fusion algorithm. If the number of components in the mixture distribution grows exponentially when data are fused, a multistep Gaussian mixture component pruning algorithm is proposed under the premise of minimal information loss. Finally, the availability and feasibility of the distributed fusion algorithm of out-of-sequence estimates based on Gaussian mixture probability hypothesis density are illustrated in simulations.

Key words: Gaussian mixture probability; distributed fusion; covariance intersection; mixture component pruning; out-of-sequence estimates (OOSE)

1 引言(Introduction)

多传感器估计融合(multisensor estimates fusion, MEF), 也称分布式融合(distributed fusion, DF), 是针对目标状态估计信息的融合, 是传统估计理论与信息融合理论的有机结合. 随着传感器网络技术和应用的发展, 完全分布式融合逐渐成为主流融合结构. 在完全分布式融合中, 信息的传播和处理以完全分布的方式进行, 各节点利用本地量测获取目标状态的局部估计, 继而与其他节点进行交互, 利用融合算法获得全局目标状态估计. 与集中式融合相比, 虽然估计融合的性能在某些场合下可能会略低一些, 但其对系统资

源要求较低、可靠性和扩展性较好, 因而在各个领域发挥着重要作用^[1-2]. 在完全分布式传感器网络中, 由于各节点数据预处理时间不同以及受网络多跳传输机制等因素的影响, 使得信息在传输过程中出现延迟现象, 而这种延迟可能是短延迟, 也可能是一步或多步延迟. 无论何种延迟都将导致信息不能按正常时序到达目的节点, 即出现所谓无序信息(out-of-sequence information, OOSI)现象. 信息传输的无序现象破坏了传统数据融合理论中要求数据有序到达的假设, 使得基于有序信息的融合算法无法正常使用, 也使得融合算法的结构设计和性能分析面临着诸多不确定的因

收稿日期: 2014-04-23; 录用日期: 2014-12-23.

[†]通信作者. E-mail: kongyunbo123@163.com; Tel.: +86 15929483781.

陕西省自然科学基金项目(2011JM8023), CEMEE国家重点实验室开放基金项目(2014K0304B)资助.

Supported by National Natural Science Foundation of Shaanxi (2011JM8023) and the State Key Laboratory of China CEMEE (2014K0304B).

素和挑战^[3-4].

根据融合框架的不同, 无序信息又被分为集中式融合下的无序量测(out-of-sequence measurements, OOSM)和分布式融合下的无序估计^[3](out-of-sequence estimates, OOSE). 针对集中式融合下的OOSM问题, 许多学者进行研究. 文献[5]针对两个传感器的一步延迟目标跟踪系统, 给出了最优无序量测更新A1算法, 并讨论了不同离散化下A1算法的最优性问题. 文献[6]针对多传感器一步无序量测系统, 采用噪声解相关技术解决了最优递推更新估计问题. 此外, 围绕同/异步采样下多传感器信息融合中的OOSM问题以及单个无序量测多步延迟的估计问题, 研究人员提出了诸多算法^[7-9]. 与集中式框架相比, 分布式估计框架在综合估计性能和实时性上具有明显的优势. 因此文献[10]在分布式估计框架下提出了无序估计(OOSE)概念, 在此基础上, 文献[11]以多传感器同步采样但带有任意随机延迟的网络跟踪系统为对象, 研究无序估计信息系统的最佳分布式融合问题, 并建立一种新型的通用最优OOSE融合算法. 然而, 这些研究均是对传统Bayes估计框架下单目标状态的滤波、集中式量测融合以及分布式估计融合过程中OOSI问题的探讨, 并未涉及基于随机集滤波技术的多目标状态及估计过程中出现的OOSI问题. 文献[12]首次研究了多目标PHD滤波过程中OOSM的处理问题, 这也是唯一一篇在多目标随机集滤波框下讨论OOSI问题的文章. 由于OOSM也只是对应于集中式量测融合的概念, 因此, 多目标随机集滤波框架完全分布式多目标状态估计融合中的OOSE问题研究仍然处于空白.

本文对高斯混合概率假设密度完全分布式无序估计融合问题进行了研究. 在高斯混合概率假设密度滤波器的框架下, 基于概率假设密度(probability hypothesis density, PHD)递推滤波的特性, 建立了适用于多目标随机集状态混合无序估计的最新可利用估计(newest available local estimate, NALE)判别机制, 然后利用扩展协方差交叉算法实现对经过NALE判别机制获得的无序PHD强度估计的融合, 针对融合过程中高斯分量快速增长的问题, 在保证信息损失最小化的前提下, 对融合过程的不同环节实施分量裁剪操作, 给出了一种多级分层分量裁剪算法. 仿真实验验证了文中所提的算法的有效性和可行性.

2 问题描述(Problem description)

2.1 基于随机有限集的多目标跟踪(Multi-target filtering with random finite sets)

R. Mahler在点过程和随机集理论的基础上建立了随机有限统计量方法(finite set statistics, FISST), 并从集值估计的角度出发研究多目标跟踪问题, 分别将多目标状态和量测视为随机有限集合(random finite set,

RFS)的集值(set-valued, SV)状态和集值量测, 基于有限集变元的概念, 在定义了FISST和广义FISST的集合积分和导数后, 推导得到RFS框架下的多目标最优贝叶斯滤波器. 其递推公式如下:

1) 预测步:

$$f_{k|k-1}(X_k|Z_{1:k-1}) = \int f_{k|k-1}(X_k|X_{k-1})f_{k-1|k-1}(X_{k-1}|Z_{1:k-1})\delta X_{k-1}. \quad (1)$$

2) 更新步:

$$f_{k|k-1}(X_k|Z_{1:k}) = \frac{f_k(Z_k|X_k)f_{k|k-1}(X_k|Z_{1:k-1})}{f_k(Z_k|X_k)f_{k|k-1}(X_k|Z_{1:k-1})\delta X_k}, \quad (2)$$

其中: $f_{k|k-1}(X_k|X_{k-1})$ 表示多目标状态集合的转移概率密度, $f_k(Z_k|X_k)$ 表示测量集合的似然函数, $f_{k|k-1}(X_k|Z_{1:k-1})$ 表示多目标状态集合的时间预测概率密度, $f_{k|k}(X_k|Z_{1:k})$ 表示多目标状态集合的后验概率密度.

由于上述RFS框架下的多目标最优贝叶斯滤波器的计算复杂度随着目标个数的增多而迅速增大, 故在大多数实际应用中是计算不可行的. 为此, R. Mahler提出了PHD滤波器, PHD是多目标后验概率密度的一阶统计矩, 其在单目标状态空间指定区域的积分值即为该区域内目标数目的期望值, 从而将多目标状态空间上的多目标后验概率密度映射为单目标状态空间上的一种近似“物理”密度(强度).

假设 $k-1$ 时刻, 目标的PHD为 $D_{k-1}(x)$, 多目标状态演化式为 $f(X_k|X_{k-1})$, 则有

1) 预测步:

$$D_{k|k-1}(x) = \gamma_k(x) + \int \varphi(x_k|x_{k-1})D_{k-1}(x_{k-1})dx_{k-1}, \quad (3)$$

$$\varphi(x_k|x_{k-1}) = b(x_k|x_{k-1}) + P_s(x_{k-1})f(x_k|x_{k-1}), \quad (4)$$

其中: $\gamma_k(x)$ 表示新生的目标, $b(x_k|x_{k-1})$ 表示的是卵生目标, $P_s(x_{k-1})$ 是目标的生存概率, 它表示了目标的死亡信息.

2) PHD更新步:

$$D_k(x) = (1 - P_D(x))D_{k|k-1}(x) + \sum_{z_k \in Z_k} \frac{P_D(x)\rho(z_k|x)}{\lambda_k c_k(z_k) + \int P_D(x)\rho(z_k|x)D_{k|k-1}(x)dx}, \quad (5)$$

其中: λ_k 是期望的杂波个数, $c_k(z_k)$ 是一个杂波点密度, $P_D(x)$ 是目标检测概率.

PHD是目标个数在状态空间的分布, 它只是包含目标状态信息, 而不能直接提供目标的状态. 目前

PHD的实现方法主要有基于序贯蒙特卡罗的粒子PHD和基于高斯和的高斯混合PHD. 本文主要研究高斯混合PHD框架下的无序估计融合问题.

2.2 问题描述(Problem description)

在完全分布式传感器网络中, 各节点在得到有序量测后, 先在本地进行滤波处理, 获得目标状态的局部估计, 然后将其传递给其他节点, 继而利用融合算法, 由本地局部估计和所接收的其他节点的目标状态局部估计获得(近似)全局目标状态估计. 受网络数据传输不确定的影响, 传感器网络的传输是随机的, 并可能产生不可预知的延迟, 这种延迟可能是短延迟、一步延迟和多步延迟等随机交替出现, 因此即便是同步采样下的传感器网络完全分布式融合系统中各局部估计信息到达相邻节点时也往往呈现无序的状态, 原先固定的顺序被随机打乱, 图1给出了完全分布式融合中混合OOSE示意图.




图1 传感器系统无序估计

Fig. 1 Out-of-sequence estimates of sensor system

对于任一节点而言, 由于PHD滤波器的递推计算特性, 新获得的局部估计总是包含该节点先前所有的局部估计信息^[3], 因此对于混合OOSE融合问题而言, 在估计融合之前, 首先需要针对每个参与融合的相邻节点判断哪一个局部估计是其最新可利用的(NALE估计), 为此需要建立相应的NALE估计判别机制, 这是传感器网络中实现多目标随机集状态混合无序估计融合的前提. 因此, 需要研究适用于多目标随机集状态混合无序估计融合的可行有效的NALE判别机制, 继而在此基础上研究由NALE判别机制判定的各节点NALE估计融合问题.

3 高斯混合概率假设密度无序估计融合算法 (Out-of-sequence estimates based on gaussian mixture probability hypothesis density)

3.1 高斯混合概率密度滤波(Gaussian mixture probability hypothesis density)

高斯混合概率假设密度滤波是PHD滤波的一种实

现形式, 通过带权值的高斯分量来近似目标强度函数, 它假设场景中的每一个目标都服从线性混合高斯模型. 高斯混合概率密度滤波器的递推主要分为预测和更新两个步骤:

1) PHD预测:

$$D_{k|k-1}(x) = \gamma_k(x) + D_{s,k|k-1}(x) = \sum_{l=1}^{J_{r,k}} \omega_{\gamma,k}^{(l)} N(m_{\gamma,k}^{(l)}, P_{\gamma,k}^{(l)}) + P_s \sum_{l=1}^{J_{k-1}} \omega_{k-1}^{(l)} N(m_{s,k|k-1}^{(l)}, P_{s,k|k-1}^{(l)}), \quad (6)$$

其中: $\{\omega_{\gamma,k}^{(l)}, m_{\gamma,k}^{(l)}, P_{\gamma,k}^{(l)}\}_{l=1}^{J_{r,k}}$ 表示新生目标集的强度函数, $\{\omega_{k-1}^{(l)}, m_{s,k|k-1}^{(l)}, P_{s,k|k-1}^{(l)}\}_{l=1}^{J_{k-1}}$ 表示存活目标集的强度函数, 每个高斯分量的预测均值 $m_{k|k-1}^{(l)}$ 和协方差 $P_{k|k-1}^{(l)}$ 可通过卡尔曼滤波进行计算:

$$m_{s,k|k-1}^{(l)} = F(k, k-1)m_{s,k-1}^{(l)}, \quad (7)$$

$$P_{s,k|k-1}^{(l)} = Q(k, k-1) + F(k, k-1)P_{s,k-1}^{(l)}F^T(k, k-1). \quad (8)$$

2) PHD更新:

$$D_k(x) = (1 - P_d)D_{k|k-1}(x) + \sum_{z \in Z_k} \sum_{l=1}^{J_{k|k-1}} \omega_k^{(l)} N(m_k^{(l)}, P_k^{(l)}), \quad (9)$$

其中高斯分量的权值、均值和协方差的计算如下:

$$\omega_k^{(l)} = \frac{P_d \omega_{k|k-1}^{(l)} N(\hat{z}_{k|k-1}^{(l)}, S_{k|k-1}^{(l)})}{\kappa_k(z) + P_d \sum_{l'=1}^{J_{k|k-1}} \omega_{k|k-1}^{(l')} N(\hat{z}_{k|k-1}^{(l')}, S_{k|k-1}^{(l')})},$$

$$m_k^{(l)} = m_{k|k-1}^{(l)} + K_k^{(l)}(z - \hat{z}_{k|k-1}^{(l)}),$$

$$P_k^{(l)} = [I - K_k^{(l)}H]P_{k|k-1}^{(l)},$$

$$\hat{z}_{k|k-1}^{(l)} = Hm_{k|k-1}^{(l)},$$

$$K_k^{(l)} = P_{k|k-1}^{(l)}H^T[S_{k|k-1}^{(l)}]^{-1},$$

$$S_{k|k-1}^{(l)} = HP_{k|k-1}^{(l)}H^T + R.$$

3.2 最新可利用估计判别机制(Newest available local estimate)

在传统单目标状态混合OOSE融合的研究中, 有关最新可利用估计(NALE)的判别机制存在两种方案, 即整体方案和递推方案^[3,11]. 在单目标状态OOSE估计融合中, 服从高斯分布的目标状态估计可仅由均值和方差表示, 较为简单, 采用二维数组变量存储方式的整体NALE判别机制不存在太大的问题. 然而, 对于由数目众多的混合高斯分量构成的多目标随机集PHD强度估计的融合问题而言, NALE判别机制的整体方案基本不可行, 特别是基于传感器网络的完全分

布式融合, 其节点计算、存储资源本身就十分受限, 额外存储数目众多且不定的高斯分量是不现实的, 这使得传统单目标混合OOSE估计融合中基于时间戳和缓存的NALE机制几乎不再可行. 因此, 本文采用基于递推方案建立多目标随机集状态估计的NALE判别机制. 判别机制如下:

第1步 令变量 $\vartheta(k)$ 表示最新可利用估计值的时间戳, M_i 表示 $(k-1, k]$ 融合周期内传感器 i 的无序估计个数. 假设到时刻 $(k-1)$ 为止, 融合节点获得的最新可利用的局部估计值为 $D_{\kappa|\kappa}(x)$, 则有 $\vartheta(k) = \kappa$, $M_i = 0$; 融合节点在 $(k-1)$ 时刻的PHD强度估计可通过对全体节点关于多目标随机集状态的共识融合估计来获得^[13], 从而利用式(6)获得融合节点的一步预测 $D_{k|k-1}(x)$, 令 $D_{k|k}^0(x) = D_{k|k-1}(x)$;

第2步 当传感器 i 的一个无序估计 $D_{a|a}(x)$ 到达融合节点时, 其中 $a < k-1$, 有 $M_i = M_i + 1$;

第3步 若 $a > \kappa$, 则 $\vartheta(k) = a$, 且有

$$D_{k|\vartheta(k)}^{M_i}(x) = \gamma_k(x) + D_{s,k|\vartheta(k)}^{M_i}(x) = \sum_{l=1}^{J_{r,k}} \omega_{\gamma,k}^{(l)} N(m_{\gamma,k}^{(l)}, P_{\gamma,k}^{(l)}) + P_s \sum_{l=1}^{J_{\vartheta(k)}} \omega_{\vartheta(k)}^{(l)} N(m_{s,k|\vartheta(k)}^{(l)}, P_{s,k|\vartheta(k)}^{(l)}), \quad (10)$$

其中:

$$m_{s,k|\vartheta(k)}^{(l)} = F(k, \vartheta(k)) m_{s,\vartheta(k)}^{(l)}, \quad (11)$$

$$P_{s,k|\vartheta(k)}^{(l)} = Q(k, \vartheta(k)) + F(k, \vartheta(k)) P_{s,k|\vartheta(k)}^{(l)} F^T(k, \vartheta(k)), \quad (12)$$

否则, 丢弃冗余估计 $D_{a|a}(x)$, 且有

$$D_{k|k}^{M_i}(x) = D_{k|k}^{M_i-1}(x). \quad (13)$$

步骤4 重复步骤2和步骤3, 直到融合节点获得传感器 i 的所有无序估计, 记 $M_N = M_i$.

步骤5 从而可得传感器 i 最优OOSE估计为

$$D_{k|k}^i(x) = D_{k|k}^{M_N}(x). \quad (14)$$

以上即为单传感器最优OOSE算法, 在分布式传感器网络中, 与融合节点相关的各节点完成NALE判别后, 当 k 时刻到来时, 即可利用扩展协方差交叉融合(generalized covariance intersection, GCI)算法, 完成对NALE预测估计值的融合.

3.3 扩展协方差交叉(GCI)融合算(Generalized covariance intersection fusion)

考虑节点 i 和节点 j , 其输出的多目标时间预测概率密度分别为 f_i 和 f_j , 其分布服从独立同布簇过程, 则

$$\begin{cases} f_i(X) = n! \cdot p_i(n) \prod_{x \in X} s_i(x), \\ f_j(X) = n! \cdot p_j(n) \prod_{x \in X} s_j(x), \end{cases} \quad (15)$$

则基于GCI算法融合估计得多目标时间预测概率分布如下^[14]:

$$f_\omega(X) = \frac{f_i(X)^{(1-\omega)} f_j(X)^\omega}{\int f_i(X')^{(1-\omega)} f_j(X')^\omega \delta X'}, \quad (16)$$

其中 $\omega \in [0, 1]$ 决定了两个概率密度相对权重.

因为 f_i 和 f_j 分布服从独立同步簇过程, 故 $f_\omega(X)$ 也服从独立同步簇过程, 有

$$f_\omega(X) = n! \cdot p_\omega(n) \prod_{x \in X} s_\omega(x), \quad (17)$$

其中:

$$s_\omega(x) = \frac{s_i^{(1-\omega)}(x) s_j^\omega(x)}{\int s_i^{(1-\omega)}(y) s_j^\omega(y) dy}, \quad (18)$$

$$p_\omega(n) = \frac{p_i^{(1-\omega)}(n) p_j^\omega(n) \left(\int s_i^{(1-\omega)}(x) s_j^\omega(x) dx \right)^n}{\sum_{m=0}^{\infty} p_i^{(1-\omega)}(m) p_j^\omega(m) \left(\int s_i^{(1-\omega)}(y) s_j^\omega(y) dy \right)^m}. \quad (19)$$

当节点采用高斯混合概率假设密度滤波器时, 节点 i 和节点 j 的局部位置密度估计为

$$s_i(x) = \sum_{a=1}^{N_i} w_i^a N(x; m_i^a, P_i^a), \quad (20)$$

$$s_j(x) = \sum_{b=1}^{N_j} w_j^b N(x; m_j^b, P_j^b). \quad (21)$$

将式(20)–(21)代入(18), 得

$$s_\omega(x) = \frac{\left(\sum_{a=1}^{N_i} w_i^a N(x; m_i^a, P_i^a) \right)^{(1-\omega)} \left(\sum_{b=1}^{N_j} w_j^b N(x; m_j^b, P_j^b) \right)^\omega}{\int \left[\left(\sum_{a=1}^{N_i} w_i^a N(y; m_i^a, P_i^a) \right)^{(1-\omega)} \times \left(\sum_{b=1}^{N_j} w_j^b N(y; m_j^b, P_j^b) \right)^\omega dy \right]}. \quad (22)$$

由于高斯混合随机变量经过求幂运算后一般不再服从高斯混合分布, 因此, 通常情况下融合后的位置密度估计 $s_\omega(x)$ 不再服从高斯混合分布, 从而无法完成目标运动状态的提取, 融合计算的有效性遭到破坏, 从而使得融合失去实际意义. 针对此问题, 本文采取忽略不同分量交叉乘积项的做法, 以保持高斯混合求幂的高斯混合分布特性^[15], 即

$$\begin{aligned} & \left[\sum_{a=1}^{N_i} w_i^a N(x; m_i^a, P_i^a) \right]^\omega \cong \\ & \sum_{a=1}^{N_i} [w_i^a N(x; m_i^a, P_i^a)]^\omega = \\ & \sum_{a=1}^{N_i} (w_i^a)^\omega \kappa(\omega, P_i^a) N(x; m_i^a, P_i^a / \omega). \end{aligned} \quad (23)$$

从而可得

$$s_\omega(x) = \frac{\sum_{a=1}^{N_i} \sum_{b=1}^{N_j} w_{ij}^{ab} N(x; m_{ij}^{ab}, P_{ij}^{ab})}{\int \sum_{a=1}^{N_i} \sum_{b=1}^{N_j} w_{ij}^{ab} N(x; m_{ij}^{ab}, P_{ij}^{ab}) dx} = \frac{\sum_{a=1}^{N_i} \sum_{b=1}^{N_j} w_{ij}^{ab} N(x; m_{ij}^{ab}, P_{ij}^{ab})}{\sum_{a=1}^{N_i} \sum_{b=1}^{N_j} w_{ij}^{ab}}, \quad (24)$$

其中:

$$P_{ij}^{ab} = [(1-\omega)(P_i^a)^{-1} + \omega(P_j^b)^{-1}]^{-1}, \quad (25)$$

$$m_{ij}^{ab} = P_{ij}^{ab} [(1-\omega)(P_i^a)^{-1} m_i^a + \omega(P_j^b)^{-1} m_j^b], \quad (26)$$

$$w_{ij}^{ab} = (w_i^a)^{(1-\omega)} (w_j^b)^\omega \kappa(1-\omega, P_i^a) \kappa(\omega, P_j^b) \cdot$$

$$N(m_i^a - m_j^b; 0, \frac{P_i^a}{1-\omega} + \frac{P_j^b}{\omega}), \quad (27)$$

$$\kappa(\omega, P) \triangleq \frac{[\det(2\pi P\omega)]^{\frac{1}{2}}}{[\det(2\pi P)]^{\frac{\omega}{2}}}. \quad (28)$$

然而,上述近似计算并非总是成立的,仅当所有不同高斯分量之间的统计距离足够大的情况下才可行。当跟踪密集目标时,上述近似计算会出现更大的误差。再者,假设两节点局部PHD强度估计的高斯分量数目分别是 N_i 和 N_j ,即便不考虑高斯混合随机变量幂运算中的不同分量的交叉乘积项,融合估计的高斯混合分量的数目也将变为 $N_i \times N_j$,特别地,对于完全分布式融合而言,本地估计要与所有相邻节点的局部估计进行融合,随着融合过程的进行,构成PHD强度估计的高斯分量数目急剧增加,这对于节点计算和存储资源受限的传感器网络而言也是不能接受的,从而使得融合计算失去可行性。因此,本文在进行NALE预测估计值融合前,在保证信息损失最小的前提下,针对融合节点的不同环节实施两次分量裁剪操作,给出了一种多级分层分量裁剪算法,其示意图如图2。

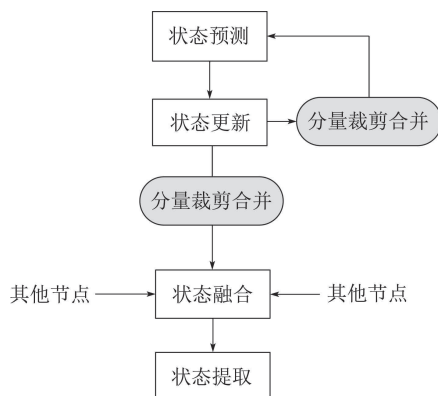


图2 裁剪算法流程

Fig. 2 The process of pruning algorithm

从图2中可以看出,第1次分量裁剪是在本地节点状态更新完成并进行下一时刻状态预测时进行(处于滤波递推计算过程中),其主要目的是从计算角度出

发,在滤波过程中减少高斯分量个数以降低滤波计算量,同时也要保证信息损失最小;第2次分量裁剪操作是在本地状态更新完成后和在局部进行融合前进行,其目的是大批量对高斯分量进行裁剪,使得高斯分量的个数等于估计目标的个数,从而为前述的融合创造条件。依据不同阶段分量裁剪合并操作定位的不同,分别给出两种分量裁剪操作算法。

1) 第1次分量裁剪操作。

第1次分量裁剪是从减少计算量角度和保证信息损失最小的角度考虑,裁剪规则如下:

第1步 设定权值门限 W_0 ,模型合并门限 η 和混合模型个数门限 K 。混合模型按权值大小进行排列,若 $w_i > W_0$,则保留该分量,否则予以删除。参数的具体值的选择可参见文献[16]。

第2步 选取保留分量中权值最大的分量 $\{w_{\max}, m_{\max}, P_{\max}\}$,将 $\{w_{\max}, m_{\max}, P_{\max}\}$ 与其他分量依次进行组合,利用Mahalanobis统计距离来度量两高斯分量之间的距离,即

$$d_{ij}^2 = \frac{w_i w_j}{w_i + w_j} (m_i - m_j)^T \Sigma^{-1} (m_i - m_j), \quad (29)$$

其中 Σ 为高斯和的组合方差,若距离小于某一设定的门限 η ,则将两分量进行合并,得到新高斯分量为权值: $w_c = w_i + w_j$ 。均值:

$$m_c = \frac{1}{w_i + w_j} (w_i m_i + w_j m_j),$$

方差:

$$\Sigma_c = \frac{1}{w_i + w_j} [w_i \Sigma_i + w_j \Sigma_j + \frac{w_i w_j}{w_i + w_j} (m_i - m_j)(m_i - m_j)^T].$$

第3步 利用约束条件下权值自适应优化算法对权值进行调整^[11]。

$$\min \int [\sum_{i=1}^N \alpha_i N(x, m_i, P_i) - \sum_{j=1}^K \beta_j N(x, m'_j, P'_j)]^2 dx, \quad (30)$$

$$\text{s.t. } \sum_{j=1}^K \beta_j = 1.$$

第4步 若混合高斯分布的个数达到预先设定的最低个数或者精度达到要求,则停止。

2) 第2次分量裁剪操作。

第1步 设定权值门限 W_0 ,通常选取 $W_0 = 0.5$,按混合模型权值大小进行排列。

第2步 选择混合模型 $w > W_0$ 的分量组成新的混合模型。

第3步 利用新的混合模型输出目标状态。


在利用扩展协方差交叉融合算法完成对NALE预测估计值的融合后,当 k 时刻的量测到来时,可利用式(9)对PHD强度估计更新。

4 仿真分析(Simulation analysis)

本文的实验在二维平面内进行, 观测区域为 $x \sim [-1000 \text{ m}, 1000 \text{ m}]$, $y \sim [-1000 \text{ m}, 1000 \text{ m}]$, 考虑3传感器跟踪4个目标的运动情况, 3传感器坐标分别为 $S1 = (-800 \text{ m}, -1000 \text{ m})$, $S2 = (600 \text{ m}, 0 \text{ m})$, $S3 = (1000 \text{ m}, 0 \text{ m})$, 采样周期 $T = 1 \text{ s}$, 传感器 $S1$ 和传感器 $S3$ 按照规律每一时刻向传感器 $S2$ 发送状态信息, 传感器 $S1$ 进行状态融合. 4 个目标相继出现, 各目标初始状态以及出生和消亡的时间如表1所示. 采样周期 $T = 1 \text{ s}$, 整个观测时间持续 100 s . 图3给出了仿真实验的态势图.

表 1 模拟目标起始状态和生存周期
Table 1 Initial state and life cycle of targets

目标	初始状态	出生/死亡时间
1	$[100 \frac{400}{99} 500 450 - \frac{1350}{99} -900]$	$\frac{1}{100} \text{ s}$
2	$[-450 \frac{1350}{40} 900 -450 - \frac{50}{40} -500]$	$\frac{20}{60} \text{ s}$
3	$[450 - \frac{600}{40} -150 -209 - \frac{691}{40} -900]$	$\frac{40}{80} \text{ s}$
4	$[-350 \frac{350}{40} 0 -350 \frac{1050}{40} 700]$	$\frac{40}{80} \text{ s}$



目标1: bom $t=1$, disk=100 目标2: bom $t=20$, disk=60
目标3: bom $t=40$, disk=80 目标4: bom $t=40$, disk=80

图 3 目标运动轨迹

Fig. 3 The trace of the targets

仿真中各目标运动状态方程和量测方程如下:

$$X_{k+1} = FX_k + G_k w_k, \quad (31)$$

$$Z_k = HX_k + W_k, \quad (32)$$

其中:

$$F_k = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, G_k = \begin{bmatrix} 0.5T^2 & 0 \\ T & 0 \\ 0 & 0.5T^2 \\ 0 & T \end{bmatrix},$$

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, w_k \sim N(\cdot, 0, \begin{bmatrix} \sigma_w^2 & 0 \\ 0 & \sigma_w^2 \end{bmatrix}),$$

$\sigma_w = 2$, W_k 为具有协方差 R 的零均值白色高斯量测噪声序列, 量测误差为 20 m .

仿真参数设置最大高斯分量数目 $J_{\max} = 100$, 修剪门限 $T_p = 10^{-5}$, 合并门限 $U = 5$, 目标存活概率 $P_s = 0.99$, 检测概率 $P_d = 0.99$. 杂波服从均值为 10 的泊松分布, 均匀分布于观测空间中. 简单起见, 不考虑目标衍生过程, 新生目标的 PHD 为

$$D_b(x) = 0.1 \times N(x; m_b, P_b) + 0.1 \times N(x; -m_b, P_b), \quad (33)$$

其中:

$$m_b = [250 \ 250 \ 0 \ 0]^T,$$

$$P_b = \text{diag}\{100, 100, 25, 25\}.$$

图4和图5给出了50次蒙特卡罗仿真实验平均后得到的融合估计和仅节点1对多目标个数估计随时间变化曲线. 正如图中所示, 融合估计和仅节点1估计均能较好地收敛到真实的目标个数. 进一步从图中可知, 在目标个数发生变化的时刻, 融合估计和仅节点1估计对目标数目估计均有较大的波动, 但一旦进入目标数目恒定阶段, 融合估计对目标个数的估计结果要优于仅节点1的结果.




图 4 目标数目估计

Fig. 4 The estimated number of targets




图 5 目标数目估计均方根误差

Fig. 5 The RMSE of estimated number

由于PHD滤波器没有进行数据关联, 均方误差 (RMSE) 无法对滤波器的性能进行评价. 为统计两种

算法的平均性能,本文采用OSPA脱靶距离对两种算法的性能进行评价,OSPA距离的计算式如下:

$$d_p^c(X, Z) = \left(\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m d^{(c)}(x_i, z_{\pi(i)})^p + c^p(n-m) \right) \right)^{\frac{1}{p}} \tag{34}$$

在OSPA距离中,参数c和p的选择对集合势误差和位置误差有重要的影响.在实验中参数c = 200,参数p = 2.图6为50次蒙特卡罗仿真实验结果.正如图6中所示,在大多数时刻,融合算法的跟踪结果都小于仅有节点1的跟踪结果,在目标个数发生变化的时刻,两种算法所得到的OSPA曲线震荡较大,波峰较高,其主要原因是目标个数发生了变化,因此,曲线主要反映的是目标个数的变化.总体来看,融合估计后的OSPA距离更小.

图7给出一次蒙特卡罗仿真t = 3时刻高斯分量的变化情况.从图7(a)中可以明显看出,存在多个相近的高斯分量描述同一个强度峰值的问题.经过第1次分量裁剪,删除了大部分没有量测支撑的混合分量,随着第2次分量的裁剪来进一步保证每一个强度峰值由

一个高斯分量来表示.




图6 OSPA距离

Fig. 6 OSPA distance

图8给出了50次蒙特卡罗仿真高斯分量数随时间的变化曲线图.从图8中可以看出,在对分量裁剪前,高斯分量的个数随着时间的增长呈几何形式增长,本文所给出的裁剪算法能较好的抑制高斯分量的增长,经过分量裁剪后,高斯分量的数量几乎与目标个数相一致,为下一步融合奠定基础的同时,减轻了融合节点的计算负担.




图7 t = 2高斯裁剪图

Fig. 7 Gaussian mixture component pruning when t = 2




图8 高斯分量变化图

Fig. 8 The change of Gaussian mixture component

5 总结(Conclusion)

本文研究传感器网络中多目标随机集状态混合无序估计的融合问题.在高斯混合概率假设密度滤

波器的框架下,基于PHD递推滤波的特性,建立了适用于多目标随机集状态混合无序估计的NALE判别机制,然后利用扩展协方差交叉算法实现对经

过NALE判别机制获得的无序PHD强度估计的融合, 针对融合过程中高斯分量快速增长的问题, 在保证信息损失最小化的前提下, 对融合过程的不同环节实施分量裁剪操作, 给出了一种多级分层分量裁剪算法. 下一步将对粒子概率假设密度滤波框架下的无序估计问题和全局共识融合问题进行研究.

参考文献(References):

- [1] 韩崇昭, 朱洪艳, 段战胜. 多传感器信息融合 [M]. 第2版. 北京: 清华大学出版社, 2010.
(HAN Chongzhao, ZHU Hongyan, DUAN Zhansheng. *Multi-source Information Fusion* [M]. 2nd edition. Beijing: Tsinghua University Press, 2010.)
- [2] 何友, 王国宏, 关欣. 信息融合理论及应用 [M]. 北京: 电子工业出版社, 2010.
(HE You, WANG Guohong, GUAN Xin. *Information Fusion Theory with Applications* [M]. Beijing: Publishing House of Electronics Industry, 2010.)
- [3] 葛泉波. 无序信息的网络融合及在舰船组合导航中的应用 [D]. 上海: 上海海事大学, 2008.
(GE Quanbo. *Net fusion based on out-of-sequence information and applications in ship integrated navigation* [D]. Shanghai: Shanghai Maritime University, 2008.)
- [4] 张建. 基于乱序数据传输的信息融合估计 [D]. 哈尔滨: 黑龙江大学, 2012.
(ZHANG Jian. *Information fusion based on out-of-sequence data transmission* [D]. Harbin: Heilongjiang University, 2012.)
- [5] BAR S Y. Update with out-of-sequence measurements in tracking: exact solution [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2002, 38(3): 769 – 778.
- [6] FENG X L, GE Q B, WEN C L. Optimal update with one step out-of-sequence measurements for wireless multisensory network [C] // *International Conference on Wavelet Analysis and Pattern Recognition*. Hong Kong: IEEE, 2008: 826 – 831.
- [7] ZHANG K S, LI X R, ZHU Y M. Optimal update with out-of-sequence measurements [J]. *IEEE Transactions on Signal Processing*, 2005, 53(6): 1992 – 2004.
- [8] SHEN X J, ZHU Y M, SONG E B, et al. Optimal centralized update with multiple local out-of-sequence measurements [J]. *IEEE Transactions on Signal Processing*, 2009, 54(7): 1551 – 1562.
- [9] EVA B P, LOPEZ J A, BESADA J A, et al. Multisensor out of sequence data fusion for estimating the state of discrete control systems [J]. *IEEE Transactions on Automatic Control*, 2009, 54(7): 1728 – 1732.
- [10] GE Q B, WEN C L. Optimal distributed fusion with one step out-of-sequence estimates [J]. *Journal of Electronics (China)*, 2008, 25(4): 529 – 538.
- [11] 葛泉波, 文成林. 多传感器网络系统基于无序估计的分布式信息融合 [J]. 电子信息学报, 2010, 32(7): 1614 – 1620.
(GE Quanbo, WEN Chenglin. Distributed information fusion with “out-of-sequence” estimates for multisensor network system [J]. *Journal of Electronics & Information Technology*, 2010, 32 (7): 1614 – 1620.)
- [12] BISHOP A N. Gaussian-sum based probability hypothesis density filtering with delayed and out-of-sequence measurements [C] // *Proceeding of Mediterranean Conference on Control & Automation*. Marrakech, Morocco: IEEE, 2010: 1423 – 1428.
- [13] BATTISTELLI G, CHISCI L, FANTACCI C, et al. Consensus CPHD filter for distributed multitarget tracking [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2013, 7(3): 508 – 520.
- [14] UNEY M, JULIER S, CLARK D. Distributed fusion of PHD filters via exponential mixture densities [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2013, 7(3): 521 – 531.
- [15] JULIER S J. An empirical study into the use of chernoff information for robust, distributed fusion of gaussian mixture models [C] // *Proceedings of the 9th International Conference on Information Fusion*. Seattle, WA, USA: IEEE, 2006: 1326 – 1333.
- [16] SCHIEFERDECKER D, HUBER M F. Gaussian mixture reduction via clustering [C] // *Proceedings of the 12th International Conference on Information Fusion*. Seattle, WA, USA: IEEE, 2009: 1526 – 1543.

作者简介:

孔云波 (1987–), 男, 博士研究生, 研究方向为多传感器数据融合、目标跟踪, E-mail: kongyunbo123@163.com;

冯新喜 (1962–), 男, 教授, 博士生导师, 研究方向为多传感器数据融合、目标跟踪, E-mail: kongyunbo123@163.com;

乔向东 (1970–), 男, 副教授, 硕士生导师, 研究方向为多传感器数据融合、目标跟踪, E-mail: qxcdm@sina.com;

刘钊 (1988–), 男, 博士研究生, 研究方向为多传感器数据融合、目标跟踪, E-mail: yeyujiyulz@163.com.