

文章编号: 1000-8152(2011)08-1164-07

强跟踪输入估计概率假设密度多机动目标跟踪算法

杨金龙, 姬红兵, 樊振华

(西安电子科技大学 电子工程学院, 陕西 西安 710071)

摘要: 针对多机动目标跟踪中, 目标数目未知及加速度不确定的问题, 提出一种强跟踪输入估计(modified input estimation, MIE)概率假设密度多机动目标跟踪算法。在详细分析算法的基础上, 通过引入强跟踪多重渐消因子, 以不同速率实时调节滤波器各个通道的预测协方差及相应的滤波器增益, 从而实现MIE算法对加速度未知或发生大幅度突变的机动目标自适应跟踪能力; 并将该算法与概率假设密度滤波算法有效结合, 可以较好地跟踪未知数目的多机动目标。仿真结果表明, 新算法比传统的多机动目标跟踪算法具有更高的跟踪精度, 且具有较好的实时性。

关键词: 概率假设密度; 输入估计; 多重渐消因子; 机动目标跟踪

中图分类号: TN953 文献标识码: A

Strong tracking modified input estimation probability hypothesis density for multiple maneuvering targets tracking

YANG Jin-long, JI Hong-bing, FAN Zhen-hua

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

Abstract: To deal with the unknown target number and the uncertain acceleration in tracking multiple maneuvering targets, we propose a new adaptive probability hypothesis density(PHD) algorithm based on the strong tracking modified input estimation(STMIE) technique. First, strong tracking filter multiple fading factors are introduced to the MIE algorithm which adjusts the prediction covariance and the corresponding filter gain with different rate in real time to make the MIE method tracking high maneuvering targets perfectly; and then, the adaptive MIE method is combined with the PHD filter to track multiple maneuvering targets. Simulation results show that the proposed algorithm is with higher tracking precision and better real-time performance than the traditional multiple maneuvering target tracking algorithms.

Key words: probability hypothesis density; modified input estimation; multiple fading factors; maneuvering target tracking

1 引言(Introduction)

随着作战环境日益复杂, 对目标跟踪技术的要求越来越高。数目随时间变化的多目标跟踪已经被广泛关注, 尤其是随着现代航空技术的飞速发展, 战斗机等飞行器的机动性能越来越强, 使得对未知数目的多机动目标跟踪的难度也越来越大, 已经成为目标跟踪领域的一个难点问题。

早期的多目标跟踪算法主要是通过量测与目标关联的技术来实现跟踪, 如联合概率数据关联(joint probabilistic data association, JPDA)^[1]、联合集成概率数据关联(joint integrated probabilistic data association, JIPDA)^[2]、多假设跟踪(multiple hypothesis tracking, MHT)^[3]等, 但这些算法的计算复杂度都比较高, 尤其是随着目标数目的增加, 计算代价将呈指数增加, 严重影响算法的实时性。随后出现许多改进的算法^[4~6], 但大多都是以降低算法的跟踪精度

来提高算法的实时性。近年来, 随机有限集(random finite set, RFS)理论得到了广泛关注, 在不需要复杂数据关联的情况下, 通过递归计算多目标状态随机集合后验概率分布的一阶矩, 可以快速实现对未知数目的多目标跟踪, 且可以实时估计目标的数目^[7~9], 但这些算法都只能实现对非机动目标的跟踪。文献[10]中提出在概率假设密度(probability hypothesis density, PHD)滤波框架下, 采用“当前”统计模型(current statistical model, CSM)实现了对多机动目标的跟踪, 但该算法对机动目标跟踪的精度通常取决于机动目标的先验参数, 如机动频率和最大加速度等, 如果先验参数设得不合理, 将严重影响跟踪的精度。此外, 该算法对匀速运动或弱机动目标的跟踪性能较差。考虑到单个模型与目标实际运动模式难以匹配的问题, 文献[11,12]中提出多模型概率假设密度滤波算法, 采用多个模型进行交互滤

波, 但跟踪的精度仍然取决于事先设计的多个模型集与真实目标运动模式的匹配程度。此外, 随着模型数量的增加, 计算代价也将显著增加, 影响跟踪的实时性。2009年Khaloozadeh等学者^[13]提出了一种新的机动目标状态估计算法——输入估计(modified input estimation, MIE)算法, 在不需要任何机动先验信息的情况下, 能够较好地估计匀速运动或弱机动目标的状态, 但当目标加速度发生大幅度突变时, 该算法性能下降, 甚至发散^[14,15]。

针对多机动目标跟踪中, 目标数目未知及加速度不确定的问题, 本文先对MIE算法作了改进, 运用强跟踪滤波(strong tracking filter, STF)^[16]思想, 推导出扩展状态情况下的多重渐消因子计算公式, 提出一种强跟踪MIE滤波算法(STMIE), 有效解决了MIE算法跟踪高机动目标时性能下降的问题; 然后将改进的MIE算法与概率假设密度滤波算法有效结合, 提出一种新的基于概率假设密度的多机动目标跟踪算法, 该算法可以自适应地跟踪数目变化的多机动目标, 且对弱机动和高机动目标都有较好的适应性。

2 多目标跟踪随机集模型(Random finite set model for multiple targets)

假设在 k 时刻, 多目标状态集为 $\mathbf{X}_k = \{x_{k,1}, \dots, x_{k,N_k}\}$, 观测集为 $\mathbf{Y}_k = \{y_{k,1}, \dots, y_{k,M_k}\}$, 其中 N_k 和 M_k 分别表示 k 时刻的目标数及量测数。若 $k-1$ 时刻多目标的状态随机集为 \mathbf{X}_{k-1} , 则 k 时刻的状态随机集 \mathbf{X}_k 及量测随机集 \mathbf{Y}_k 可分别表示为:

$$\begin{aligned} \mathbf{X}_k &= \left(\bigcup_{x \in \mathbf{X}_{k-1}} S_{k|k-1}(x) \right) \cup \\ &\quad \left(\bigcup_{x \in \mathbf{X}_{k-1}} B_{k|k-1}(x) \right) \cup \Gamma_k, \end{aligned} \quad (1)$$

$$\mathbf{Y}_k = K_k \cup \left(\bigcup_{x \in \mathbf{X}_k} \Theta_k(x) \right). \quad (2)$$

其中: $S_{k|k-1}(x)$ 表示 $k-1$ 时刻的目标在 k 时刻存活的随机集, $B_{k|k-1}(x)$ 表示 $k-1$ 时刻的目标在 k 时刻衍生目标的随机集, Γ_k 表示 k 时刻新生目标的随机集, $\Theta_k(x)$ 表示源于真实目标的量测随机集, K_k 表示由杂波引起的量测随机集。

根据贝叶斯估计理论, 可推导出多目标联合后验概率密度分布的最优贝叶斯递推计算公式^[7,8]如下:

$$p_{k|k-1}(\mathbf{X}_k | \mathbf{Y}_{1:k-1}) = \int f_{k|k-1}(\mathbf{X}_k | \mathbf{X}) p_{k-1}(\mathbf{X} | \mathbf{Y}_{1:k-1}) \mu_s(d\mathbf{X}), \quad (3)$$

$$p_k(\mathbf{X}_k | \mathbf{Y}_{1:k}) = \frac{g_k(\mathbf{Y}_k | \mathbf{X}_k) p_{k|k-1}(\mathbf{X}_k | \mathbf{Y}_{1:k-1})}{\int g_k(\mathbf{Y}_k | \mathbf{X}) p_{k|k-1}(\mathbf{X} | \mathbf{Y}_{1:k-1}) \mu_s(d\mathbf{X})}. \quad (4)$$

其中: μ_s 表示状态空间的近似Lebesgue测度, $p_{k|k-1}(\mathbf{X}_k | \mathbf{Y}_{1:k-1})$ 和 $p_k(\mathbf{X}_k | \mathbf{Y}_{1:k})$ 分别表示多目标联合预测概率密度分布和后验概率密度分布,

$f_{k|k-1}(\cdot)$ 表示状态转移概率密度函数, $g_k(\cdot)$ 表示似然函数。由于式(3)和式(4)中涉及多目标状态空间上的多维积分问题, 导致其计算量非常大, 使得对目标状态和目标数的估计变得难以实现。文献[7]中提出通过递归计算多目标状态随机集合后验概率分布的一阶矩来降低问题的复杂性。文献[8, 9]在一些特定的高斯假设条件下, 进一步提出了具有闭合解的高斯混合概率假设密度滤波算法, 有效地实现了对数目变化的多目标跟踪, 但这些算法都只能跟踪非机动目标。目前采用概率假设密度滤波方法对变数目的多机动目标跟踪研究还比较少; 此外, 传统多机动目标跟踪算法中通常存在一些缺陷, 对机动目标的先验知识依赖性较强。针对此问题, 本文将在PHD的滤波框架下, 提出一种新的多机动目标跟踪算法——强跟踪输入估计概率假设密度滤波算法(STMIE-PHD), 可以有效地实现对数目变化的多机动目标跟踪。

3 强跟踪输入估计滤波算法(Strong tracking MIE filter algorithm)

3.1 输入估计算法(MIE method)

假设二维情况下单个机动目标的状态方程和量测方程分别为:

$$x(k+1) = Fx(k) + CU(k) + GW(k), \quad (5)$$

$$y(k) = Hx(k) + V(k). \quad (6)$$

其中: $x(k) = [p_x(k) \ v_x(k) \ p_y(k) \ v_y(k)]^T$ 为 k 时刻的目标状态向量, 包含位置和速度信息。 $y(k)$ 为观测向量, $U(k) = [a_x(k) \ a_y(k)]^T$ 为未知的加速度向量, $W(k)$ 和 $V(k)$ 分别为状态噪声和观测噪声, 且为相互独立的高斯白噪声向量, 其协方差矩阵分别为 $Q(k)$ 和 $R(k)$ 。由于式(5)中加速度向量的不确定性, 给机动目标的跟踪带来了困难, 传统的跟踪算法中, 通常需要单独检测目标的机动性, 增加了算法的复杂度。为了避免这些问题, Khaloozadeh等人^[13]提出了一种新的机动目标跟踪算法, 把不确定的加速度向量扩展为状态的一个新分量, 并把机动目标状态模型转化为扩展状态下的非机动模型, 扩展的状态方程为

$$\begin{bmatrix} x(k+1) \\ U(k+1) \end{bmatrix} = \begin{bmatrix} F & C \\ 0 & I \end{bmatrix} \begin{bmatrix} x(k) \\ U(k) \end{bmatrix} + \begin{bmatrix} G \\ 0 \end{bmatrix} W(k), \quad (7)$$

则 $k+1$ 时刻的量测信息为

$$\begin{aligned} y(k+1) &= Hx(k+1) + V(k+1) = \\ &H\{Fx(k)+CU(k)+GW(k)\}+V(k+1) = \\ &[HF \ HC] \begin{bmatrix} x(k) \\ U(k) \end{bmatrix} + HGW(k) + V(k+1). \end{aligned} \quad (8)$$

由式(7)和式(8)可得标准的非机动扩展状态模型为:

$$x_{\text{aug}}(k+1) = F_{\text{aug}}(k)x_{\text{aug}}(k) + G_{\text{aug}}(k)W_{\text{aug}}(k), \quad (9)$$

$$y_{\text{aug}}(k) = H_{\text{aug}}(k)x_{\text{aug}}(k) + V_{\text{aug}}(k). \quad (10)$$

其中:

$$\begin{aligned} x_{\text{aug}}(k+1) &= \begin{bmatrix} x(k+1) \\ U(k+1) \end{bmatrix}^T, \\ F_{\text{aug}}(k) &= \begin{bmatrix} F & C \\ 0 & I \end{bmatrix}, \quad G_{\text{aug}}(k) = \begin{bmatrix} G \\ 0 \end{bmatrix}, \\ y_{\text{aug}}(k) &= y(k+1), \quad W_{\text{aug}}(k) = W(k), \\ H_{\text{aug}}(k) &= [HF \quad HC], \\ V_{\text{aug}}(k) &= HGW(k) + V(k+1). \end{aligned}$$

扩展的量测噪声 $V_{\text{aug}}(k)$ 与状态噪声 $W_{\text{aug}}(k)$ 的协方差为:

$$\begin{aligned} \mathbb{E} \begin{bmatrix} W_{\text{aug}}(k_1) \\ V_{\text{aug}}(k_1) \end{bmatrix} [W_{\text{aug}}^T(k_2) \quad V_{\text{aug}}^T(k_2)] &= \\ \begin{cases} \begin{bmatrix} Q_{\text{aug}}(k_1) & T_{\text{aug}}(k_1) \\ T_{\text{aug}}^T(k_1) & R_{\text{aug}}(k_1) \end{bmatrix}, & k_1 = k_2, \\ 0, & k_1 \neq k_2. \end{cases} \end{aligned}$$

其中:

$$\begin{aligned} Q_{\text{aug}}(k) &= \mathbb{E}[W_{\text{aug}}(k) \quad W_{\text{aug}}^T(k)] = Q(k), \\ R_{\text{aug}}(k) &= \mathbb{E}[V_{\text{aug}}(k) \quad V_{\text{aug}}^T(k)] = \\ &\quad HGQ(k)G^T H^T + R(k), \\ T_{\text{aug}}(k) &= \mathbb{E}[W_{\text{aug}}(k) \quad V_{\text{aug}}^T(k)] = Q(k)G^T H^T. \end{aligned}$$

此时, 虽然扩展的量测噪声 $V_{\text{aug}}(k)$ 与状态噪声 $W_{\text{aug}}(k)$ 时间相关, 但仍为高斯白噪声。因此, 扩展系统中, 状态的最优估计可以通过标准的卡尔曼滤波获得。该算法可以有效地实现对非机动或弱机动目标的跟踪, 但对加速度发生大幅度变化的强机动目标跟踪时, 由于预测协方差不能得到合理地调整, 导致算法发散。

3.2 强跟踪多重渐消因子(Strong tracking multiple fading factors)

文献[16]中提出一种强跟踪滤波器, 该滤波器采用在线选择适当的时变增益, 使输出残差近似为高斯白噪声。它与常规滤波器相比, 具有较强模型参数失配的鲁棒性、极强的突变状态跟踪能力以及适中的计算复杂度等优点。本文在MIE算法基础上, 借鉴强跟踪滤波思想, 引入时变的多重渐消因子, 实时调节滤波器预测协方差来增强MIE算法对加速度发生大幅度变化的机动目标跟踪性能。

根据强跟踪滤波器的设计原理, 要使得MIE滤波器具有强跟踪滤波性能, 需通过在线选择合适的滤

波增益, 使得式(11)和(12)成立, 即

$$\begin{aligned} \mathbb{E}\{[x_{\text{aug}}(k+1) - \hat{x}_{\text{aug}}(k+1|k+1)]^T \cdot \\ [x_{\text{aug}}(k+1) - \hat{x}_{\text{aug}}(k+1|k+1)]\} &= \min, \quad (11) \end{aligned}$$

$$\begin{aligned} \mathbb{E}[d_{\text{aug}}^T(k+1)d_{\text{aug}}(k+1+j)] &= 0, \quad (12) \\ k = 0, 1, \dots, j = 1, 2, \dots \end{aligned}$$

其中 $d_{\text{aug}}(k+1)$ 为残差,

$$\begin{aligned} d_{\text{aug}}(k+1) &= \\ y_{\text{aug}}(k+1) - H_{\text{aug}}(k+1)\hat{x}_{\text{aug}}(k+1|k). \quad (13) \end{aligned}$$

在滤波过程中要获得适当的时变增益, 则需对滤波过程中预测协方差 $P_{\text{aug}}(k+1|k)$ 进行实时调整。因此, 为了获得最佳的滤波增益, 预测协方差表达式可写为:

$$\begin{aligned} P_{\text{aug}}(k+1|k) &= \Lambda(k+1)F_{\text{aug}}(k)P_{\text{aug}}(k|k)F_{\text{aug}}^T(k) + \\ &\quad G_{\text{aug}}(k)Q_{\text{aug}}(k)G_{\text{aug}}^T(k). \quad (14) \end{aligned}$$

其中 $\Lambda(k+1)$ 为多重渐消因子矩阵, 可根据残差的变化以不同速率实时地调整滤波器不同通道的预测协方差, 从而相应地调整滤波增益。经过推导, 可得 $\Lambda(k+1)$ 的计算公式如下:

$$\Lambda(k+1) = \text{diag}\{\lambda_1(k+1), \dots, \lambda_n(k+1)\}, \quad (15)$$

其中 $\lambda_i(k+1)$, $i = 1, 2, \dots, n$ 为渐消因子。

$$\lambda_i(k+1) = \begin{cases} a_i c(k+1), & a_i c(k+1) > 1, \\ 1, & a_i c(k+1) \leq 1. \end{cases} \quad (16)$$

$$c(k+1) = \frac{\text{tr}[N(k+1)]}{\sum_{i=1}^n a_i M_{ii}(k+1)}, \quad (17)$$

$$\begin{aligned} N(k+1) &= \\ S_0(k+1) - \beta R_{\text{aug}}(k+1) - H_{\text{aug}}(k+1) \cdot \\ G_{\text{aug}}(k)Q_{\text{aug}}(k)G_{\text{aug}}^T(k)H_{\text{aug}}^T(k+1), \quad (18) \\ M(k+1) &= \\ F_{\text{aug}}(k)P_{\text{aug}}(k|k)F_{\text{aug}}^T(k)H_{\text{aug}}^T(k+1)H_{\text{aug}}(k+1), \quad (19) \end{aligned}$$

其中 $N(k+1)$ 和 $M(k+1)$ 没有具体意义, 是为了保证不同时刻残差近似正交而推导得出:

$$\begin{aligned} S_0(k+1) &= \mathbb{E}[d_{\text{aug}}(k+1)d_{\text{aug}}^T(k+1)] = \\ \begin{cases} d_{\text{aug}}(1)d_{\text{aug}}^T(1), & k = 0, \\ \frac{[\rho S_0(k) + d_{\text{aug}}(k+1)d_{\text{aug}}^T(k+1)]}{1+\rho}, & k \geq 1. \end{cases} \quad (20) \end{aligned}$$

式(16)~(20)中, $0 < \rho \leq 1$ 为遗忘因子, 一般取 $\rho = 0.95$; $\beta \geq 1$ 为弱化因子, 可以使得状态估计值更加平滑; $S_0(k+1)$ 为残差的二阶矩; $a_i \geq 1$, $i = 1, 2, \dots, n$ 为可以预先设定的系数, 如果状态中某个分量

变化很快, 则可选较大的 a_i 进一步提高滤波器的跟踪能力; 如果 $a_i = 1, i = 1, 2, \dots, n$, 此时, 多重渐消因子将退化为单渐消因子。关于部分参数值的选取可以参考文献[16, 17]。

3.3 STMIE滤波基本步骤(Steps of the STMIE filtering)

Step 1 一步预测.

一步预测协方差 $\mathbf{P}_{\text{aug}}(k+1|k)$ 可由式(14)求出, 状态的一步预测表达式如下:

$$\hat{x}_{\text{aug}}(k+1|k) = F_{\text{aug}}(k)\hat{x}_{\text{aug}}(k|k). \quad (21)$$

Step 2 一步更新.

$$\begin{aligned} \hat{x}_{\text{aug}}(k+1|k+1) &= \\ \hat{x}_{\text{aug}}(k+1|k) + K_{\text{aug}}(k+1) \times & \\ [y_{\text{aug}}(k+1) - H_{\text{aug}}(k+1)\hat{x}_{\text{aug}}(k+1|k)], & \quad (22) \end{aligned}$$

$$\begin{aligned} \mathbf{P}_{\text{aug}}(k+1|k+1) &= \\ \mathbf{P}_{\text{aug}}(k+1|k) - \mathbf{P}_{\text{aug}}(k+1|k)H_{\text{aug}}^T(k+1) \times & \\ [R_{\text{aug}}(k+1) + H_{\text{aug}}(k+1)\mathbf{P}_{\text{aug}}(k+1|k) \times & \\ H_{\text{aug}}^T(k+1)]^{-1}H_{\text{aug}}(k+1)\mathbf{P}_{\text{aug}}(k+1|k). & \quad (23) \end{aligned}$$

其中滤波器增益 $K_{\text{aug}}(k+1)$ 为

$$\begin{aligned} K_{\text{aug}}(k+1) &= [\mathbf{P}_{\text{aug}}(k+1|k)H_{\text{aug}}^T(k+1) + \\ G_{\text{aug}}(k)T_{\text{aug}}(k)]R_{\text{aug}}^{-1}(k). & \quad (24) \end{aligned}$$

从式(24)可以看出, 扩展状态下滤波器的增益 $K_{\text{aug}}(k+1)$ 由预测协方差矩阵 $\mathbf{P}_{\text{aug}}(k+1|k)$ 和 $T_{\text{aug}}(k)$ 共同决定。通常当系统发生强机动时, 残差迅速增大, 预测协方差将通过多重渐消因子矩阵 $\Lambda(k+1)$ 及时调整, 从而导致滤波增益能得到合理地调整, 增强了MIE算法对强机动目标的跟踪能力, 且 $\Lambda(k+1)$ 能分别对不同的数据通道以不同的速率进行渐消, 充分考虑了不同数据通道的数据变化情况, 显著提高了算法对机动目标的跟踪精度。当系统发生弱机动或匀速运动时, $\Lambda(k+1)$ 将退化为单位矩阵, 此时, $T_{\text{aug}}(k)$ 将起到决定性作用, 能适当调节滤波器的增益, 使得滤波器仍能保持收敛, 且稳定跟踪。

4 强跟踪输入估计概率假设密度滤波(Strong tracking modified input estimation hypothesis density filter)

假设 $k-1$ 时刻目标状态的后验概率假设密度函数 $D_{k-1|k-1}(x)$ 满足混合高斯分布, 则 k 时刻目标状态的预测概率假设密度函数 $D_{k|k-1}(x)$ 可表示为^[8]

$$D_{k|k-1}(x) = D_{S,k|k-1}(x) + b_{k|k-1}(x) + \gamma_k(x). \quad (25)$$

其中: $D_{S,k|k-1}(x)$, $b_{k|k-1}(x)$, $\gamma_k(x)$ 分别为存活目标

状态集合、衍生目标状态集合和新生目标状态集合的预测概率假设密度, 且

$$\begin{aligned} D_{S,k|k-1}(x) &= \\ \Pr_{S,k} \sum_{i=1}^{J_{k-1}} w_{k-1}^{(i)} N(x; \mathbf{m}_{S,k|k-1}^{(i)}, \mathbf{P}_{S,k|k-1}^{(i)}), & \quad (26) \end{aligned}$$

$$\begin{aligned} b_{k|k-1}(x) &= \\ \sum_{i=1}^{J_{k-1}} \sum_{j=1}^{J_{b,k}} w_{k-1}^{(i)} w_{b,k}^{(j)} N(x; \mathbf{m}_{b,k|k-1}^{(i,j)}, \mathbf{P}_{b,k|k-1}^{(i,j)}), & \quad (27) \end{aligned}$$

$$\gamma_k(x) = \sum_{i=1}^{J_{\gamma,k}} w_{\gamma,k}^{(i)} N(x; \mathbf{m}_{\gamma,k}^{(i)}, \mathbf{P}_{\gamma,k}^{(i)}). \quad (28)$$

$w_{k-1}^{(i)}$ 和 J_{k-1} 为 $k-1$ 时刻高斯分量的权值及总个数; $\mathbf{m}_{S,k|k-1}^{(i)}$ 及 $\mathbf{P}_{S,k|k-1}^{(i)}$ 分别为第*i*个存活目标的均值及其协方差矩阵的预测; $w_{b,k}^{(j)}$, $\mathbf{m}_{b,k|k-1}^{(i,j)}$ 和 $\mathbf{P}_{b,k|k-1}^{(i,j)}$ 分别表示 $k-1$ 时刻的第*i*个目标衍生的第*j*个目标对应的高斯分量的权值、预测均值和预测协方差矩阵; $w_{\gamma,k}^{(i)}$, $\mathbf{m}_{\gamma,k}^{(i)}$ 和 $\mathbf{P}_{\gamma,k}^{(i)}$ 是已知的新生目标对应的高斯分量的权值、均值和协方差矩阵。 $J_{b,k}$ 和 $J_{\gamma,k}$ 分别为衍生高斯分量及新生高斯分量的个数。式(26)和式(27)中高斯分量的均值和协方差可由STMIE滤波算法估计出, 过程可简单描述为

$$\begin{aligned} [\mathbf{m}_{S,k|k-1}^{(i)}, \mathbf{P}_{S,k|k-1}^{(i)}] &= \\ \text{STMIE}_P[\mathbf{m}_{S,k-1|k-1}^{(i)}, \mathbf{P}_{S,k-1|k-1}^{(i)}, & \\ F_{\text{aug}}(k-1), Q_{\text{aug}}(k-1)], & \\ [\mathbf{m}_{b,k|k-1}^{(i,j)}, \mathbf{P}_{b,k|k-1}^{(i,j)}] &= \\ \text{STMIE}_P[\mathbf{m}_{b,k-1|k-1}^{(i,j)}, \mathbf{P}_{b,k-1|k-1}^{(i,j)}, & \\ F_{\text{aug}}(k-1), Q_{\text{aug}}(k-1)]. & \quad (29) \end{aligned}$$

其中 $\text{STMIE}_P[\cdot]$ 表示STMIE算法一步预测滤波。

设 k 时刻的预测概率假设密度函数满足混合高斯分布, 即

$$D_{k|k-1}(x) = \sum_{i=1}^{J_{k|k-1}} w_{k|k-1}^{(i)} N(x; \mathbf{m}_{k|k-1}^{(i)}, \mathbf{P}_{k|k-1}^{(i)}). \quad (30)$$

则后验概率假设密度函数也可表述为混合加权的高斯和形式,

$$D_k(x) = (1 - \Pr_{D,k})D_{k|k-1}(x) + \sum_{y \in Y_k} D_{D,k}(x; y). \quad (31)$$

式(31)中

$$D_{D,k}(x; y) = \sum_{j=1}^{J_{k|k-1}} w_k^{(j)}(y) N(x; \mathbf{m}_{k|k}^{(j)}, \mathbf{P}_{k|k}^{(j)}). \quad (32)$$

其中高斯分量更新的均值、协方差和权值为:

$$\begin{aligned} [\mathbf{m}_{k|k}^{(i)}, \mathbf{P}_{k|k}^{(i)}] &= \\ \text{STMIE}_U[\mathbf{m}_{k|k-1}^{(i)}, \mathbf{P}_{k|k-1}^{(i)}, y_k, H_{\text{aug}}(k), R_{\text{aug}}(k)], & \quad (33) \end{aligned}$$

$$w_k^{(j)}(y) = \frac{\Pr_{D,k} w_{k|k-1}^{(j)} q_k^{(j)}(y)}{\kappa_k(y) + \Pr_{D,k} \sum_{i=1}^{J_{k|k-1}} w_{k|k-1}^{(i)} q_k^{(j)}(y)}. \quad (34)$$

其中:

$$q_k^{(j)}(y) = N(y; H_{\text{aug}}(k) \mathbf{m}_{k|k-1}^{(j)}, H_{\text{aug}}(k) \mathbf{P}_{k|k-1}^{(j)} H_{\text{aug}}^T(k) + R_{\text{aug}}(k)).$$

STMIE_U[·]表示STMIE算法一步更新滤波, $\Pr_{D,k}$ 为检测概率, $\kappa_k(y) = \lambda_k c_k(y)$ 为观测杂波集合的PHD, 其中杂波数目服从 λ_k 的泊松分布, $c_k(y)$ 为杂波概率密度分布。根据式(25)~(34)可实现对未知数目的多机动目标跟踪。

5 实验结果及分析(Simulation results and analysis)

为了验证提出算法的有效性及实时性, 仿真中考虑一个数目变化的机动目标跟踪例子, 场景中含有匀速运动、弱机动和加速度发生大幅度变化的强机动3种运动情况。假设二维场景情况下, 初始时刻有两个目标, 目标1($t=1 \sim 80$ s)的初始位置为 $(p_{x1}, p_{y1}) = (1000 \text{ m}, 0 \text{ m})$, 初始速度为 $(v_{x1}, v_{y1}) = (100 \text{ m/s}, 100 \text{ m/s})$, 匀速运动80 s; 目标2($t=1 \sim 60$ s)的初始位置为 $(p_{x2}, p_{y2}) = (1000 \text{ m}, 2000 \text{ m})$, 初始速度为 $(v_{x2}, v_{y2}) = (100 \text{ m/s}, 100 \text{ m/s})$, 先作15 s匀速运动, 在 $t=16$ s时发生弱机动, 加速度为 $(a_{x2}, a_{y2}) = (0 \text{ m/s}^2, 5 \text{ m/s}^2)$, 持续到30 s, 最后作强机动, 加速度为 $(a_{x2}, a_{y2}) = (5 \text{ m/s}^2, -15 \text{ m/s}^2)$, 持续到50 s, 然后作匀速运动, 在第60 s时消失; 目标3($t=40 \sim 70$ s)的初始位置为 $(p_{x3}, p_{y3}) = (1000 \text{ m}, 2000 \text{ m})$, 先做10 s匀速运动, 速度为 $(v_{x3}, v_{y3}) = (110 \text{ m/s}, 90 \text{ m/s})$, $t=51$ s时以加速度 $(a_{x3}, a_{y3}) = (5 \text{ m/s}^2, -15 \text{ m/s}^2)$ 开始加速, 持续到70 s消失。实验中为了简便, 没有考虑衍生目标。假设3个目标的观测噪声都为50 m, 平均每个采样时刻有 $\lambda=5$ 个杂波, 采样周期取 $T=1$ s, 目标的存活概率 $\Pr_{S,k}=0.99$, 检测概率 $\Pr_{D,k}=0.98$ 。目标的真实运动轨迹如图1所示。

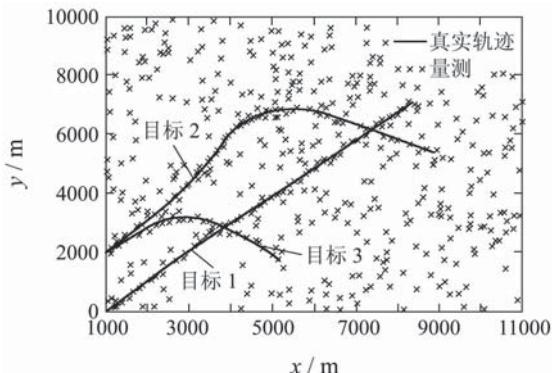


图1 目标运动真实轨迹及量测

Fig. 1 Target tracks and measurements

仿真中采用最优子模式分配(optimal subpattern assignment, OSPA)距离来评价3种算法的估计精度。对于任意有限集 $L_1 = \{l_{11}, \dots, l_{1m}\}$ 和 $L_2 = \{l_{21}, \dots, l_{2n}\}$, m 和 n 为正整数, 当 $m \leq n$ 时, 定义它们之间的 p 阶OSPA距离为^[18]

$$\bar{d}_p^{(c)}(L_1, L_2) = \left(\frac{1}{n} \left(\min_{\pi \in \prod_n} \sum_{i=1}^m d^{(c)}(l_{1i}, l_{2\pi(i)}) \right)^p + c^p (n-m) \right)^{1/p}, \quad 1 \leq p < \infty. \quad (35)$$

其中: $d^{(c)}(l_{1i}, l_{2\pi(i)}) = \min(c, d(l_{1i}, l_{2\pi(i)}))$; c 为一大于零的常数, 反应目标势估计误差对性能的影响程度; p 在OSPA中的意义与其在Wasserstein距离中的意义类似; \prod_n 表示 $n=1, 2, \dots, k$ 的所有排列组成集合。如果 $m \geq n$, 则可令

$$\bar{d}_p^{(c)}(L_1, L_2) = \bar{d}_p^{(c)}(L_2, L_1).$$

此外, 当 $p \rightarrow \infty$ 时,

$$\bar{d}_\infty^{(c)}(L_1, L_2) = \begin{cases} \min_{\pi \in \prod_n} \max_{1 \leq i \leq n} d^{(c)}(l_{1i}, l_{2\pi(i)}), & m=n, \\ c, & m \neq n. \end{cases} \quad (36)$$

仿真实验在主频为Pentium(R)4, CPU 3.06 GHz, 内存1 GB的PC机上采用MATLAB7.4软件完成。图2分别给出了本文提出算法、传统的当前统计模型概率假设密度(CSM-PHD)滤波算法和匀加速概率假设密度(CA-PHD)滤波算法估计的多机动目标轨迹与真实轨迹的对比情况, 图3给出了3种算法分别对多机动目标数目的估计结果。其中CSM-PHD算法中最大加速度取100 m/s², 机动频率大小取0.1。

从图2(a)中可以明显看出, 由于本文提出的算法中, 多重渐消因子可以以不同的速率对滤波器不同通道的数据进行合理地调节, 从而实现对多机动目标轨迹估计的精度明显要高于其他两种算法, 无论是对匀速运动的目标1, 还是对加速度发生突变的目标2和新生目标3都具有很好的跟踪结果。图2(b)中可以看出CSM-PHD算法虽然可以跟踪多机动目标, 但由于CSM算法本身存在缺陷, 对匀速运动和弱机动目标跟踪性能较差, 估计的轨迹与真实轨迹之间存在较大的偏离。图2(c)中可以看出CA-PHD算法的跟踪性能最差, 因为跟踪模型与目标实际运动模式不匹配, 导致对目标2和新生目标3跟踪时出现严重的失跟现象。从图3中也可以看出, 本文算法对目标数目的估计也明显要好于其他两种算法, 除了有3个时刻过估计外, 其他时刻均能正确估计目标的数目, 而CSM-PHD算法在目标匀速阶段出现了多个时刻目标数目估计不准的现象, CA-PHD算法则出现大量的目标漏跟。

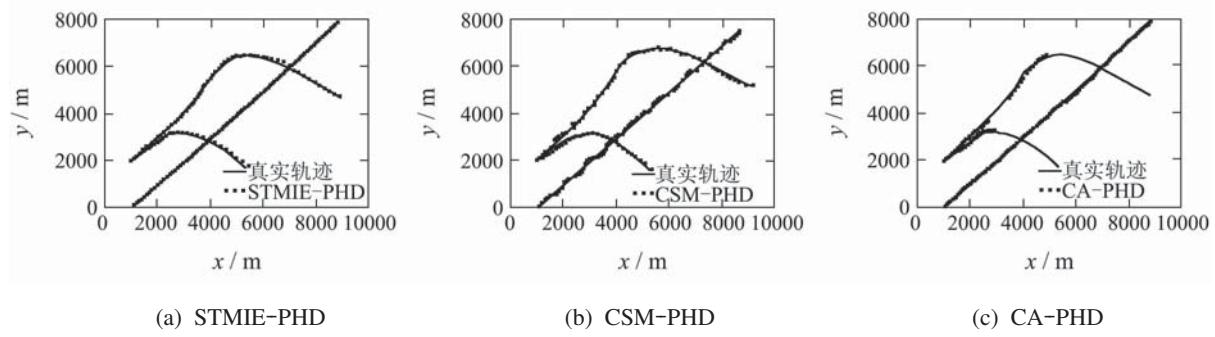


图 2 3种算法对多机动目标的估计轨迹与真实轨迹的对比

Fig. 2 The comparison of the estimated tracks by the three algorithms with the true tracks

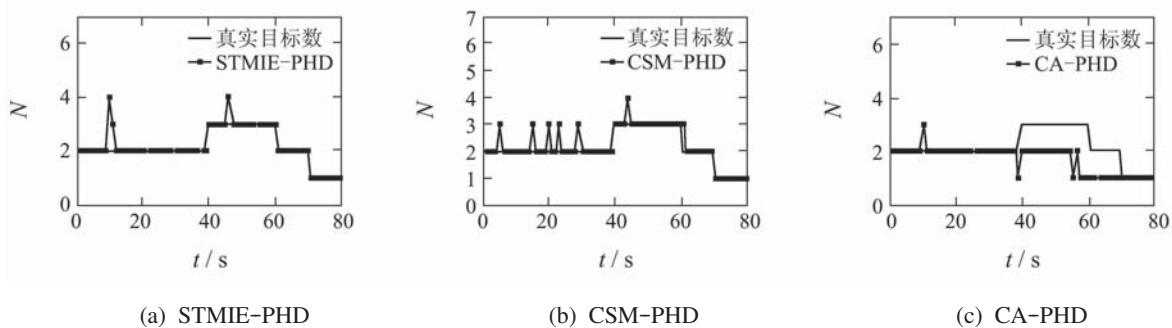


图 3 3种不同算法估计的目标数与真实目标数的对比

Fig. 3 The comparison of the estimated target number by the three algorithms with the true target number

图4和表1都给出了3种算法跟踪精度的对比情况,均为100次蒙特卡罗(Monte Carlo)仿真结果,可以看出,本文算法对多机动目标的估计精度最高,CSM-PHD算法其次,而CA-PHD算法由于对机动目标跟踪时出现大量的漏跟而导致跟踪精度最差。

从表1中还可计算出本文算法比CSM-PHD算法在估计精度上提高了28.0%，比CA-PHD提高了70.0%。本文算法的平均单步运算时间也要明显低于其他两种算法，具有较好的实时性。

6 结束语(Conclusions)

本文在MIE算法基础上,借鉴强跟踪滤波思想,对MIE滤波算法作了改进,并将改进的MIE方法与概率假设密度滤波器有效结合,提出一种新的多机动目标跟踪算法,可以实时地跟踪杂波环境下未知数目的多机动目标,对加速度发生大幅度变化的机动目标也具有较好的适应性,在机动目标跟踪领域有着良好的实际工程应用价值.

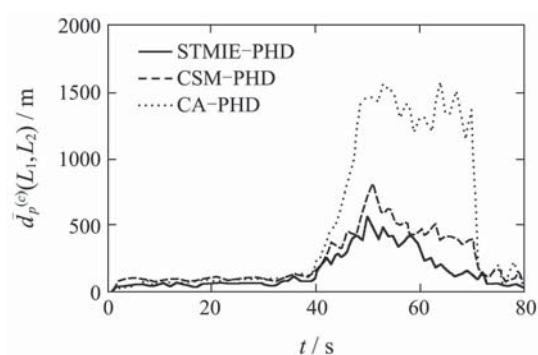


图 4 QSPA 距离比较 ($p \equiv 2, c \equiv 600$)

Fig. 4 The comparison of the three algorithms in OSPA distance

表1 3种算法单步平均跟踪精度和运算时间比较

Table 1 Comparison of the three algorithms in tracking accuracy and average run-time of each step

算法	STMIE-PHD	CSM-PHD	CA-PHD
OSPA距离/m	110.1167	152.9755	367.4068
平均单步时间/s	0.7372	0.9850	0.9700

- 参考文献(References):**

 - [1] FORTMANN T, BAR-SHALOM Y, SCHEFFE M. Sonar tracking of multiple targets using joint probabilistic data association[J]. *IEEE Journal of Oceanic Engineering*, 1983, 8(3): 173 – 183.
 - [2] MUSICKI D, EVANS R. Joint integrated probabilistic data association: JIPD[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2004, 40(3): 1093 – 1099.
 - [3] BLACKMAN S. Multiple hypothesis tracking for multiple target tracking[J]. *IEEE Aerospace and Electronic Systems Magazine*, 2004, 19(1): 5 – 18.
 - [4] ROECKER J, PILLIS G. Suboptimal joint probabilistic data association[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1993, 29(2): 504 – 510.

- [5] ROECKER J. A class of near optimal JPDA algorithms[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1994, 30(2): 504 – 510.
- [6] PURANK S, TUGNAIT J K. Tracking of multiple maneuvering targets using multiscan JPDA and IMM filter[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(1): 23 – 34.
- [7] MAHLER R. Multitarget bayes filtering via first-order multitarget moments[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 29(4): 1152 – 1178.
- [8] VO B N, MA W K. The Gaussian mixture probability hypothesis density filter[J]. *IEEE Transactions on Signal Processing*, 2006, 54 (11): 4091 – 4104.
- [9] YIN J J, ZHANG J Q, ZHANG Z S. Gaussian sum PHD filtering algorithm for nonlinear non-gaussian models[J]. *Chinese Journal of Aeronautics*, 2008, 21(4): 341 – 351.
- [10] JIN M G, HONG S H, SHI Z G, et al. Current statistical model probability hypothesis density filter for multiple maneuvering targets tracking[C] // *International Conference on Wireless Communication & Signal Processing*. Piscataway, NJ: IEEE, 2009: 1 – 5.
- [11] PUNITHAKUMAR K, KIRUBARAJAN T. Multiple-model probability hypothesis density filter for tracking maneuvering targets[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2008, 44(1): 87 – 98.
- [12] HONG S H, SHI Z G, CHEN K S. Novel multiple-model probability hypothesis density filter for multiple maneuvering targets tracking[C] // *Postgraduate Research in Asia Pacific Conference on Microelectronics & Electronics*. Piscataway, NJ: IEEE, 2009: 189 – 192.
- [13] KHALOOZADEH H, KARSAZ A. Modified input estimation technique for tracking maneuvering targets[J]. *IET Radar, Sonar and Navigation*, 2009, 3(1): 30 – 41.
- [14] BAHARI M H, NAGHIBI SISTANI M B, PARIZ N. Intelligent fading memory for high maneuvering target tracking[J]. *International Journal of Physical Sciences*, 2009, 4(10): 548 – 554.
- [15] BAHARI M H, PARIZ N. High maneuvering target tracking using an input estimation technique associated with fuzzy forgetting factor[J]. *Scientific Research and Essay*, 2009, 4(10): 936 – 945.
- [16] ZHOU D H, FRANK P M. Strong tracking filtering of nonlinear time-varying stochastic systems with coloured noise: application to parameter estimation and empirical robustness analysis[J]. *International Journal of Control*, 1996, 65(2): 295 – 307.
- [17] ZHOU D H. On-line adaptive estimation of time-varying time delay[J]. *Acta Electronica Sinica*, 1999, 27(12): 61 – 63.
- [18] SCHUHMACHER D, VO B T, VO B N. 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:

杨金龙 (1981—), 男, 博士研究生, 主要研究方向为信号处理与检测、机动目标跟踪等, E-mail: yjlgedeng@163.com;

姬红兵 (1963—), 男, 教授, 博士生导师, 主要研究方向为被动多传感器定位与跟踪、雷达目标识别与分类、微弱信号检测等, E-mail: hbj@xidian.edu.cn;

樊振华 (1985—), 男, 博士研究生, 主要研究方向为信号处理与检测、视频跟踪等, E-mail: fzh_xd@163.com.