

一种幅度信息辅助多伯努利滤波算法

袁常顺 王 俊* 孙进平 孙忠胜 毕严先
(北京航空航天大学电子信息工程学院 北京 100191)

摘要:在许多多目标跟踪场景中,目标返回的幅度通常强于虚警杂波返回的幅度。通过建立更加准确的包含幅度信息的目标和虚警杂波似然函数,可提高多目标估计精度。该文提出一种基于随机有限集的幅度信息辅助多伯努利滤波(Amplitude Information Assistant Multi-Bernoulli Filter, AIA-MBerF)算法。该算法通过建立幅度似然函数将幅度信息引入到多伯努利滤波的更新过程中,并给出针对线性和非线性模型的高斯混合(Gaussian Mixture, GM)和序贯蒙特卡洛(Sequential Monte Carlo, SMC)实现方法。仿真结果表明,该滤波算法相比于传统多伯努利滤波(Multi-Bernoulli Filter, MBerF)无论GM还是SMC实现都可获得更加准确稳定的目标数和对应的目标状态估计。
关键词:多目标跟踪;随机有限集;幅度信息;多伯努利滤波

中图分类号: TN953

文献标识码: A

文章编号: 1009-5896(2016)02-0464-08

DOI: 10.11999/JEIT150683

A Multi-Bernoulli Filtering Algorithm Using Amplitude Information

YUAN Changshun WANG Jun SUN Jinping SUN Zhongsheng BI Yanxian
(School of Electronics and Information Engineering, Beihang University, Beijing 100191, China)

Abstract: In many multi-target tracking scenarios, the amplitude of target returns are stronger than those coming from false alarms. This amplitude information can be used to improve the multi-target state estimation by obtaining more accurate target and false-alarm likelihoods. In this paper, a novel multi-Bernoulli filtering algorithm is proposed, which is based on the random finite set and incorporate the amplitude information. The amplitude likelihood functions are derived to incorporate the amplitude information into the multi-Bernoulli filter in the update step. In addition, a Gaussian Mixture (GM) implementation for the linear model and a Sequential Monte Carlo (SMC) implementation for the non-linear model are proposed. Simulation results for Gaussian Mixture and Sequential Monte Carlo implementations show that the proposed filter demonstrates a significant improvement than conventional multi-Bernoulli filter in the estimation accuracy of both the number of targets and their states.

Key words: Multi-target tracking; Random finite set; Amplitude information; Multi-Bernoulli filter

1 引言

多目标跟踪一直是目标跟踪领域研究的热点,其目的是从量测中联合估计时变且未知目标数和对目标运动状态^[1]。由于传感器自身特性,检测器提供给跟踪器的目标量测是不可靠的:一部分量测可能是杂波,一部分真实目标被漏检;跟踪器利用观测模型从量测中识别正确的目标,根据目标的运动

状态模型跟踪目标。许多传感器,例如雷达和声呐,可同时实现对目标位置和幅度的测量。由于目标的信号幅度通常强于杂波,因此为区分量测来源于目标或者杂波提供了一个有价值的信息。在低信噪比目标跟踪中,将目标幅度信息作为一个量测变量与传统的距离、方位、多普勒等量测变量共同使用可提高数据关联,减少虚假航迹数目,取得更好的跟踪性能。目标幅度信息已经被应用于传统的多目标跟踪,如:概率数据关联(Probability Data Association, PDA)滤波器^[2]、多假设跟踪(Multiple Hypothesis Tracking, MHT)^[3]和 Viterbi 数据关联^[4]。

传统的多目标跟踪方法围绕量测和目标的关联展开,随着目标数或者杂波数的增加,其计算量指数增长^[1]。为了克服该困难,文献[1]以有限集统计

收稿日期: 2015-06-08; 改回日期: 2015-11-11; 网络出版: 2015-12-18

*通信作者: 王俊 yuanchang61@126.com

基金项目: 国家自然科学基金(61171122, 61201318, 61471019, 61501011), 中央高校基本科研业务费专项资金(YWF-15-GJSYS-068)

Foundation Items: The National Natural Science Foundation of China (61171122, 61201318, 61471019, 61501011), The Fundamental Research Funds for the Central Universities (YWF-15-GJSYS-068)

学为基础,提出了随机有限集(Random Finite Set, RFS)方法,该方法为多目标跟踪问题提供了一个精确和简洁的公式表示,避免了数据关联,很快成为了多目标跟踪的研究热点之一。尤其是概率假设密度滤波器(Probability Hypothesis Density Filter, PHDF)^[5]和势概率假设密度滤波器(Cardinalized Probability Hypothesis Density Filter, CPHDF)^[6]的发展、实现^[7-10]和收敛结果^[11,12]已经证明了RFS方法的可行性。文献[13]将幅度信息应用于PHDF和CPHDF,提高了多目标的跟踪精度。但是由于其SMC实现需要聚类处理,很难判断滤波性能的下降是由于聚类处理还是滤波器自身或者二者都有。不同于PHDF和CPHDF传递多目标阶矩和势分布,另一类基于RFS方法的多伯努利滤波器(MBerF)最近被提出,该滤波器传递近似后验多目标密度的多伯努利分布参数^[1]。MBerF与PHDF具有相同的计算量,但是其SMC实现不需要采用聚类的方法估计多目标状态,计算量小于CPHDF。MBerF从提出后很快被成功的应用在许多实际问题中,例如:传感器网络跟踪^[14]、音频跟踪^[15]、虚拟跟踪^[16]和图像跟踪^[17]。

但是,到目前为止,所有关于MBerF的研究都没有考虑利用目标幅度信息提高多目标跟踪性能。基于此,本文从传统的MBerF出发,结合目标幅度信息,推导了一种幅度信息辅助多伯努利滤波(AIA-MBerF)算法,该算法通过建立幅度似然函数将幅度信息引入到多伯努利滤波的更新过程中,充分利用杂波和目标幅度信息的不同,提高目标数和目标状态估计准确性。针对线性和非线性多目标跟踪场景,分别给出了GM和SMC实现。最后通过仿真实验验证了在已知信噪比(Signal-to-noise Ratio, SNR)和未知SNR下该滤波算法相比于传统MBerF在目标数和目标状态估计精度都得到显著提高。

2 幅度信息辅助多伯努利滤波算法

2.1 幅度模型

本文采用文献[2]中的瑞利分布描述杂波和目标幅度变化,该模型描述信号通过带通匹配滤波器,包络检波的幅度变化结果,同时对于Swerling 1和Swerling 2模型^[18]也适用。杂波和目标幅度 a 的概率密度可分别被表示为^[2]

$$p_c(a) = a \exp\left(\frac{-a^2}{2}\right), \quad a \geq 0 \quad (1)$$

$$p_t^S(a) = \frac{a}{1+S} \exp\left(\frac{-a^2}{2(1+S)}\right), \quad a \geq 0 \quad (2)$$

其中, $1+S$ 表示 SNR 的均值且

$$\text{SNR (dB)} = 10 \lg(1+S)$$

假设检测过程门限为 $\tau > 0$, 检测概率和虚警概率分别为

$$p_D^\tau(S) = \int_\tau^\infty p_t^S(a) da \quad (3)$$

$$p_{FA}^\tau = \int_\tau^\infty p_c(a) da \quad (4)$$

通过门限检波器后,杂波和目标幅度 a 的概率密度可分别被表示为

$$p_c^\tau(a) = a \exp\left(\frac{\tau^2 - a^2}{2}\right), \quad a \geq \tau \quad (5)$$

$$p_t^{\tau,S}(a) = \frac{a}{1+S} \exp\left(\frac{\tau^2 - a^2}{2(1+S)}\right), \quad a \geq \tau \quad (6)$$

2.2 幅度似然函数

本文以2维运动场景为例,目标状态包含位置 p_x, p_y ,速度 \dot{p}_x, \dot{p}_y 或位置 p_x, p_y ,速度 \dot{p}_x, \dot{p}_y ,转弯率 ω 和参数 S , $\tilde{\mathbf{x}} = [p_x, \dot{p}_x, p_y, \dot{p}_y]^\top$ 或 $\tilde{\mathbf{x}} = [p_x, \dot{p}_x, p_y, \dot{p}_y, \omega]^\top$, $\mathbf{x} = [\tilde{\mathbf{x}}^\top, S]^\top$ 。量测包含线性位置量测 $\tilde{\mathbf{z}} = [z_x, z_y]^\top$ 或非线性距离角度量测 $\tilde{\mathbf{z}} = [R, \theta]^\top$ 和幅度 $a \geq 0$, $\mathbf{z} = [\tilde{\mathbf{z}}^\top, a]^\top$ 。假设幅度量测与位置量测或距离角度量测相互独立,则检波后目标似然函数和杂波似然函数可分别表示为

$$g(\mathbf{z}|\mathbf{x}) = g_{\tilde{\mathbf{z}}}(\tilde{\mathbf{z}}|\tilde{\mathbf{x}}) g_a(a|S) \quad (7)$$

$$c(\mathbf{z}) = c_{\tilde{\mathbf{z}}}(\tilde{\mathbf{z}}) c_a(a) \quad (8)$$

其中, $g_a(a|S)$ 和 $c_a(a)$ 为目标和杂波幅度似然函数,且 $g_a(a|S) = g_a^\tau(a|S) p_D^\tau(S)$, $c_a(a) = c_a^\tau(a) p_{FA}^\tau$ 。

(1)已知SNR: 当SNR已知时,检测门限 τ 通过给定虚警值 p_{FA}^τ 计算,检测概率值 $p_D^\tau(S)$ 利用式(3)解析求解。采用式(5)和式(6)作为检测后杂波 $c_a^\tau(a)$ 和目标 $g_a^\tau(a|S)$ 的幅度似然函数。

(2)未知SNR: 在实际应用中,SNR通常是未知的,本文采用文献[13]的方法,通过排除参数 S 所有可能取值范围,找到一个不依赖参数 S 的目标幅度似然函数 g_a 。对于瑞利幅度似然函数,假设先验的SNR在dB域 $[dB_1, dB_2]$ 服从均匀分布,参数 S 对应的取值范围为 $[S_1, S_2]$,则该目标幅度似然函数可表示为

$$g_a(a) = \frac{2 \left(\exp\left(\frac{-a^2}{2(1+S_2)}\right) - \exp\left(\frac{-a^2}{2(1+S_1)}\right) \right)}{a (\ln(1+S_2) - \ln(1+S_1))} \quad (9)$$

2.3 幅度信息辅助多伯努利滤波(AIA-MBerF)

由于杂波和目标幅度信息不同且可测,本文推导了一种AIA-MBerF算法,该算法通过建立幅度似然函数将幅度信息引入到多伯努利滤波的更新过

程中, 提高目标数和目标状态估计准确性。其预测和更新步骤总结如下:

预测 假设在 $k-1$ 时刻, 后验多目标密度为多伯努利形式^[19]:

$$\pi_{k-1} = \left\{ \left(r_{k-1}^{(i)}, p_{k-1}^{(i)} \right) \right\}_{i=1}^{M_{k-1}} \quad (10)$$

则预测的多目标密度也为多伯努利形式, 且由存在和新生两部分组成, 即^[19]

$$\pi_{k|k-1} = \left\{ \left(r_{P,k|k-1}^{(i)}, p_{P,k|k-1}^{(i)} \right) \right\}_{i=1}^{M_{k-1}} \cup \left\{ \left(r_{\Gamma,k}^{(i)}, p_{\Gamma,k}^{(i)} \right) \right\}_{i=1}^{M_{\Gamma,k}} \quad (11)$$

其中,

$$r_{P,k|k-1}^{(i)} = r_{k-1}^{(i)} \left\langle p_{k-1}^{(i)}, p_{S,k} \right\rangle \quad (12)$$

$$p_{P,k|k-1}^{(i)}(\mathbf{x}) = \frac{\left\langle f_{k|k-1}(\mathbf{x}|\bullet), p_{k-1}^{(i)} p_{S,k} \right\rangle}{\left\langle p_{k-1}^{(i)}, p_{S,k} \right\rangle} \quad (13)$$

$\langle \bullet, \bullet \rangle$ 表示内积运算; $f_{k|k-1}(\bullet|\zeta)$ 表示单目标在 k 时刻

$$r_{U,k}(\mathbf{z}) = \frac{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \left(1 - r_{k|k-1}^{(i)} \right) \left\langle p_{k|k-1}^{(i)}, g_{\mathbf{z},k}(\tilde{\mathbf{z}}|\tilde{\mathbf{x}}) g_{a,k}^{\tau}(a|S) p_{D,k}^{\tau}(S) \right\rangle}{\left(1 - r_{k|k-1}^{(i)} \left\langle p_{k|k-1}^{(i)}, p_{D,k}^{\tau}(S) \right\rangle \right)^2}}{\lambda p_{FA,k}^{\tau} c_{a,k}^{\tau}(a) c_{\mathbf{z},k}^{\tau}(\tilde{\mathbf{z}}) + \sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \left\langle p_{k|k-1}^{(i)}, g_{\mathbf{z},k}(\tilde{\mathbf{z}}|\tilde{\mathbf{x}}) g_{a,k}^{\tau}(a|S) p_{D,k}^{\tau}(S) \right\rangle}{1 - r_{k|k-1}^{(i)} \left\langle p_{k|k-1}^{(i)}, p_{D,k}^{\tau}(S) \right\rangle}} \quad (18)$$

$$p_{U,k}(\mathbf{x}, \mathbf{z}) = \frac{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} p_{k|k-1}^{(i)}(\mathbf{x}) g_{\mathbf{z},k}(\tilde{\mathbf{z}}|\tilde{\mathbf{x}}) g_{a,k}^{\tau}(a|S) p_{D,k}^{\tau}(S)}{1 - r_{k|k-1}^{(i)} \left\langle p_{k|k-1}^{(i)}, p_{D,k}^{\tau}(S) \right\rangle}}{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \left\langle p_{k|k-1}^{(i)}, g_{\mathbf{z},k}(\tilde{\mathbf{z}}|\tilde{\mathbf{x}}) g_{a,k}^{\tau}(a|S) p_{D,k}^{\tau}(S) \right\rangle}{1 - r_{k|k-1}^{(i)} \left\langle p_{k|k-1}^{(i)}, p_{D,k}^{\tau}(S) \right\rangle}} \quad (19)$$

3 滤波器实现

本节详细给出了线性模型的 GM-AIA-MBerF 和非线性模型的 SMC-AIA-MBerF 实现。

3.1 GM-AIA-MBerF 实现

假设目标的状态转移和量测采用线性高斯模型, 其表示为

$$f_{k|k-1}(\mathbf{x}|\zeta) = N(\tilde{\mathbf{x}}; \mathbf{F}_{k-1}\zeta, \mathbf{Q}_{k-1}) \quad (20)$$

$$g_{\mathbf{z},k}(\tilde{\mathbf{z}}|\tilde{\mathbf{x}}) = N(\tilde{\mathbf{z}}; \mathbf{H}_k\tilde{\mathbf{x}}, \mathbf{R}_k) \quad (21)$$

其中, $N(\bullet; \mathbf{m}, \mathbf{P})$ 表示均值 \mathbf{m} 和方差 \mathbf{P} 的高斯概率密度, \mathbf{F}_{k-1} 为状态转移矩阵, \mathbf{Q}_{k-1} 为过程噪声方差, \mathbf{H}_k 为观测矩阵, \mathbf{R}_k 为观测噪声方差。

GM-AIA-MBerF 实现主要包含预测、更新、剪枝和多目标状态提取步骤, 详细过程如下:

预测 假设在 $k-1$ 时刻, 后验多目标密度为多伯努利形式 $\pi_{k-1} = \left\{ \left(r_{k-1}^{(i)}, p_{k-1}^{(i)} \right) \right\}_{i=1}^{M_{k-1}}$, 且 $p_{k-1}^{(i)}(\mathbf{x}) =$

$\sum_{j=1}^{J_{k-1}^{(i)}} w_{k-1}^{(i,j)} N(\tilde{\mathbf{x}}; \mathbf{m}_{k-1}^{(i,j)}, \mathbf{P}_{k-1}^{(i,j)})$, 则预测多目标密度式(11)采用文献[19]的式(51)~式(53)计算。

更新 假设在 k 时刻, 预测的多目标密度为如

给定先验状态 ζ 的转移密度; $p_{S,k}(\zeta)$ 表示目标在 k 时刻给定先验状态 ζ 的存在概率; $\left\{ \left(r_{\Gamma,k}^{(i)}, p_{\Gamma,k}^{(i)} \right) \right\}_{i=1}^{M_{\Gamma,k}}$ 表示在 k 时刻新生多伯努利 RFS 参数。

更新 假设在 k 时刻, 预测的多目标密度为多伯努利形式:

$$\pi_{k|k-1} = \left\{ \left(r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)} \right) \right\}_{i=1}^{M_{k|k-1}} \quad (14)$$

则给定量测集 \mathbf{Z}_k 下, 后验多目标密度近似为多伯努利形式, 由遗留和更新两部分组成:

$$\pi_k \approx \left\{ \left(r_{L,k}^{(i)}, p_{L,k}^{(i)} \right) \right\}_{i=1}^{M_{k|k-1}} \cup \left\{ \left(r_{U,k}(\mathbf{z}), p_{U,k}(\bullet; \mathbf{z}) \right) \right\}_{\mathbf{z} \in \mathbf{Z}_k} \quad (15)$$

$$r_{L,k}^{(i)} = r_{k|k-1}^{(i)} \frac{1 - \left\langle p_{k|k-1}^{(i)}, p_{D,k}^{\tau}(S) \right\rangle}{1 - r_{k|k-1}^{(i)} \left\langle p_{k|k-1}^{(i)}, p_{D,k}^{\tau}(S) \right\rangle} \quad (16)$$

$$p_{L,k}^{(i)}(\mathbf{x}) = p_{k|k-1}^{(i)}(\mathbf{x}) \frac{1 - p_{D,k}^{\tau}(S)}{1 - \left\langle p_{k|k-1}^{(i)}, p_{D,k}^{\tau}(S) \right\rangle} \quad (17)$$

下多伯努利形式:

$$\pi_{k|k-1} = \left\{ \left(r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)} \right) \right\}_{i=1}^{M_{k|k-1}} \quad (22)$$

$$p_{k|k-1}^{(i)}(\mathbf{x}) = \sum_{j=1}^{J_{k-1}^{(i)}} w_{k|k-1}^{(i,j)} N(\tilde{\mathbf{x}}; \mathbf{m}_{k|k-1}^{(i,j)}, \mathbf{P}_{k|k-1}^{(i,j)}) \quad (23)$$

则给定量测集 \mathbf{Z}_k 下, 更新的后验多目标密度式(15)计算如式(24)~式(27):

$$r_{L,k}^{(i)} = r_{k|k-1}^{(i)} \frac{1 - p_{D,k}^{\tau}(S)}{1 - r_{k|k-1}^{(i)} p_{D,k}^{\tau}(S)} \quad (24)$$

$$p_{L,k}^{(i)}(\mathbf{x}) = p_{k|k-1}^{(i)}(\mathbf{x}) \quad (25)$$

$$r_{U,k}(\mathbf{z}) = \frac{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \left(1 - r_{k|k-1}^{(i)} \right) \eta_{U,k}^{(i)}}{\left(1 - r_{k|k-1}^{(i)} p_{D,k}^{\tau}(S) \right)^2}}{\lambda p_{FA,k}^{\tau} c_{a,k}^{\tau}(a) c_{\mathbf{z},k}^{\tau}(\tilde{\mathbf{z}}) + \sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \eta_{U,k}^{(i)}}{1 - r_{k|k-1}^{(i)} \eta_{L,k}^{(i)}}} \quad (26)$$

$$p_{U,k}(\mathbf{x}; \mathbf{z}) = \frac{\sum_{i=1}^{M_{k|k-1}} \sum_{j=1}^{J_{k-1}^{(i)}} w_{U,k}^{(i,j)}(\mathbf{z}) N(\tilde{\mathbf{x}}; \mathbf{m}_{U,k}^{(i,j)}, \mathbf{P}_{U,k}^{(i,j)})}{\sum_{i=1}^{M_{k|k-1}} \sum_{j=1}^{J_{k-1}^{(i)}} w_{U,k}^{(i,j)}(\mathbf{z})} \quad (27)$$

其中,

$$\eta_{U,k}^{(i)} = \sum_{j=1}^{J_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} q_k^{(i,j)}(\mathbf{z}) \quad (28)$$

$$q_k^{(i,j)}(\mathbf{z}) = N\left(\tilde{\mathbf{z}}; \mathbf{H}_k \mathbf{m}_{k|k-1}^{(i,j)}, \mathbf{H}_k \mathbf{P}_{k|k-1}^{(i,j)} \mathbf{H}_k^T + \mathbf{R}_k\right) \cdot g_{a,k}^T(a|S) p_{D,k}^\tau(S) \quad (29)$$

$$w_{U,k}^{(i,j)} = \frac{r_{k|k-1}^{(i)}}{1 - r_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} q_k^{(i,j)}(\mathbf{z}) \quad (30)$$

$$\mathbf{m}_{U,k}^{(i,j)} = \mathbf{m}_{k|k-1}^{(i,j)} + \mathbf{K}_{U,k}^{(i,j)} \left(\tilde{\mathbf{z}} - \mathbf{H}_k \mathbf{m}_{k|k-1}^{(i,j)}\right) \quad (31)$$

$$\mathbf{P}_{U,k}^{(i,j)} = \left[\mathbf{I} - \mathbf{K}_{U,k}^{(i,j)} \mathbf{H}_k\right] \mathbf{P}_{k|k-1}^{(i,j)} \quad (32)$$

$$\mathbf{K}_{U,k}^{(i,j)} = \mathbf{P}_{k|k-1}^{(i,j)} \mathbf{H}_k^T \left[\mathbf{H}_k \mathbf{P}_{k|k-1}^{(i,j)} \mathbf{H}_k^T + \mathbf{R}_k\right]^{-1} \quad (33)$$

剪枝 由于在预测过程中新生目标的加入和更新过程中平均多伯努利项的增加,使得最终表示多伯努利后验密度的高斯数目不断增加。为了降低高斯数目,采用文献[19]中的方法,首先删除存在概率低于门限 P 的多伯努利项;其次对于保留的多伯努利项,删除高斯权重低于门限 T 的高斯分量,同时合并距离在 U 范围内的高斯分量。

多目标状态提取 类似于文献[19]的方法,首先估计出目标数,然后选取对应数目的存在概率最大的伯努利项,计算其高斯分量的均值作为对应目标状态。

3.2 SMC-AIA-MBerF 实现

由于 SMC-AIA-MBerF 是直接采用标准的 SMC 方法,因此该滤波器的收敛结果与文献[20]中的收敛结果相一致。其预测、更新、重采样和多目标状态提取步骤如下:

预测 假设在 $k-1$ 时刻,后验多目标密度为多伯努利形式 $\pi_{k-1} = \left\{ \left(r_{k-1}^{(i)}, p_{k-1}^{(i)} \right) \right\}_{i=1}^{M_{k-1}}$, 且 $p_{k-1}^{(i)}(\mathbf{x}) = \sum_{j=1}^{J_{k-1}^{(i)}} w_{k-1}^{(i,j)} \delta_{\mathbf{x}_{k-1}^{(i,j)}}(\mathbf{x})$, 则预测多目标密度式(11)采用文献[19]的式(39)~式(42)计算。

更新 假设在 k 时刻,预测的多目标密度为式(34),式(35)所示的多伯努利形式:

$$\pi_{k|k-1} = \left\{ \left(r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)} \right) \right\}_{i=1}^{M_{k|k-1}} \quad (34)$$

$$p_{k|k-1}^{(i)} = \sum_{j=1}^{J_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} \delta_{\mathbf{x}_{k|k-1}^{(i,j)}}(\mathbf{x}) \quad (35)$$

则给定量测集 \mathbf{Z}_k 下,更新的后验多目标密度式(15)计算如式(36)~式(39)所示:

$$r_{L,k}^{(i)} = r_{k|k-1}^{(i)} \frac{1 - \eta_{L,k}^{(i)}}{1 - r_{k|k-1}^{(i)} \eta_{L,k}^{(i)}} \quad (36)$$

$$p_{L,k}^{(i)}(\mathbf{x}) = \sum_{j=1}^{J_{k|k-1}^{(i)}} \tilde{w}_{L,k}^{(i,j)} \delta_{\mathbf{x}_{k|k-1}^{(i,j)}}(\mathbf{x}) \quad (37)$$

$$r_{U,k}(\mathbf{z}) = \frac{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} (1 - r_{k|k-1}^{(i)}) \eta_{U,k}^{(i)}}{(1 - r_{k|k-1}^{(i)} \eta_{L,k}^{(i)})^2}}{\lambda p_{FA,k}^\tau c_{a,k}^\tau(a) c_{z,k}(\tilde{\mathbf{z}}) + \sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \eta_{U,k}^{(i)}}{1 - r_{k|k-1}^{(i)} \eta_{L,k}^{(i)}}} \quad (38)$$

$$p_{U,k}(\mathbf{x}; \mathbf{z}) = \sum_{i=1}^{M_{k|k-1}} \sum_{j=1}^{J_{k|k-1}^{(i)}} \tilde{w}_{U,k}^{(i,j)} \delta_{\mathbf{x}_{k|k-1}^{(i,j)}}(\mathbf{x}) \quad (39)$$

其中

$$\tilde{w}_{L,k}^{(i,j)} = \frac{w_{k|k-1}^{(i,j)} (1 - p_{D,k}^\tau(S))}{\sum_{j=1}^{J_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} (1 - p_{D,k}^\tau(S))} \quad (40)$$

$$\eta_{L,k}^{(i)} = \sum_{j=1}^{J_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} p_{D,k}^\tau(S) \quad (41)$$

$$\eta_{U,k}^{(i)}(\mathbf{z}) = \sum_{j=1}^{J_{k|k-1}^{(i)}} w_{k|k-1}^{(i,j)} g_{z,k}(\tilde{\mathbf{z}} | \tilde{\mathbf{x}}_{k|k-1}^{(i,j)}) g_{a,k}^\tau(a|S) p_{D,k}^\tau(S) \quad (42)$$

$$\tilde{w}_{U,k}^{(i,j)} = \frac{w_{k|k-1}^{(i,j)} \frac{r_{k|k-1}^{(i)}}{1 - r_{k|k-1}^{(i)}} g_{z,k}(\tilde{\mathbf{z}} | \tilde{\mathbf{x}}_{k|k-1}^{(i,j)}) g_{a,k}^\tau(a|S) p_{D,k}^\tau(S)}{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)}}{1 - r_{k|k-1}^{(i)}} \eta_{U,k}^{(i)}(\mathbf{z})} \quad (43)$$

重采样 由于在预测过程中新生目标的加入和更新过程中平均多伯努利项的增加,使得最终近似后验密度的多伯努利项数目不断增加。采用文献[19]的方法,删除存在概率低于门限值 P 的伯努利项,同时设置一个允许存在的最大多伯努利项数 T_{\max} 。

多目标状态提取 类似于标准的多伯努利滤波器对于多目标状态的提取^[19],首先采用后验势分布的均值估计目标数,然后选取对应数目的存在概率最大的伯努利项,计算其后验密度的均值作为对应目标状态。

4 仿真实验与分析

4.1 线性模型 GM-AIA-MBer 实现

考虑一个二维线性多目标跟踪场景,仿真场景中 12 个目标作匀速运动,初始时刻有 3 个目标作匀速运动,随后分别有 9 个新生目标出现。目标的运动模型和量测模型分别为

$$\tilde{\mathbf{x}}_k = \mathbf{F} \tilde{\mathbf{x}}_{k-1} + \mathbf{G} \mathbf{w}_{k-1} \quad (44)$$

$$\tilde{\mathbf{z}}_k = \mathbf{H} \tilde{\mathbf{x}}_k + \varepsilon_k \quad (45)$$

其中, $\mathbf{F} = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}$ 为转移矩阵; $\mathbf{G} =$

$$\begin{bmatrix} T^2 & 0 \\ 2 & 0 \\ T & T^2 \\ 0 & 2 \\ 0 & T \end{bmatrix}$$

为过程噪声矩阵； $\tilde{\mathbf{x}}_k = [p_{x,k}, \dot{p}_{x,k}, p_{y,k},$

$\dot{p}_{y,k}]^T$ ，包含目标位置 $(p_{x,k}, p_{y,k})$ 和速度 $(\dot{p}_{x,k}, \dot{p}_{y,k})$ ， $\mathbf{w}_{k-1} \sim N(\mathbf{0}; \sigma_w^2 \mathbf{I}_2)$ 表示过程噪声，取 $\sigma_w = 5$ m；

$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$ 为线性观测函数； ε_k 为量测噪声，

且 $\varepsilon_k \sim N(\mathbf{0}; \mathbf{R}_k)$ ， $\mathbf{R}_k = \text{diag}([\sigma_r^2, \sigma_r^2]^T)$ ， $\sigma_r = 10$ m。

观测区域为 $[-1000 \text{ m}, 1000 \text{ m}] \times [-1000 \text{ m}, 1000 \text{ m}]$ ；目标的存活概率为 $p_{S,k} = 0.99$ 。新生目标多伯努利随机集为 $\pi_\Gamma = \{(r_\Gamma, p_\Gamma^{(i)})\}_{i=1}^4$ ，其中， $r_\Gamma = 0.03$ ， $p_\Gamma^{(i)}(x) = N(\mathbf{x}; \mathbf{m}_\Gamma^{(i)}, \mathbf{P}_\Gamma)$ ； $\mathbf{m}_\Gamma^{(1)} = (-200, 0, 900, 0)$ ； $\mathbf{m}_\Gamma^{(2)} = (-900, 0, -400, 0)$ ； $\mathbf{m}_\Gamma^{(3)} = (0, 0, 200, 0)$ ； $\mathbf{m}_\Gamma^{(4)} = (300, 0, -500, 0)$ ； $\mathbf{P}_\Gamma = \text{diag}([100, 100, 100, 100])$ 。采样间隔取1 s，共采样100个时刻。对于每个多伯努利项，高斯分量剪枝门限为 $T = 10^{-5}$ ，合并距离门限为 $U = 4$ m，最大高斯分量数为 $J_{\max} = 100$ ；对于多伯努利项，其删除门限为 $P = 10^{-3}$ ，最大多伯努利数为 $T_{\max} = 100$ 。设定虚警概率为 $p_{\text{FA}}^\tau = 0.1$ ，信噪比为20 dB，信噪比变化范围为[15 dB, 30 dB]，根据式(4)和式(3)计算检测门限 $\tau = 2.146$ ，检测概率为 $p_D^{\tau, S} = 0.9775$ ，同时设定杂波服从强度为30的泊松分布(量测数大概为310个)。仿真场景如图1(a)所示，其中 ∇ 和 \square 分别表示目标运动起始和结束位置， $-$ 和 \times 分别表示真实航迹和量测。

图1(b)和图1(c)给出了已知和未知SNR条件下，GM-AIA-MBerF单次仿真实验对多目标位置的估计结果。从仿真结果可以看出无论在已知或者未知SNR条件下，给出的算法均可在大量虚警杂波中正确跟踪单独目标运动和不同的目标新生和消失。

为进一步分析GM-AIA-MBerF在SNR已知和未知条件下的性能，将其与标准GM-MBerF对比。图2展示了GM-MBerF，SNR已知和未知条件下




图1 包含杂波量测和 GM-AIA-MBerF 估计结果

GM-AIA-MBerF 经 100 次蒙特卡洛仿真实验平均后的多目标个数估计及方差随时间变化曲线。从图中可以看出，无论是已知或未知 SNR 的 GM-AIA-MBerF 目标数估计性能都优于标准的 GM-MBerF，并且已知和未知 SNR 的 GM-AIA-MBerF 性能接近。标准的 MBerF 会存在偏差，这是由于标准的 MBerF 主要应用于低杂波高检测概率的环境，对于 GM 实现，其适用范围为杂波强度小于 20 的泊松分布和检测概率高于 0.9 的场景^[10]，当杂波数增多时会存在估计偏高。而 GM-AIA-MBerF 算法由于增加了幅度信息，可以很好提高对杂波和目标的区别，因此其对于高杂波环境效果好，但是由于没有改进 MBerF 滤波器本身的算法结构，因此对于低检测概率环境效果仍然不理想。

最优子模式分配 (Optimal SubPattern Assignment, OSPA) 距离^[21]用于定量分析算法的估计误差，定义如式(46)：

$$\bar{d}_p^{(c)}(X, Z) = \left(\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m d^{(c)}(x_i, z_i)^p + c^p (n - m) \right) \right)^{1/p} \quad (46)$$

本仿真中取 $p = 1; c = 100$ 。OSPA 距离既包含目标位置估计误差，也包含目标个数估计误差，在目标个数估计错误的时刻会出现峰值，因此 OSPA 距离实际上反映了一个滤波器对多目标状态和个数估计的综合精度，OSPA 距离越大该算法的综合精度越差。

图3展示了经100次蒙特卡洛仿真实验平均后得到的三者 OSPA 距离随时间变化曲线。该结果进一步验证了 GM-AIA-MBerF 性能优于标准的 GM-MBerF。这是因为目标和杂波的幅度分布不同，通过采用幅度信息量测有利于区分目标和杂波，提高对杂波的抑制能力，更好地估计真实目标数。

表1所示为不同虚警概率和 SNR 下，3种滤波器的平均 OSPA 距离。可以看出，随着 SNR 的提高，3种滤波器的 OSPA 距离呈现整体下降趋势，




图 2 3 种滤波器的目标数估计均值与方差




图 3 3 种滤波算法的 OSPA 距离

这主要是由于随着 SNR 的提高，检测概率提高，目标漏检降低；同时已知或未知 SNR 的 GM-AIA-MBerF 的性能比较接近，均优于未利用幅度信息标准 GM-MBerF，且 SNR 越高优势越明显，这主要是由于利用幅度信息之后，提高了对虚假目标的识别能力，可以更加有效地消除杂波干扰。另一方面，随着虚警概率的降低，3 种滤波器的 OSPA 距离呈现整体上升趋势，这是由于随着虚警概率的降低，目标检测概率降低，而 MBerF 算法对于检测概率更加敏感，因此在仿真中出现了 OSPA 距离上升的结果。

4.2 非线性模型 SMC-AIA-MBerF 实现

采用一个非线性多目标运动场景来验证 SMC-AIA-MBerF 性能。观测区域是半径为 2000 m 的半圆区域，监控时间为 100 s，传感器位于原点，采样间隔 1 s。总共有 10 个起始时刻和消失时刻不同的目标出现在该场景中。真实目标按照直角转弯模型

运动，目标运动状态变量 $\tilde{\mathbf{x}}_k = [\hat{\mathbf{x}}_k, \omega_k]^T$ 由位置、速度变量 $\hat{\mathbf{x}}_k$ 和转弯率 ω_k 组成。状态转移模型为

$$\tilde{\mathbf{x}}_k = \mathbf{F}(\omega_{k-1})\tilde{\mathbf{x}}_{k-1} + \mathbf{G}\mathbf{w}_{k-1} \quad (47)$$

$$\omega_k = \omega_{k-1} + T u_{k-1} \quad (48)$$

其中

$$\mathbf{F}(\omega) = \begin{bmatrix} 1 & \frac{\sin \omega T}{\omega} & 0 & -\frac{1 - \cos \omega T}{\omega} \\ 0 & \cos \omega T & 0 & -\sin \omega T \\ 0 & \frac{1 - \cos \omega T}{\omega} & 1 & \frac{\sin \omega T}{\omega} \\ 0 & \sin \omega T & 0 & \cos \omega T \end{bmatrix}$$

为转移矩阵； $\mathbf{G} = \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix}$ 为过程噪声矩阵；

$\mathbf{w}_{k-1} \sim N(\bullet; 0, \sigma_w^2 \mathbf{I}_2)$ 和 $u_{k-1} \sim N(\bullet; 0, \sigma_u^2 \mathbf{I})$ 为过程噪声，取 $\sigma_w = 15 \text{ m/s}^2$ ； $\sigma_u = \pi/180 \text{ rad/s}$ 。量测采用角度和距离的极坐标量测模型，表达式为

$$\tilde{\mathbf{z}}_k = \begin{bmatrix} \arctan(p_{x,k}/p_{y,k}) \\ \sqrt{p_{x,k}^2 + p_{y,k}^2} \end{bmatrix} + \boldsymbol{\varepsilon}_k \quad (49)$$

其中， $\boldsymbol{\varepsilon}_k \sim N(\bullet; 0, \mathbf{R}_k)$ ， $\mathbf{R}_k = \text{diag}([\sigma_\theta^2, \sigma_r^2]^T)$ ，取 $\sigma_\theta = \pi/180 \text{ rad}$ ； $\sigma_r = 5 \text{ m}$ 。目标的存活概率为

表 1 不同信噪比和虚警率下的 OSPA 距离

		SNR											
		15 dB			20 dB			25 dB			30 dB		
p_{FA}	τ	a	b	c	a	b	c	a	b	c	a	b	c
0.001	3.717	32.54	32.13	40.32	23.49	23.65	30.64	19.68	19.47	28.12	15.12	15.02	26.95
0.010	3.035	27.21	27.68	34.74	22.54	22.43	29.47	19.37	19.24	27.43	14.94	14.78	26.32
0.100	2.146	22.57	22.94	28.54	21.56	21.76	27.34	18.59	18.63	26.27	14.46	14.32	25.53

注：a：已知 SNR GM-AIA-MBerF；b：未知 SNR GM-AIA-MBerF；c：GM-MBerF

$p_{S,k} = 0.99$ ，为了运算简单，取 $q_k^{(i)}(\bullet | \mathbf{x}_{k-1}^{(i,j)}, \mathbf{Z}_k) = f_{k|k-1}(\bullet | \mathbf{x}_{k-1}^{(i,j)})$ 。每个假设航迹的最大粒子数为 $L_{\max} = 1000$ ，最小粒子数为 $L_{\min} = 300$ 。假设航迹的删除门限为 $P = 10^{-3}$ ，最大假设航迹数为 $T_{\max} = 100$ ，其他参数设置与 GM-AIA-MBer 中的相同。仿真场景如图 4(a)所示。

图 4(b)和图 4(c)给出了已知 SNR 和未知 SNR 条件下，采用 SMC-AIA-MBerF 单次仿真实验对多目标位置的估计结果。从仿真结果可以看出无论在已知 SNR 或者未知 SNR 条件下，给出的滤波均可在大量虚警杂波中正确跟踪单独目标运动和不同的目标新生和消失。

图 5 展示了已知和未知 SNR 的 SMC-AIA-MBerF 和 SMC-MBerF 经 100 次蒙特卡洛仿真实

验平均后的多目标个数估计及其方差随时间变化曲线，其结果与 GM 实现结果类似。

图 6 展示了经 100 次蒙特卡洛仿真实验平均后得到的三者 OSPA 距离随时间变化曲线。表 2 所示为不同虚警概率和 SNR 下，3 种滤波算法的平均 OSPA 距离，其结果与 GM 实现结果类似。

5 结论

由于在多目标跟踪场景中，目标和虚警杂波返回的信号幅度不同，该幅度信息可以作为一种有效的辅助，提高跟踪性能，消除虚警杂波。因此，本文提出了一种基于随机有限集的幅度信息辅助多伯努利滤波算法，该算法通过建立幅度似然函数将幅度信息引入到多伯努利滤波的更新过程中。针对线性和非线性模型，给出了 GM 和 SMC 实现方法。仿真结果表明，该算法相比传统 MBerF，无论 GM




图 4 包含杂波量测和 SMC-AIA-MBerF 估计结果




图 5 3 种滤波算法的目标数估计均值与方差

表 2 不同信噪比和虚警率下的 OSPA 距离

		SNR											
		15 dB			20 dB			25 dB			30 dB		
P_{FA}	τ	a	b	c	a	b	c	a	b	c	a	b	c
0.001	3.717	37.71	37.54	53.72	29.63	29.53	39.48	25.53	25.59	34.43	21.96	22.16	29.80
0.010	3.035	34.36	34.28	47.87	28.82	28.76	38.41	25.29	25.21	33.91	21.79	21.94	29.42
0.100	2.146	27.65	27.49	38.48	26.65	26.52	36.74	24.47	24.61	32.49	21.46	21.62	28.64

注：a：已知 SNR, SMC-AIAMBerF；b：未知 SNR SMC-AIAMBerF；c：SMC-AIAMBerF




图6 3种滤波算法的OSPA距离

还是 SMC 实现都可获得更加准确稳定的目标数和对应的目标状态估计。

参考文献

- [1] MAHLER R. Statistical Multisource-Multitarget Information Fusion[M]. Norwood: Artech House, 2007: 565-682.
 - [2] LERRO D and BAR-SHALOM Y. Automated tracking with target amplitude information[C]. American Control Conference, USA, San Diego, 1990: 2875-2880.
 - [3] VAN KEUK G. Multihypothesis tracking using incoherent signal-strength information[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1996, 32(3): 1164-1170.
 - [4] LA Scala B F. Viterbi data association tracking using amplitude information[C]. Proceedings of the 7th International Conference on Information Fusion, Stockholm, Sweden, 2004: 698-705.
 - [5] MAHLER R. Multitarget Bayes filtering via first-order multitarget moments[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1152-1178.
 - [6] MAHLER R. PHD filters of higher order in target number[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(4): 1523-1543.
 - [7] VO B N and MA W. The Gaussian mixture probability hypothesis density filter[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4091-4104.
 - [8] VO B T, VO B N, and CANTONI A. Analytic implementations of the cardinalized probability hypothesis density filter[J]. *IEEE Transactions on Signal Processing*, 2007, 55(7): 3553-3567.
 - [9] 胡子军, 张林让, 张鹏, 等. 基于高斯混合带势概率假设密度滤波器的未知杂波下多机动目标跟踪算法[J]. 电子与信息学报, 2015, 37(1): 116-122. doi:10.11999/JEIT140218.
HU Zijun, ZHANG Linrang, ZHANG Peng, et al. Gaussian mixture cardinalized probability hypothesis density filter for multiple maneuvering target tracking under unknown clutter situation[J]. *Journal of Electronics & Information Technology*, 2015, 37(1): 116-122. doi:10.11999/JEIT140218.
 - [10] 占荣辉, 刘盛启, 欧建平, 等. 基于序贯蒙特卡罗概率假设密度滤波的多目标检测前跟踪改进算法[J]. 电子与信息学报, 2014, 36(11): 2593-2599. doi:10.3724/SP.J.1146.2013.02029.
ZHAN Ronghui, LIU Shengqi, OU Jianping, et al. Improved multitarget track before detect algorithm using the sequential monte carlo probability hypothesis density filter[J]. *Journal of Electronics & Information Technology*, 2014, 36(11): 2593-2599. doi:10.3724/SP.J.1146.2013.02029.
 - [11] CLARK D and BELL J. Convergence results for the particle PHD filter[J]. *IEEE Transactions on Signal Processing*, 2006, 54(7): 2652-2661.
 - [12] CLARK D and VO B T. Convergence analysis of the Gaussian mixture PHD filter[J]. *IEEE Transactions on Signal Processing*, 2007, 55(4): 1204-1212.
 - [13] CLARK D, RISTIC B, VO BN, et al. Bayesian multi-object filtering with amplitude feature likelihood for unknown object SNR[J]. *IEEE Transactions on Signal Processing*, 2010, 58(1): 26-37.
 - [14] GOSTAR A K, HOSEINNEZHAD R, and BAB-HADIASHAR A. Sensor control for multi-object tracking using labeled multi-Bernoulli filter[C]. The 17th International Conference on Information Fusion, Salamanca, 2014: 1-8.
 - [15] CHONG N, WONG S, NORDHOLM S, et al. Multiple sound source tracking and identification via degenerate unmixing estimation technique and cardinality balanced multi-target multi-bernoulli filter (DUET-CBMeMBer) with track management[C]. Asia-Pacific Signal and Information Processing Association, Siem Reap, 2014: 1-5.
 - [16] KIM D Y and JEON M. Robust multi-Bernoulli filtering for visual tracking[C]. International Conference on Control, Automation and Information Sciences (ICCAIS). Gwangju, 2014: 47-51.
 - [17] 胡子军, 张林让, 房嘉奇. 多站无源雷达多起伏目标检测前跟踪算法[J]. 电子与信息学报, 2015, 37(3): 651-657. doi:10.11999/JEIT140466.
HU Zijun, ZHANG Linrang, and FANG Jiaqi. A Track-before-detect algorithm for tracking multiple fluctuating targets using passive multistatic radar[J]. *Journal of Electronics & Information Technology*, 2015, 37(3): 651-657. doi:10.11999/JEIT140466.
 - [18] SKOLNIK M I. Introduction to Radar[M]. New York: McGraw-Hill, 2002: 148-256.
 - [19] VO B T, VO B N, and CANTONI A. The cardinality balanced multi-target multi-Bernoulli filter and its implementations[J]. *IEEE Transactions on Signal Processing*, 2009, 57(2): 409-423.
 - [20] LIAN F, LI C, HAN C, et al. Convergence analysis for the SMC-MeMBer and SMC-CBMeMBer filters[J]. *Journal of Applied Mathematics*, 2012, 2012: 1-25.
 - [21] SCHUHMACHER D, VO B T, and VO B N. A consistent metric for performance evaluation of multi-object filters[J]. *IEEE Transactions on Signal Processing*, 2008, 56(8): 3447-3457.
- 袁常顺：男，1987年生，博士生，研究方向为雷达信号处理、随机集多目标跟踪等。
- 王 俊：男，1972年生，教授，博士生导师，研究方向为雷达信号处理、实时信号处理等。
- 孙进平：男，1975年生，教授，博士生导师，研究方向为高分辨率雷达信号处理、压缩感知等。
- 孙忠胜：男，1980年生，博士生，工程师，研究方向为雷达信号处理、目标识别等。
- 毕严先：男，1988年生，博士生，研究方向为雷达信号处理、3维成像等。