

一种基于模糊聚类的 PHD 航迹维持算法

欧阳成,姬红兵,田 野

(西安电子科技大学电子工程学院,陕西西安 710071)

摘 要: 针对杂波环境下数量变化的多目标航迹关联问题,提出一种基于模糊聚类的 PHD 航迹维持算法.该算法充分利用多帧信息,对当前时刻状态进行多步预测,并根据惯性进行加权,然后利用模糊聚类求得当前估计属于每条航迹的隶属度,从而得到最终的航迹.与传统的估计与航迹关联算法不同,该算法在更新每条航迹信息时,不仅仅是简单地对相邻帧之间的对数似然比进行求和,而是通过加权聚类等操作综合考虑了多帧信息.实验结果表明,所提算法能够更好地保持目标航迹,即使在目标出现交叉的地方也能达到很好的跟踪精度,具有较强的鲁棒性和优良的航迹维持性能.

关键词: 模糊聚类; 概率假设密度滤波; 数据关联; 航迹维持

中图分类号: TP302.7 **文献标识码:** A **文章编号:** 0372-2112 (2012) 06-1284-05

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2012.06.037

Fuzzy Clustering Based Algorithm for Track Continuity in PHD Filter

OUYANG Cheng, JI Hong-bing, TIAN Ye

(School of Electronic Engineering, Xidian University, Xi'an, Shannxi 710071, China)

Abstract: Due to the difficulty in association and estimation of multi-target track in the presence of data association uncertainty, clutter, noise and miss-detection, a fuzzy clustering based algorithm for track continuity in probability hypothesis density (PHD) filter is proposed in this paper. Firstly, a multi-step prediction of current target states is made, and then the weighted labels are assigned to them according to the inertia. Secondly, the fuzzy membership degrees of the current state estimates belonging to the tracks are obtained with the maximum entropy fuzzy clustering. Finally, the tracks are maintained by the use of all the information. Different from the traditional estimate-to-track association, the proposed algorithm does not update the track information by simply summing the log likelihood ratios between adjacent frames, but takes the entire multi-frame information into account by the operations such as weighting and clustering. The simulation results show that the proposed algorithm can maintain target tracks more accurately, even when the targets cross each other, implying strong robustness and excellent performance of track continuity.

Key words: fuzzy clustering; probability hypothesis density (PHD) filter; data association; track continuity

1 引言

近几年,越来越多专家开始尝试利用随机有限集^[1,2](RFS, Random Finite Set)理论来解决多目标跟踪问题.其中最有影响力的是 Mahler 提出的概率假设密度滤波(PHD, Probability Hypothesis Density)^[1],该滤波算法将复杂的多目标状态空间的运算转换为单目标状态空间内的运算,有效避免了多目标跟踪中复杂的量测-目标关联问题,在保证精度的同时,提高了算法实时性.目前已有的 PHD 实现方法主要包括粒子滤波 PHD^[3]和高斯混合 PHD(GMPHD, Gaussian Mixture PHD)^[4].这两种方法均是在 RFS 的理论框架下对整个目标集合的处理,虽然避免了量测-目标关联,但无法得到某一特定目标的

完整航迹,从而给一些后续处理如目标行为识别,目标身份识别以及最后的势态估计带来困难.

针对 PHD 的航迹维持问题, Panta 在文献[5]中提出,首先采用 PHD 进行预滤波,然后将结果输入 MHT 中进行滤波,从而得到目标的完整航迹.由于该方法中的 PHD 只是作为辅助,其性能主要取决于 MHT,因此该方法仍然具有较高的时间和空间复杂度. Lin 在文献[6]中提出,将 PHD 按处理单元进行划分,并通过计算相邻两帧 PHD 峰值之间的似然函数,将航迹维持问题转化为一个二维分配问题.然而,该方法仅考虑了连续两帧之间的信息,且只适用于线性高斯情况. Clark 在文献[7]中提出了一种基于粒子 PHD 的航迹维持算法,该方法首先对粒子进行标记,通过计算聚类后各个类中不同

标记的粒子数目进行关联.然而,由于没有用到之前的状态信息,当目标距离很近或发生交叉时,来自不同目标的粒子经过重采样后可能具有相同的标记,从而导致失跟或误跟.类似的方法还有 Clark 在文献[8]中提出的高斯项标记法,该方法是在高斯混合 PHD 的框架下提出的,通过对每个高斯项进行标记从而得到每个目标的完整航迹.该方法虽然简单易行,但当目标距离很近或发生交叉时,由于来自不同目标的高斯项之间的合并操作,同样容易导致失跟或误跟. Panta 在文献[9]中提出了一种估计与航迹的关联方法,该方法首先采用之前的多个滤波状态建立多种航迹假设,通过计算每种假设的预测状态与当前状态估计之间的似然函数更新每种假设的对数似然比,从而挑选出最有可能的航迹.然而,该算法虽然考虑了之前的多个滤波状态,但它在计算每种航迹假设的对数似然比时仍然只考虑了相邻两帧之间的信息,因此只要其中的一到两帧发生错误,可能导致整条航迹的关联错误.

针对以上问题,本文提出一种基于模糊聚类的 PHD 航迹维持算法,该方法充分利用多帧信息,对当前时刻状态进行多步预测,并根据惯性进行加权,最后利用模糊聚类求得当前估计属于每条航迹的隶属度,从而得到最终的航迹.实验结果表明,所提算法较传统的估计与航迹关联算法,能够更好地保持目标航迹,即使在目标出现交叉的地方也能达到很好的跟踪精度,具有较强的鲁棒性和优良的航迹维持性能.

2 估计与航迹关联

PHD 滤波算法仅能估计出每时刻所有目标组成的集合,不能识别其中单个目标,即不能够估计出单个目标的完整航迹.针对此问题,文献[9]提出了一种估计与航迹的数据关联算法,下面对其基本步骤做一简要介绍.假设 k 时刻的 \hat{T}_k 个状态估计集合为 $\{\hat{x}_k^i\}_{i=1}^{\hat{T}_k}$,则

步骤 1 初始化:

(a) 根据初始状态 \hat{x}_k^i 起始新航迹

(b) 为每条航迹创建一个新的聚类

步骤 2 预测: 当 $k > 1$ 时,按照状态方程对每条航迹假设的状态和协方差进行预测

步骤 3 跟踪门:

(a) 为与其关联上的每条航迹建立新的假设

(b) 如果没有任何航迹关联则起始一条新航迹

(c) 每条航迹均保留一个漏检假设

步骤 4 更新存在的聚类

步骤 5 更新每条航迹假设的对数似然比(LLR)

$$\text{LLR}_{k,i}^j = \text{LLR}_{k-1,i} + \log(N(\mathbf{m}_{k,i}^j; \hat{\mathbf{m}}_{k-1,i}^j, \mathbf{P}_{k,i}^j + \hat{\mathbf{P}}_{k-1,i}^j)) \quad (1)$$

步骤 6 航迹的确认与修剪

步骤 7 采用有效航迹建立可能的航迹假设树

步骤 8 对航迹进行修剪,即只保留 N 帧以内的信息

步骤 9 对于通过 N 帧修剪的航迹进行量测更新

步骤 10 选取使得整体 LLR 最大的 \hat{T}_k 条航迹作为输出

由于上述算法在更新每种航迹假设的对数似然比时只考虑了相邻两帧之间的信息,因此只要其中的一到两帧发生错误,可能导致整条航迹的关联错误.例如,考虑两目




图1 两目标交叉情况

标发生交叉的情况,如图 1 所示,目标 A 与目标 B 在 k 时刻关联错误,即 $\text{LLR}_{k,A}^A < \text{LLR}_{k,A}^B$, $\text{LLR}_{k,B}^A > \text{LLR}_{k,B}^B$,形成的航迹假设树如图 2 所示(简单起见,不考虑目标漏检情况,且采用具体的数字表示两帧之间对数似然比的大小).可以看出,由于在第 $k-1$ 到第 k 帧发生了关联错误,即使之后的关联全部正确,也可能导致整条航迹的错误.

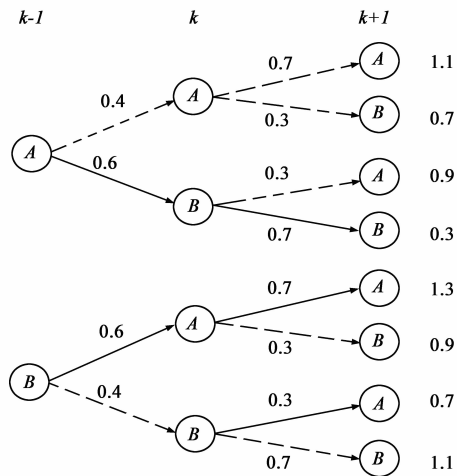


图2 航迹假设树

3 改进算法

针对上节所述问题,本节提出一种基于模糊聚类的 PHD 航迹维持算法,该算法充分利用多帧信息,由不同时刻的滤波状态对当前时刻状态进行 n 步预测,并根据惯性进行加权,最后利用模糊聚类求得当前估计属于每条航迹的隶属度,从而得到最终的航迹.

3.1 基本原理

假设 $k-1$ 时刻的 \hat{T}_{k-1} 个状态估计集合为 $\{\hat{x}_{k-1}^i\}_{i=1}^{\hat{T}_{k-1}}$,若给每个状态估计 \hat{x}_{k-1}^i 分配一个标记 l_{k-1}^i ,则 k 时刻的预测标记集合 $L_{k|k-1}$ 由 $k-1$ 时刻的标记集合 L_{k-1} 和 k 时刻的新生标记集合 $L_{\gamma,k}$ 组成(简单起见,不考虑目标衍生情况).

$$L_{k|k-1} = L_{k-1} \cup L_{\gamma,k} \quad (2)$$

其中, $\mathbf{L}_{k-1} = \{l_{k-1}^1, l_{k-1}^2, \dots, l_{k-1}^{\hat{T}_{k-1}}\}$, \hat{T}_{k-1} 为 $k-1$ 时刻的目标数估计。

为了充分利用多帧信息, 考虑到 k 时刻的标记可能来自之前 N 帧的所有标记集合, 我们将式(2)展开为式(3),

$$\begin{aligned} \mathbf{L}_{k|k-N:k-1} &= \mathbf{L}_{k-N:k-1} \cup \mathbf{L}_{\gamma,k} \\ &= \mathbf{L}_{k-N} \cup \mathbf{L}_{k-N+1} \cup \dots \cup \mathbf{L}_{k-1} \cup \mathbf{L}_{\gamma,k} \end{aligned} \quad (3)$$

其中, $\mathbf{L}_{k-n} = \{l_{k-n}^1, l_{k-n}^2, \dots, l_{k-n}^{\hat{T}_{k-n}}\}$, \hat{T}_{k-n} 为 $k-n$ 时刻的目标数估计, $n=1, 2, \dots, N$, N 为时间衰减窗的窗长, 可按下式进行计算:

$$N = \left\lceil \frac{\ln 2}{\lambda T} \right\rceil \quad (4)$$

其中, $\lceil \cdot \rceil$ 代表取整运算, T 为采样周期, λ 为时间衰减因子, 它的选取与目标运动方式有关. 如果目标做强机动, 则 λ 应取大一些, 如果目标做弱机动, 则 λ 应取小一些.

给集合 \mathbf{L}_{k-n} 中的每个标记赋予一个权值, 该权值与标记距离当前时刻的远近及其对应的 PHD 强度有关:

$$W(l_{k-n}^i) = e^{-n\lambda T} \rho_s^n D_{k-n}(\hat{x}_{k-n}^i) \quad (5)$$

其中, $i=1, 2, \dots, \hat{T}_{k-n}$, $n=1, 2, \dots, N$, $D_{k-n}(\hat{x}_{k-n}^i)$ 为 $k-n$ 时刻状态估计 \hat{x}_{k-n}^i 的 PHD 强度, ρ_s 为目标存活概率, 由式(4)可以看出, 时间衰减系数 $e^{-n\lambda T} \in [0.5, 1]$.

对 $k-n$ 时刻的每个状态估计 \hat{x}_{k-n}^i 按式(6)进行 n 步预测, 可得 k 时刻的预测估计 $\hat{x}_{k|k-n}^i$, 其标记为 l_{k-n}^i , 相应的权值为 $W(l_{k-n}^i)$.

$$\hat{x}_{k|k-n}^i = f_n(\hat{x}_{k-n}^i) \quad (6)$$

其中, $f_n(\cdot)$ 表示 n 步状态转移方程.

以 k 时刻的状态估计 \hat{x}_k^j 作为聚类中心, 对所有预测估计 $\hat{x}_{k|k-n}^i$, $i=1, 2, \dots, \hat{T}_{k-n}$, $n=1, 2, \dots, N$ 进行聚类, 得到 $k-n$ 时刻的第 i 个预测状态 $\hat{x}_{k|k-n}^i$ 属于 \hat{x}_k^j 的模糊隶属度 $u_{ij}^{(n)}$. 设 k 时刻状态估计 \hat{x}_k^j 的存活标记集合记为 $\mathbf{L}_{k,S}^j = \mathbf{L}_{k-N:k-1} = \{l_{k-1}^1, l_{k-1}^2, \dots, l_{k-1}^S\}$, S 为集合 $\mathbf{L}_{k-N:k-1}$ 中元素的个数, 则其中每个元素的权值可下式进行计算:

$$W(l_{k,s}^j) = \frac{\sum_{n=1}^N \sum_{i=1}^{\hat{T}_{k-n}} u_{ij}^{(n)} W(l_{k-n}^i)}{\sum_{n=1}^N W(l_{k-n}^j)}, \text{ if } l_{k-n}^i = l_{k,s}^j \quad (7)$$

其中, $s=1, 2, \dots, S$.

为了关联的方便, 特增加一组虚假标记 $l_{k,0}^j$, 并且令 $W(l_{k,0}^j)$ 等于新生目标 PHD 强度, 则该问题转化为一个二维分配问题, 即通过选取合适的 $\rho(k, j, s)$, 最小化式(8)的全局代价函数,

$$C(k|\rho(k, j, s)) = - \sum_{j=1}^{\hat{T}_k} \sum_{s=0}^S \rho(k, j, s) W(l_{k,s}^j) \quad (8)$$

其中, $\rho(k, j, s)$ 为一个二值变量:

$$\rho(k, j, s) = \begin{cases} 1, & \text{若第 } s \text{ 个标记分配给 } \hat{x}_k^j \\ 0, & \text{否则} \end{cases} \quad (9)$$

满足以下条件:

$$\left. \begin{aligned} \sum_{s=0}^S \rho(k, j, s) &= 1; \forall j = 1, 2, \dots, \hat{T}_k \\ \sum_{j=1}^{\hat{T}_k} \rho(k, j, s) &= 1; \forall s = 1, 2, \dots, S \end{aligned} \right\} \quad (10)$$

该问题可通过拍卖算法求解^[10], 如果 $\exists \rho(k, j, 0) = 1$, 则起始一条新航迹, 并给状态估计 \hat{x}_k^j 分配一个新标记, 最后将具有相同标记的状态估计连接起来便可得到一条完整的航迹.

3.2 最大熵模糊聚类

由上节可知, 该算法需要以 k 时刻的状态估计 \hat{x}_k^j 作为聚类中心, 对所有预测状态进行聚类. 聚类过程可以描述为以下的一个优化过程, 相应的代价函数为:

$$E = \sum_{n=1}^N \sum_{i=1}^{\hat{T}_{k-n}} \sum_{j=1}^{\hat{T}_k} u_{ij}^{(n)} \cdot d(\hat{x}_{k|k-n}^i, \hat{x}_k^j) \quad (11)$$

其中 $d(\hat{x}_{k|k-n}^i, \hat{x}_k^j)$ 表示 $\hat{x}_{k|k-n}^i$ 与聚类中心 \hat{x}_k^j 之间的欧式距离, 并且 $u_{ij}^{(n)}$ 服从如下约束:

$$\sum_{j=1}^{\hat{T}_k} u_{ij}^{(n)} = 1, \forall u_{ij}^{(n)} \in [0, 1] \quad (12)$$

根据信息理论, 为了最小无偏地描述数据点和类中心的隶属度, 可以采用最大熵原理使熵最大化, 由香农熵原理, 表达式为:

$$H = H(u_{ij}^{(n)}) = - \sum_{n=1}^N \sum_{i=1}^{\hat{T}_{k-n}} \sum_{j=1}^{\hat{T}_k} u_{ij}^{(n)} \ln u_{ij}^{(n)} \quad (13)$$

在式(11)和式(12)的约束下, 最大化式(13), 可得 $k-n$ 时刻的第 i 个预测状态 $\hat{x}_{k|k-n}^i$ 与聚类中心 \hat{x}_k^j 的隶属度为:

$$u_{ij}^{(n)} = \frac{e^{-\alpha_i^{(n)} d(\hat{x}_{k|k-n}^i, \hat{x}_k^j)}}{\sum_{j=1}^{\hat{T}_k} e^{-\alpha_i^{(n)} d(\hat{x}_{k|k-n}^i, \hat{x}_k^j)}} \quad (14)$$

其中, $\alpha_i^{(n)}$ 为差异因子, 通过变化 $\alpha_i^{(n)}$ 可以调整 $\hat{x}_{k|k-n}^i$ 与最近聚类中心及其它类中心的隶属度值.

设 $d_{i,\min}^{(n)}$ 为 $\hat{x}_{k|k-n}^i$ 与最近聚类中心的欧式距离, 则在满足下式的情况下, 可得最优的 $\alpha_i^{(n)}$.

$$\exp(-\alpha_{i,\text{opt}}^{(n)} d_{i,\min}^{(n)}) = \varepsilon \quad (15)$$

其中, ε 是一个小正常数, 仿真实验中设为 0.51.

在式(15)的条件下, E 可以达到饱和, 这时可以得到最优值:

$$\alpha_{i,\text{opt}}^{(n)} = - \frac{\ln(\varepsilon)}{d_{i,\min}^{(n)}} \quad (16)$$

将 $\alpha_{i,\text{opt}}^{(n)}$ 代入式(14)即可得到 $k-n$ 时刻的第 i 个预测状态 $\hat{x}_{k|k-n}^i$ 与聚类中心 \hat{x}_k^j 的隶属度 $u_{ij}^{(n)}$, 再将其代入式(7)即可求得标记 $l_{k,s}^i$ 的权值 $W(l_{k,s}^i)$, 从而对航迹进行关联。

4 仿真与分析

本节通过模拟真实二维空间内的多目标交叉情况来验证本文算法性能. 采用三个被动传感器观测多个交叉目标, 传感器位置分别为 $s_1(0, -50)\text{km}$, $s_2(40, 30)\text{km}$ 和 $s_3(80, -50)\text{km}$, 每个目标在二维平面上的运动方程如下:

$$\mathbf{x}_k = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{\Gamma}w_k \quad (17)$$

其中, $\mathbf{x}_k = [\xi_{x,k}, \dot{\xi}_{x,k}, \xi_{y,k}, \dot{\xi}_{y,k}]^T$ 表示 2 维坐标的位置

$$\text{和速度分量, } \mathbf{F} = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{\Gamma} = \begin{bmatrix} \frac{1}{2} & 0 \\ 1 & 0 \\ 0 & \frac{1}{2} \\ 0 & 1 \end{bmatrix},$$

$$w_k \sim N\left(0, \begin{bmatrix} \sigma_w^2 & 0 \\ 0 & \sigma_w^2 \end{bmatrix}\right), \sigma_w = 0.5, \text{ 采样间隔 } T = 1\text{s}.$$

每个目标的存活概率 $p_s = 0.9$ 及检测概率 $p_D = 0.99$ 为常数. 简单起见, 不考虑目标衍生的情况, 新生目标随机集服从 Poisson 分布, 其 PHD 为:

$$\gamma_k(x) = \sum_{i=1}^5 0.2N(x; \mathbf{m}_\gamma^i, \mathbf{P}_\gamma) \quad (18)$$

其中, $\mathbf{m}_\gamma^1 = [0, 0, 0, 0]^T$, $\mathbf{m}_\gamma^2 = [25, 0, -35, 0]^T$, $\mathbf{m}_\gamma^3 = [40, 0, 15, 0]^T$, $\mathbf{m}_\gamma^4 = [65, 0, -20, 0]^T$, $\mathbf{m}_\gamma^5 = [55, 0, -55, 0]^T$, $\mathbf{P}_\gamma = \text{diag}\{10, 5, 10, 5\}$.

设三个传感器的观测噪声标准差均为 $\sigma_s = 0.03\text{rad}$, 杂波数服从均值为 10 的 Poisson 分布, 在观测空间中均匀分布. 在粒子 PHD 的框架下实现贝叶斯递归, 每个目标采样 1000 个粒子, 新算法中的时间衰减因子 $\lambda = 0.2$.

图 3 所示为估计与航迹关联算法的航迹维持性能. 可以看出, 标记为点的目标和标记为叉的目标在相交之后, 其航迹发生了互换. 这是因为该算法在更新每种航迹假设的对数似然比时只考虑了相邻两帧之间的信息, 而在交点附近的不同目标状态难以区分, 此时一旦发生关联错误则可能导致整条航迹的错误.

图 4 所示为本章所提算法的航迹维持性能. 可以看出, 在这种情况下的所有目标均关联正确, 航迹维持效果良好. 这是因为该算法充分利用了多帧信息, 虽然交点处的不同目标状态难以区分, 但交点前 n 个时刻的目标状态则相对容易区分, 这些目标状态通过加权聚类等操作均参与最终的判决, 因此其鲁棒性更强, 具有

良好的航迹维持性能.




图3 估计与航迹关联算法的航迹维持性能




图4 本章所提算法的航迹维持性能

通过统计不同量测噪声标准差 σ_v 和不同检测概率 P_d 情况下, 每条航迹的平均标记个数进一步考察算法性能. 理想情况下, 每条航迹只有一个标记, 若发生图 3 所示情况, 由于有两条航迹具有两个标记, 三条航迹具有一个标记, 则平均标记数为 1.4. 因此, 通过统计每条航迹的平均标记个数即可反映出航迹维持性能的好坏, 平均标记数越接近于 1, 航迹维持性能越好. 保持实验环境不变, 进行 100 次蒙特卡洛实验, 结果如表 1 和表 2 所示. 可以看出, 随着观测噪声的增加和检测概率的降低, 航迹维持效果均有所下降, 但本文所提算法普遍优于传统的估计与航迹关联算法.

表 1 检测概率 $P_d = 0.95$ 时的算法性能对比

	每条航迹的平均标记数			平均单步运行时间 (s)
	$\sigma_v = 0.1$	$\sigma_v = 0.4$	$\sigma_v = 0.7$	
估计与航迹关联	1.4275	1.4889	1.5222	0.2876
本章所提算法	1.0508	1.0754	1.1444	0.7654

表 2 量测噪声标准差 $\sigma_v = 0.5\text{m}$ 时的算法性能对比

	每条航迹的平均标记数			平均单步运行时间 (s)
	$P_d = 1$	$P_d = 0.95$	$P_d = 0.9$	
估计与航迹关联	1.3081	1.4925	1.6049	0.3183
本章所提算法	1.0417	1.1208	1.1951	0.9011

值得注意的是, 由于本文所提算法中包含加权聚类步骤, 运算复杂度略高于传统算法. 因此, 实际应

用中应结合具体情况选择合适的算法,以达到关联精度和运算效率之间的折中。

5 结论

传统的估计与航迹关联算法在更新每条航迹信息时仅是对相邻帧之间的对数似然比进行简单的求和,因此只要其中的一到两帧发生错误,可能导致整条航迹的关联错误。

针对以上问题,本文提出一种基于模糊聚类的 PHD 航迹维持算法。该算法充分利用多帧信息,由不同时刻的滤波状态对当前时刻状态进行 n 步预测,并根据惯性进行加权,最后利用模糊聚类求得当前估计属于每条航迹的隶属度,从而得到最终的航迹。实验结果表明,所提算法能够更好地保持目标航迹,即使在目标出现交叉的地方也能达到很好的跟踪精度,具有较强的鲁棒性和优良的航迹维持性能。值得注意的是,算法中某些参数的设置缺乏指导,如何设置参数、对算法进行优化以降低算法执行时间,进一步提高关联正确率都是今后需要开展的工作。

参考文献

- [1] 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.
- [2] 徐晓滨, 文成林, 刘荣利. 基于随机集理论的多源信息统一表示与建模方法 [J]. 电子学报, 2008, 36(6): 1174 – 1181.
XU Xiao-bin, WEN Cheng-lin, LIU Rong-li. The unified method of describing and modeling multisource information based on random set theory [J]. Acta Electronica Sinica, 2008, 36(6): 1174 – 1181.
- [3] Shoenfeld Peter S. A particle filter algorithm for the multi-target probability hypothesis density [A]. Signal Processing, Sensor

Fusion, and Target Recognition XIII [C]. Orlando, FL, USA: SPIE, 2004. 315 – 325.

- [4] Vo B-N, Ma W-K. The Gaussian mixture probability hypothesis density filter [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091 – 4104.
- [5] K Panta, B Vo, S Singh, A Doucet. Probability hypothesis density filter versus multiple hypothesis tracking [A]. Signal Processing, Sensor Fusion, and Target Recognition XIII [C]. Orlando, FL, USA: SPIE, 2004. 284 – 295.
- [6] Lin Lin. Parameter Estimation and Data Association for Multi-target Tracking [D]. Connecticut, USA: The University of Connecticut, 2004.
- [7] D E Clark, J Bell. Data association for the PHD filter [A]. Proceedings of the International Conference on Intelligent Sensors, Sensor Networks and Information Processing [C]. Cairns, Australia: IEEE Press, 2005. 217 – 222.
- [8] Clark D E, Panta K, Vo B N. The GM-PHD filter multiple target tracker [A]. Proceedings of 2006 9th International Conference on Information Fusion [C]. Florence: IEEE, 2006. 1 – 8.
- [9] Panta K, Vo Ba-Ngu, Singh S. Novel data association schemes for the probability hypothesis density filter [J]. IEEE Transactions on Aerospace and Electronic Systems, 2007, 43(2): 556 – 570.
- [10] Bertsekas D P. The auction algorithm: A distributed relaxation method for the assignment problem [J]. Annals of Operate Res, 1988, 14(1): 105 – 123.

作者简介

欧阳成 男, 1985 年生, 博士生, 被动多传感器定位与跟踪, 信息融合. E-mail: ouoye@yahoo.com.cn

姬红兵 男, 1963 年生, 教授, 博士生导师, 光电信息处理、智能信息处理、被动多传感器定位与跟踪、雷达目标识别与分类、微弱信号检测与识别、医学影像处理等。

田野 男, 1986 年生, 硕士生, 信号处理与检测, 目标跟踪。