

基于改进的 PHD 粒子滤波的多目标跟踪技术

龙建乾 杨 威 付耀文

(国防科技大学电子科学与工程学院, 湖南长沙 410073)

摘要: 有限集统计学(FISST)理论将任意时刻目标状态的集合视为多目标集值状态, 而相应的传感器观测值集合被视为多目标集值观测。通过随机有限集建模并利用集合的微积分运算可推导出最优多目标贝叶斯滤波器。然而由于涉及集合微积分运算, 最优多目标贝叶斯滤波器的运算量极大。概率假设密度(PHD)滤波器是最优多目标贝叶斯滤波器的一阶矩近似, 可以实现在关联不确定、目标数目未知或变化情况下的多目标状态估计。相比于最优多目标跟踪技术, 基于 PHD 滤波器的多目标跟踪技术的运算复杂度得到了有效的降低, 更易于工程应用。但在密集杂波背景下 PHD 滤波器的粒子实现方法仍然存在运算复杂度过高的问题。本文针对密集杂波的情形, 提出一种有效的杂波滤除方法, 在不影响滤波性能的情况下, 降低了运算复杂度, 提高了滤波效率。

关键词: 多目标跟踪; 概率假设密度滤波; 粒子滤波; 门限

中图分类号: TN911.7 **文献标识码:** A **文章编号:** 1003-0530(2011)09-1296-05

Multi-target Tracking Based on Improved Particle PHD Filter

LONG Jian-qian YANG Wei FU Yao-wen

(The Electron Sci. and Eng. Inst., Nat. Univ. of Defense Technology, Changsha 410073, China)

Abstract: The finite set statistics theory (FISST) treats the collection of target states at any given time as a set-valued multi-target state, and the corresponding collection of sensor measurements is treated as a set-valued multi-target observation. Modeling set-valued states and set-valued observations as random finite sets (RFSs) allows the problem of dynamically estimating multiple targets to be cast in an optimal Bayesian filtering framework. This theoretically optimal approach to multiple targets tracking involves set integrals on the multi-target state space, which are computationally intractable. The PHD filter is the first order moment approximation of the optimal multi-target Bayesian filter, which can track an unknown and time-varying number of targets under association uncertainty. The computational load of the multi-target tracking method based on the PHD filter is much lower than the optimal multi-target Bayesian filtering methods, so it is more applicable to engineer application. However, the particle PHD filter is still computationally intensive in dense clutter environment. This paper proposes an approach to eliminate some of the clutter from the measurement set at any particular time. The proposed approach does not influence the estimate accuracy significantly, but it alleviates the computational complexity of the particle PHD filter and improves the efficiency of filtering.

Key words: Multi-target Tracking; Probability Hypothesis Density Filter; Particle Filter; Gating

1 引言

传统目标跟踪技术的难点在于数据关联^[1], 但现有的各种数据关联算法都存在着各自的缺陷, 比如: 概率数据关联(PDA)只能处理杂波环境下单个目标的跟踪问题, 但是不能处理多目标跟踪问题; 联合概率数据关联(JPDA)只适用于跟踪固定数目的多个目标, 而且

构建所有可能关联事件是一个 NP hard 问题^[2]; 多假设数据关联(MHT)存在组合爆炸问题, 即随着传感器扫描周期的增加, 各种假设的数目呈指数增长。

在有限集统计学(Finite-Set Statistics: FISST)^[3,4]理论框架下, 所有个体目标状态的集合被视为一个集值状态, 而一次观测所获得的所有观测值集合被视为集值观测。将集值状态和集值观测建模为随机有限集

后,就可以利用最优多目标贝叶斯滤波器实现关联不确定、目标数目未知或变化情况下多目标状态的估计。理论上最优多目标贝叶斯滤波器运算复杂度非常高。Mahler 将单传感器单目标中的近似方法推广到多传感器多目标系统的研究中,提出了概率假设密度(Probability Hypothesis Density: PHD)^[5,6] 滤波器。相比于最优多目标贝叶斯滤波器,PHD 滤波器的运算复杂度有很大降低。B. -N. Vo 给出了 PHD 滤波器的两种收敛实现:序贯 Monte Carlo PHD (SMC-PHD)^[7],即粒子滤波的方法,以及高斯混合的 PHD(GM-PHD)^[8,9]。同一时期,zajic^[10]、H. Sidenbladh^[11]等也分别采用粒子滤波方法实现了 PHD 滤波器。

作为最优多目标贝叶斯滤波器的一阶矩近似,PHD 滤波器比最优多目标贝叶斯滤波器的运算复杂度降低了不少,但是在密集杂波背景下 PHD 滤波器的粒子实现方法仍然存在运算复杂度过高的问题。本文在 PHD 粒子滤波的过程中,通过设定门限,将位于门限之外的观测值滤除,仅利用位于门限内的观测值进行粒子权重的更新,在保证目标估计性能的前提下大大降低了运算量,并且通过仿真验证了该方法的有效性。

2 概率假设密度 (PHD) 滤波

利用随机集表示多目标的状态和传感器测量,可以将多传感器、多目标系统看成全局的单传感器、单目标系统。进一步地,利用有限集统计学理论,可以将关于单目标的 Bayes 滤波方法推广到多目标系统^[12]。

随机集的引入为多目标 Bayes 滤波提供了与单目标 Bayes 滤波相一致的形式。但当目标数目较大时,全局密度的计算是极为困难的。这就使得传递全局密度的多目标 Bayes 滤波在工程上很难应用。解决这一问题的一个有效方法,是利用概率假设密度(PHD)^[5,6]来代替多目标 Bayes 滤波中的全局密度。这样可以大大降低计算负担。

随机有限集 Ξ 的 PHD 定义为:

$$\nu(\mathbf{x}) = E \left[\sum_{y \in \Xi} \delta_y(\mathbf{x}) \right] = \int \sum_{y \in \Xi} \delta_y(\mathbf{x}) f_{\Xi}(X) \delta X \quad (1)$$

在多目标跟踪系统中, $\nu(\mathbf{x}_0)$ 是在 \mathbf{x}_0 点的期望的目标密度。 $\int_S \nu(\mathbf{x}) d\mathbf{x}$ 是出现在区域 S 内的期望的目标数,而 $\nu(\mathbf{x})$ 的峰值点对应的状态即为目标的状态估计。

PHD 预测方程:

$$\nu_{k|k-1}(\mathbf{x}) = \int p_{s,k}(\zeta) f_{k|k-1}(\mathbf{x} | \zeta) \nu_{k-1}(\mathbf{x}) d\zeta +$$

$$\int \beta_{k|k-1}(\mathbf{x} | \zeta) \nu_{k-1}(\mathbf{x}) d\zeta + \gamma_k(\mathbf{x}) \quad (2)$$

其中:

$p_{s,k}(\zeta)$ 状态为 ζ 的目标在 k 时刻仍然存在的概率;

$f_{k|k-1}(\mathbf{x} | \zeta)$ k 时刻状态为 ζ 的目标的转移概率密度;

$\beta_{k|k-1}(\mathbf{x} | \zeta)$ k 时刻由状态为 ζ 的目标衍生的目标的强度函数;

$\gamma_k(\mathbf{x})$ k 时刻新生目标的强度函数;

假设目标相互独立运动,则 PHD 更新方程可以用下式近似计算:

$$\nu_k(\mathbf{x}) = [1 - p_{D,k}(\mathbf{x})] \nu_{k|k-1}(\mathbf{x}) + \sum_{z \in Z_k} \frac{p_{D,k}(\mathbf{x}) g_k(\mathbf{z} | \mathbf{x}) \nu_{k|k-1}(\mathbf{x})}{\kappa_k(\mathbf{z}) + \int p_{D,k}(\zeta) g_k(\mathbf{z} | \zeta) \nu_{k|k-1}(\zeta) d\zeta} \quad (3)$$

其中:

$p_{D,k}(\mathbf{x})$ k 时刻状态为 \mathbf{x} 的目标被检测到的概率;

$\kappa_k(\mathbf{z})$ k 时刻杂波集的强度函数;

$g_k(\mathbf{z} | \mathbf{x})$ k 时刻目标的似然函数。

对更新后的 PHD 进行积分,取最接近的整数值,即可得到当前时刻目标数的期望值。而各个目标的状态可以从更新之后的 PHD 峰值点对应的状态估计获得。

事实上 $\nu(\mathbf{x})$ 的解析表达式是无法给出的,所以 PHD 滤波很难直接实现,通常选择近似方法进行处理,而其中基于蒙特卡罗采样近似的粒子滤波(Particle Filter: PF)算法是最常用的手段。

3 PHD 粒子滤波及其改进

3.1 PHD 粒子滤波

正如 Mahler 在文献[12]所说明,由于 PHD 滤波器类似于单传感器单目标 Bayes 滤波器,所以原则上它可以用任意的非线性滤波技术来实现。最典型的就是 Vo 提出的序贯蒙特卡^[7],即 PHD 粒子滤波实现的跟踪方法,其步骤如下所述。

步骤 1 预测

给定重要性函数 $p_k(\cdot | Z_k)$ 、 $q_k(\cdot | \mathbf{x}_{k-1}, Z_k)$ 。对于任意 $k \geq 1$ 时刻,预测粒子为 $\tilde{\mathbf{x}}_k^{(i)} \sim q_k(\cdot | \mathbf{x}_{k-1}^{(i)}, Z_k)$, $i = 1, \dots, L_{k-1}$,其中 L_k 为时刻的粒子数目($L_0 = 0$ 表示滤波开始前粒子数目为零,即存在任何目标),对应粒子的预测权重为:

$$\tilde{w}_{k|k-1}^{(i)} = \frac{\phi_{k|k-1}(\tilde{\mathbf{x}}_k^{(i)}, \mathbf{x}_{k-1}^{(i)})}{q_k(\tilde{\mathbf{x}}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, Z_k)} w_{k-1}^{(i)} \quad (4)$$

其中 $\phi_{k|k-1}(\mathbf{x}, \xi) = \beta_{k|k-1}(\mathbf{x} | \xi) + p_{S,k}(\xi) f_{k|k-1}(\mathbf{x} | \xi)$, 新生目标粒子采样 $\tilde{\mathbf{x}}_k^{(i)} \sim p_k(\cdot | Z_k)$, $i = L_{k-1} + 1, \dots, L_{k-1} + J_k$, 其中 J_k 是用于初始化新生目标粒子的数目, 对应粒子的权重为:

$$\tilde{w}_{k|k-1}^{(i)} = \frac{1}{J_k} \frac{\gamma_k(\tilde{\mathbf{x}}_k^{(i)})}{p_k(\tilde{\mathbf{x}}_k^{(i)} | Z_k)} \quad (5)$$

步骤2 更新

对于每个观测值 $\mathbf{z} \in Z_k$, 计算 $C_k(\mathbf{z}) = \sum_{j=1}^{L_{k-1}+J_k} \varphi_{k,z}(\tilde{\mathbf{x}}_k^{(j)})$

$\tilde{w}_{k|k-1}^{(j)}$, 其中 $\varphi_{k,z}(\mathbf{x}) = p_D(\mathbf{x}) g_k(\mathbf{z} | \mathbf{x})$, $g_k(\mathbf{z} | \mathbf{x})$ 是似然函数; 然后更新粒子权重得到:

$$\tilde{w}_k^{(i)} = \left[\nu(\tilde{\mathbf{x}}_k^{(i)}) + \sum_{\mathbf{z} \in Z_k} \frac{\varphi_{k,z}(\tilde{\mathbf{x}}_k^{(i)})}{\kappa_k(\mathbf{z}) + C_k(\mathbf{z})} \right] \tilde{w}_{k|k-1}^{(i)}, \quad i = 1, \dots, L_{k-1} + J_k \quad (6)$$

步骤3 重采样

计算得到目标的估计数目:

$$\hat{N}_{k|k} = \sum_{j=1}^{L_{k-1}+J_k} \tilde{w}_k^{(j)} \quad (7)$$

对归一化权重的粒子 $\{(\tilde{w}_k^{(i)} / \hat{N}_{k|k}), \tilde{\mathbf{x}}_k^{(i)}\}_{i=1}^{L_{k-1}+J_k}$ 重采样得到 $\{(w_k^{(i)} / \hat{N}_{k|k}), \mathbf{x}_k^{(i)}\}_{i=1}^{L_k}$, 然后恢复权重总和得到重采样后的粒子 $\{w_k^{(i)}, \mathbf{x}_k^{(i)}\}_{i=1}^{L_k}$.

3.2 改进的 PHD 粒子滤波

在 PHD 滤波的粒子实现过程中, 我们发现, 在密集杂波的情况下, 远离粒子的杂波测量对粒子权重的更新影响不大, 但是却需要大量的运算。如图 1, 由于更新式(3)式或者(6)式中似然函数的作用, 远离粒子的杂波测量对粒子权重的更新作用微乎其微, 于是可以通过设定门限将杂波测量排除, 使其不再用于相应粒子的更新, 这样, 在对粒子权重的更新几乎没有影响的情况下, 将会大大地降低运算量。

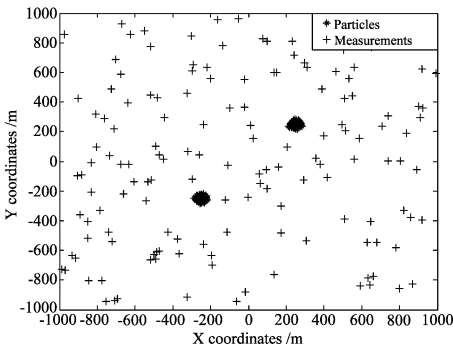


图1 粒子及观测值

Fig. 1 Particles and measurements

将 PHD 滤波更新式(3)式修改如下,

$$\nu_k'(\mathbf{x}) = [1 - p_{D,k}(\mathbf{x})] \nu_{k|k-1}(\mathbf{x}) + \sum_{\mathbf{z} \in Z_k'(\mathbf{x}) \subset Z_k} \frac{p_{D,k}(\mathbf{x}) g_k(\mathbf{z} | \mathbf{x}) \nu_{k|k-1}(\mathbf{x})}{\kappa_k(\mathbf{z}) + \int p_{D,k}(\xi) g_k(\mathbf{z} | \xi) \nu_{k|k-1}(\xi) d\xi} \quad (8)$$

其中 $Z_k'(\mathbf{x}) = \{\mathbf{z} | \varphi(\mathbf{z}, \mathbf{x}) \leq \gamma, \forall \mathbf{z} \in Z_k\}$, $\varphi(\cdot), \gamma$ 待定。

下面根据文献[13]的方法确定 $\varphi(\cdot)$ 的具体形式以及相应的 γ 。

非线性系统可通过测量转换等方法近似为线性系统^[14,15,16]。这里针对线性系统, 假设目标的预测方程及观测方程如下,

$$\mathbf{x}_{k|k-1} = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{v}_k \quad \mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{w}_{k-1} \quad (9)$$

这里 \mathbf{F} 、 \mathbf{H} 分别是状态转移矩阵和观测矩阵; \mathbf{v}_k 、 \mathbf{w}_{k-1} 都是满足高斯分布, 均值为 $\mathbf{0}$ 、协方差分别为 \mathbf{R}_v 、 \mathbf{R}_w 的过程噪声和观测噪声。则有

$$\varphi(\mathbf{z}, \mathbf{x}) = (\mathbf{z} - \mathbf{H}\mathbf{x})^T \mathbf{S}_k^{-1} (\mathbf{z} - \mathbf{H}\mathbf{x}) \leq \gamma \quad (10)$$

其中 \mathbf{S}_k 称为残差协方差矩阵, 并且

$$\mathbf{S}_k = \mathbf{H}\mathbf{P}_{k|k-1}\mathbf{H}^T + \mathbf{R}_w \quad (11)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}\mathbf{P}_{k-1}\mathbf{F}^T + \mathbf{R}_v \quad (12)$$

这里 $\mathbf{P}_{k|k-1}$ 为一步预测协方差矩阵, 而 \mathbf{P}_{k-1} 是目标状态协方差矩阵。

显然 \mathbf{P}_{k-1} 就是 $\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1}$ 的协方差 ($\hat{\mathbf{x}}_{k-1}$ 为滤波结果, 即对目标状态 \mathbf{x}_{k-1} 的估计), 这样可以假定 $\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1} \sim N(\mathbf{0}, \mathbf{R})$, 并且协方差矩阵 \mathbf{R} (是一个对角阵) 对应于方位的项不大于观测噪声方差, 对应于速度的项不大于过程噪声方差。以二维平面运动为例, 设 \mathbf{R}_v 的对角元素 $(\mathbf{R}_v)_{ii} = \sigma_{vi}^2, i = 1, 2, 3, 4$ 、 \mathbf{R}_w 的对角元素 $(\mathbf{R}_w)_{ii} = \sigma_{wi}^2, i = 1, 2$, 则有以下不等式成立,

$$(\mathbf{R})_{ii} \leq ([\sigma_{w1}^2 \ \sigma_{w2}^2 \ \sigma_{w3}^2 \ \sigma_{w4}^2]^T)_i, i = 1, 2, 3, 4 \quad (13)$$

式中 $(\cdot)_{ii}$ 表示矩阵的对角向量的第 i 个元素, $(\cdot)_i$ 表示向量的第 i 个元素。

如此, \mathbf{R} 便可用 $diag([\sigma_{w1}^2 \ \sigma_{w2}^2 \ \sigma_{w3}^2 \ \sigma_{w4}^2]^T)$ 代替, 这里 $diag(\cdot)$ 表示对角矩阵。至于 γ 的取值, 可以依据文献[13]结合具体条件而获得。

4 实验仿真

假设观测区域为 $[-1000, 1000] \text{m} \times [-1000, 1000] \text{m}$, 状态向量 $\mathbf{x} = [x \ x' \ y \ y']^T$, 采样周期 $T = 1\text{s}$, 状态转

$$\text{移矩阵 } \mathbf{F} = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, \text{ 观测矩阵 } \mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \text{ 过程}$$

$$\text{噪声协方差 } \mathbf{R}_v = \begin{bmatrix} T^4/4 & T^3/3 & 0 & 0 \\ T^3/3 & T^2 & 0 & 0 \\ 0 & 0 & T^4/4 & T^3/3 \\ 0 & 0 & T^3/3 & T^2 \end{bmatrix} \sigma_v^2, \sigma_v =$$

$$10\text{m/s}^2, \text{观测噪声协方差 } \mathbf{R}_w = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \sigma_w^2, \sigma_w = 10\text{m}.$$

目标存活概率 p_s 为 0.99, 目标检测概率 p_d 为 0.98; 设定场景中出现 N (服从 $[1, 8]$ 的整值均匀分布) 个目标, 且各个目标的出现时刻 (服从 $[1, 20]$ 的整值均匀分布) 及消失时刻 (服从 $[21, 40]$ 的整值均匀分布) 在跟踪期间相互独立, 进行 100 次蒙特卡洛仿真。

下面对添加门限前后的目标估计性能及平均每次完整的滤波过程耗费的时间进行对比, 以此验证添加门限的有效性。这里, 我们使用文献 [17] 所定义的 OPTIMAL SUBPATTERN ASSIGNMENT (OSPA) 距离用于衡量多目标估计的性能。OSPA 能够同时刻画目标数目估计及状态估计的性能, 其值越小表示多目标估计的性能越好。而平均每次完整的滤波过程耗费的时间是对滤波效率的反映, 耗费的时间越少表示滤波效率越高, 滤波过程的运算复杂度越低。




图 2 目标真实位置、观测值及其估计位置
Fig. 2 Target true positions, measurements and estimates.

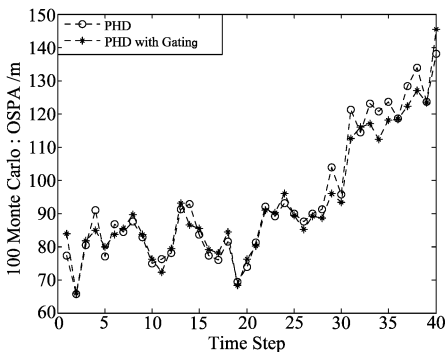


图 3 杂波密度为 $4 \times 10^{-5} \text{m}^{-2}$ (平均 160 个杂波) 情况下的 OSPA
Fig. 3 Tracking performance OSPA. The intensity of clutter is fixed at $4 \times 10^{-5} \text{m}^{-2}$

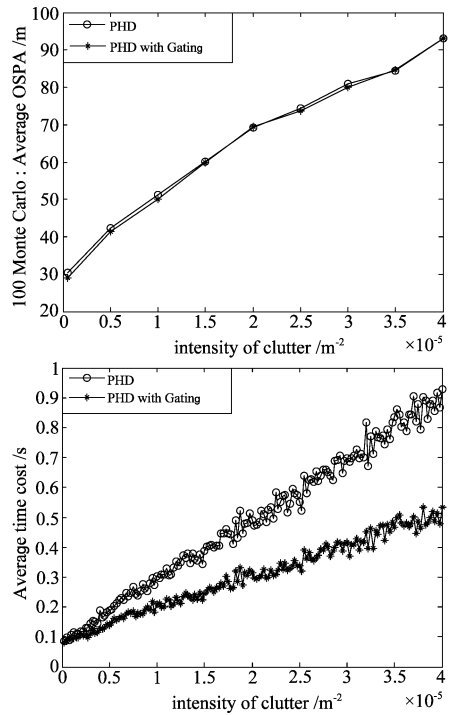


图 4 不同杂波密度情况下的平均 OSPA、每个滤波周期的平均用时
Fig. 4 Average OSPA and time cost versus intensity of clutter

由图 4 可见, 不同杂波密度情况下, 添加门限前后的目标估计性能基本维持在同等水平; 而且在添加门限之后, 程序运行的时间明显减少, 说明添加门限后明显地减少了运算量, 大大提高了 PHD 粒子滤波的滤波效率。

5 结论

杂波量测给 PHD 滤波器的粒子实现增加运算量, 本文针对密集杂波背景下的 PHD 粒子滤波, 提出通过添加门限的方法以达到在不影响多目标估计性能的情况下减少运算量的目的。由仿真结果可知, 添加门限之后的 PHD 粒子滤波在保证目标的估计性能的前提下, 运算复杂度明显降低, 运行时间明显减少, 验证了添加门限方法的有效性。

参考文献

[1] Y. Bar-Shalom, T. E. Fortmann. Tracking and Data Association[M]. Boston: Academic Press, 1988.
 [2] B.-T. Vo, B.-N. Vo, A. Cantoni. Analytic Implementations of the Cardinalized Probability Hypothesis Density Filter [J]. IEEE Transactions on Signal Processing, 2007, 55(7):3553-3567.
 [3] R. Mahler. Global integrated data fusion[J]. In Proceedings of the 7th National Symposium on Sensor Fusion,

- vol. 1 (unclassified), Sandia National Laboratories, Albuquerque, NM, 1994, 187-199.
- [4] R. Mahler. An Introduction to Multisource-Multitarget Statistics and Its Applications[J]. Lockheed Martin Technical Monograph, 2000.
- [5] I. R. Goodman, R. Mahler, H. Nguyen. Mathematics of Data Fusion[M]. Boston: Kluwer Academic Publishers, 1997.
- [6] R. Mahler. Statistical Multisource Multitarget Information Fusion[M]. Norwood MA; Artech House, 2007.
- [7] B.-N. 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.
- [8] B.-N. Vo, W. K. Ma. The Gaussian Mixture Probability Hypothesis Density Filter[J]. IEEE Transactions on Signal Processing, 2006, 54(11):4091-4104.
- [9] D. Clark, B.-N. Vo. Convergence Analysis of the Gaussian Mixture PHD filter[J]. IEEE Transactions on Signal Processing, 2007, 55(4):1204-1211.
- [10] T. Zajic, R. Mahler. A particle-systems implementation of the PHD multi-target tracking filter[C]. Proceedings of SPIE, Signal Processing, Sensor Fusion and Target Recognition, Vol. 5096, 2003. 291-299.
- [11] H. Sidenbladh. Multi-Target Particle Filtering for the Probability Hypothesis Density[J]. In Proceedings of the 6th International Conference on Information Fusion, Cairns, Australia, 2003, 800-806.
- [12] R. Mahler. Multitarget Bayes filtering via first-order multitarget moments [J]. IEEE Transactions on Aerospace and Electronics Systems, 2003, 39(3):1152-1178.
- [13] 周宏仁, 敬忠良, 王培德. 机动目标跟踪[M]. 北京: 国防工业出版社, 1991. 134-153.
- [14] D. Ierro, Y. bar. shalom. Tracking With Debiased Consistent Converted Measurements Versus EKF[J]. IEEE Transactions on Aerospace and Electronic Systems, 1993, 29(3): 1015-1022.
- [15] F. J. Harris. Explicit Expressions for Debiased Statistics of 3D Converted Measurements[J]. IEEE Transactions on Aerospace and Electronic Systems, 1999, 35(1): 368-370.
- [16] A. Farina, B. Ristic, D. Benvenuti. Tracking a ballistic target: comparison of several nonlinear filters[J]. IEEE Transactions on Aerospace and Electronic Systems, 2002, 38(3):854-867.
- [17] D. Schuhmacher, B.-T. Vo, B.-N. Vo. A Consistent Metric for Performance Evaluation of Multi-Object Filters [J]. IEEE Transactions on Signal Processing, 2008, 56(8): 3447-3457.

作者简介



龙建乾(1986-),男,广西南宁人,现为国防科学技术大学硕士研究生,研究方向为信息融合、目标跟踪。
E-mail:longjts@126.com



杨威(1985-),男,江西丰城人,现为国防科学技术大学博士研究生,研究方向为信息融合、目标跟踪与目标识别。
E-mail:yw850716@sina.com



付耀文(1976-),男,江西进贤人,现为国防科学技术大学副教授,研究方向为雷达信号处理与信息融合。
E-mail:fuyaowen@sina.com