

DOI:10.11918/202210098

非线性量测下的机动多目标跟踪

国强^{1,2}, 任海宁^{1,2}, 周凯^{1,2}, 戚连刚^{1,2}

(1. 哈尔滨工程大学 信息与通信工程学院, 哈尔滨 150001;

2. 先进船舶通信与信息技术工业和信息化部重点实验室(哈尔滨工程大学), 哈尔滨 150001)

摘要: 为了解决非线性量测下机动多目标跟踪实时性差、跟踪误差大以及对杂波变化鲁棒性较差的问题, 基于随机有限集理论, 提出了一种采用量测转换和模糊算法改进的多模型 δ -广义标签多伯努利滤波器。首先, 推导了交互多模型的 δ -GLMB 滤波器, 通过去相关无偏量测转换实现位置量测从极坐标系到笛卡尔坐标系的无偏转换, 并通过预测值去除量测误差和其协方差的相关性造成的滤波估计偏差, 实现了非线性场景下的机动多目标跟踪; 然后, 通过航迹和量测的关联新息以及目标的机动约束构建联合波门, 降低了杂波量测的数量; 最后引入改进的模糊算法, 以目标的模型后验概率为输入, 根据模型的分离程度自适应调节运动模型的过程噪声, 增加滤波精度。研究结果表明: 在杂波环境下, 通过与 CKF-JMS- δ -GLMB、CKF-IMM- δ -GLMB 等非线性多模型滤波器对比, 所提算法计算时间较小, 且跟踪精度更高, 鲁棒性强。所提算法避免了传统的非线性处理方式计算量较大的问题, 并且具有较好的杂波抑制特性, 提升了非线性量测下机动多目标跟踪的性能。

关键词: 非线性量测; 机动多目标; δ -广义标签多伯努利滤波器; 量测转换; 交互多模型; 模糊算法

中图分类号: TN953

文献标志码: A

文章编号: 0367-6234(2024)05-0064-10

Multiple maneuvering target tracking with nonlinear measurements

GUO Qiang^{1,2}, REN Haining^{1,2}, ZHOU Kai^{1,2}, QI Liangang^{1,2}

(1. College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China;

2. Key Laboratory of Advanced Ship Communication and Information Technology (Harbin Engineering University),
Ministry of Industry and Information Technology, Harbin 150001, China)

Abstract: In order to solve the problems of poor real-time performance, significant tracking errors and poor robustness to clutter changes with maneuvering multi-target tracking with nonlinear measurement, a multi-model δ -generalized labeled multi-Bernoulli (δ -GLMB) filter is proposed in light of the random finite set (RFS) theory, capitalizing on measurement transformation and a fuzzy algorithm. Initially, the interactive multiple model (IMM) δ -GLMB filter realizes the unbiased conversion of position measurement from polar coordinate system to Cartesian coordinate system by initiating an uncorrelated unbiased measurement conversion and removes the filter estimation deviation caused by the correlation between measurement errors and their covariances on the basis of the predicted value, thus realizing the maneuvering multi-target tracking in nonlinear scenarios. Then, the number of clutter measurements is reduced by constructing a joint gate that takes into account track and measurement correlation and target maneuver constraints. Finally, an improved fuzzy algorithm is introduced, which takes the posterior model probability of the target as the input, to adaptively adjust the process noise of the motion model according to the separation degree of the model, thereby increasing filtering accuracy. The research result shows that in the clutter environment, compared with CKF-JMS- δ -GLMB, CKF-IMM- δ -GLMB, and other nonlinear filters, the proposed algorithm performs better in terms of computation time, tracking accuracy and robustness. The proposed algorithm sidesteps the computational burden typically associated with traditional nonlinear processing methods, and has better clutter suppression characteristics, which improves the performance of maneuvering multi-target tracking with nonlinear measurement.

Keywords: nonlinear measurements; maneuvering multiple target; δ -generalized labeled multi-Bernoulli (δ -GLMB); converted measurement; interactive multiple model; fuzzy algorithm

非线性量测下的机动目标跟踪问题是多目标跟踪 (multi-target tracking, MTT) [1] 领域的热点问题之

一。一方面实际场景中常见的传感器, 诸如雷达、声呐等, 捕获到的目标量测信息均为非线性的, 滤波时

收稿日期: 2022-10-25; 录用日期: 2023-01-10; 网络首发日期: 2023-03-31

网络首发地址: <http://kns.cnki.net/kcms/detail/23.1235.T.20230331.1533.014.html>

基金项目: 国家重点研发计划(2018YFE0206500); 国家自然科学基金(62071140); 中央高校基本科研业务费专项(3072022QBZ0801)

作者简介: 国强(1972—), 男, 教授, 博士生导师

通信作者: 戚连刚, qiliangang@hrbeu.edu.cn

无法直接得到闭合形式的解;另一方面被跟踪的目标常具有机动性,单一运动模型无法描述目标的运动状态,易产生目标的漏估。因此需要对非线性量测下的机动多目标跟踪算法展开研究。

近几年,基于随机有限集(random finite set, RFS)^[2]的MTT算法因避免了传统数据关联^[3]算法中的NP问题,受到广泛的关注。经典的RFS多目标跟踪算法有:概率假设密度(probability hypothesis density, PHD)^[4]、势概率假设密度(cardinalized probability hypothesis density, CPHD)^[5]、多伯努利(multiple target multi-Bernoulli, MeMBer)^[6]以及 δ -广义标签多伯努利(δ -generalized labeled multi-Bernoulli, δ -GLMB)^[7]滤波器。其中 δ -GLMB能够利用标签信息准确的产生航迹,跟踪性能优异,被证明为最优贝叶斯滤波器,是本文研究的基础。

在非线性量测场景中, δ -GLMB算法一般通过扩展卡尔曼(extended Kalman filter, EKF)^[8]、无迹卡尔曼(unscented Kalman filter, UKF)^[9]、容积卡尔曼(cubature Kalman filter, CKF)^[10]等线性化技术将非线性滤波问题转化为近似线性滤波问题,但这些技术的应用会使算法的计算复杂度大幅度增加。而另一类基于量测转换卡尔曼(converted measurement Kalman filter, CMKF)^[11]的方法,可直接将非线性量测转化为线性量测,再使用卡尔曼求解,避免了此问题,却因转换有偏导致跟踪精度较低,应用较少。

另外,为了实现对机动多目标的跟踪,文献[12]引入了马尔科夫跳变系统(jump Markov system, JMS),推导了JMS- δ -GLMB高斯混合实现的闭式解,但其只能应用于线性高斯场景;文献[13]提出了无迹变换的马尔科夫多模型 δ -GLMB(UKF-JMS- δ -GLMB)滤波器,实现了非线性场景的应用,但其在滤波阶段使用的分支真实密度以及UKF为近似先验分布所产生的点集,导致计算量过于庞大;文献[14]对分支密度进行合并,提出了交互多模型 δ -GLMB(IMM- δ -GLMB)滤波器,降低了计算量,但其计算时间仍随着杂波率线性增加。

针对上述非线性量测下的机动多目标 δ -GLMB算法计算复杂度较高、跟踪误差较大以及对杂波变化鲁棒性较差的问题,本文提出了一种采用去相关无偏量测转换(decorrelated unbiased converted measurement, DUCM)^[15]和模糊算法^[16]改进的多模型 δ -GLMB(DUCM-FIMM- δ -GLMB)滤波器。该算法使用DUCM处理非线性量测,实现位置量测从极坐标系到笛卡尔坐标系的无偏转换,并通过预测值去除量测误差和其协方差的相关性造成的滤波估计偏差;然后基于量测关联新息和目标的机动约束构

建联合波门,降低杂波环境中无效关联量测的数量;最后在IMM的基础上引入模糊算法,自适应改变运动模型的过程噪声,进一步提升对机动多目标的跟踪精度。仿真结果表明,所提算法与现有算法相比跟踪精度更高,计算时间更少,鲁棒性更强。

1 背景模型

1.1 状态模型

在二维多目标运动场景中,假设 k 时刻有 N 个目标,则多目标状态RFS建模为 $X_k = \{\mathbf{x}_{1,k}, \dots, \mathbf{x}_{N,k}\}$, $\mathbf{x}_{i,k} = [x_{i,k}, \dot{x}_{i,k}, y_{i,k}, \dot{y}_{i,k}]^T$,其中 $x_{i,k}, y_{i,k}$ 为目标的位置坐标, $\dot{x}_{i,k}, \dot{y}_{i,k}$ 为目标在 x, y 方向的速度。目标的运动状态方程为

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

式中: $\mathbf{F}$ 为状态转移矩阵; $\mathbf{w}_{k-1}$ 为过程噪声,服从均值为零、标准差为 σ_μ 的高斯分布。

1.2 量测模型

假设传感器在 k 时刻获取到 M 个量测信息 $Z_k^m = \{\mathbf{z}_{1,k}^m, \dots, \mathbf{z}_{M,k}^m\}$, $\mathbf{z}_{j,k}^m = [\gamma_{j,k}^m, \beta_{j,k}^m]^T$,其中 $\gamma_{j,k}^m, \beta_{j,k}^m$ 分别为目标的径向距离和方位角。目标状态和量测之间的关系可表示为

$$\mathbf{z}_k^m = h(\mathbf{x}_k) + \mathbf{v}_k^m \quad (2)$$

式中 $h(\cdot)$ 为非线性函数,式(2)可写为

$$\begin{bmatrix} \gamma_k^m \\ \beta_k^m \end{bmatrix} = \begin{bmatrix} \sqrt{x_k^2 + y_k^2} \\ \arctan(y_k/x_k) \end{bmatrix} + \begin{bmatrix} \tilde{\gamma}_k^m \\ \tilde{\beta}_k^m \end{bmatrix} \quad (3)$$

式中 $\tilde{\gamma}_k^m, \tilde{\beta}_k^m$ 为径向距离和方位角的量测噪声,服从均值为零、标准差为 σ_γ 和 σ_β 的高斯分布。

1.3 δ -GLMB RFS模型

引入标签集,用标签 l 对状态 $\mathbf{x}$ 进行扩维,则多目标状态 X 可由标签RFS表示为

$$X = \{(\mathbf{x}, l)_1, (\mathbf{x}, l)_2, \dots, (\mathbf{x}, l)_N\} \quad (4)$$

式中: $\mathbf{x} \in X$ 为目标状态矢量, $l \in L$ 为其唯一一对对应标签; $X \subseteq X \times L$, X 为状态空间, L 为标签空间。

设 k 时刻的多目标概率密度 $\pi_{klk}(X)$ 服从 δ -GLMB分布,如下式所示:

$$\pi_{klk}(X) = \Delta(X) \sum_{(l, \vartheta) \in \mathcal{T}(L_{klk}) \times \Xi} w_{klk}^{(l, \vartheta)} \delta_l(\mathcal{L}(X)) [p_{klk}^{(\vartheta)}]^\mathbf{X} \quad (5)$$

式中, $\mathcal{L}: X \times L \rightarrow L$ 为标签投影函数,即 $\mathcal{L}(x, l) = l$; $\mathcal{T}(L)$ 为 L 的所有子集空间; $\delta(\cdot)$ 为狄拉克 δ 函数; $\Delta(X) = \delta_{|\mathbf{x}|}(|\mathcal{L}(X)|)$ 为标签互异指示器。 $\vartheta \in \Xi$ 为关联映射历史信息, Ξ 为关联空间;对于滤波密度, ϑ 为截止到 k 时刻的关联映射历程,即 $\vartheta = (\theta_0, \theta_1, \dots, \theta_k)$, θ 为航迹标签到量测索引的映射函数。 $p_{klk}^{(\vartheta)}$ 为单目标的概率密度, $w_{klk}^{(l, \vartheta)}$ 为假设分量的权值,

二维数组 (I, ϑ) 表示航迹集合 I 具有关联映射历程 ϑ 时的假设。将 $\pi_{klk}(X)$ 代入到多目标贝叶斯滤波器^[4]的预测和更新方程, 可得 δ -GLMB 的预测和更新步骤。

2 DUCM-FIMM- δ -GLMB 滤波器

交互多模型(interactive multiple model, IMM)算法在单目标跟踪领域一直被认为是解决机动目标跟踪的有效手段, 它采用多个运动模型来描述目标的运动状态, 再通过加权融合估计, 很好地克服了单模型估计误差较大的问题。在基于 RFS 的 MTT 领域, 文献[17]最早使用 IMM 思想提出了一种新的多模型 PHD 滤波器; 文献[14]采用马尔科夫分支合并策略与 δ -GLMB 算法结合, 提出了线性高斯的 IMM- δ -GLMB, 并证实了 IMM 在 RFS 领域同样具有优越性。本文在此基础上提出了用于非线性量测下机动多目标跟踪的 DUCM-FIMM- δ -GLMB 滤波器, 算法流程见图 1。首先进行输入混合, 通过混合每个航迹上一时刻所有模型滤波器的状态估计来获得与此航迹特定模型匹配的滤波器的初始条件; 然后对每个模型进行并行预测; 预测完成后, 利用预测信息对非线性量测进行去相关无偏量测转换和杂波滤除; 处理后的线性量测将用于并行滤波更新; 最后, 更新每个模型的概率, 一方面将其作为模糊控制器的输入, 用于改变运动模型的过程噪声系数, 另一方面用于对每个模型滤波器的输出进行加权混合, 得到最终的状态估计。




图 1 DUCM-FIMM- δ -GLMB 流程

Fig. 1 DUCM-FIMM- δ -GLMB flow

2.1 输入混合

在 JMS 中, 各模型之间的转移由马尔科夫概率转移矩阵 T_{PM} 确定, 其中元素 p_{ij} 为目标从模型 i 转移到模型 j 的概率

$$T_{PM} = \begin{bmatrix} p_{11} & \cdots & p_{1j} \\ \vdots & & \vdots \\ p_{i1} & \cdots & p_{ij} \end{bmatrix} \quad (6)$$

使用表征运动模型的离散变量对状态变量进行扩维, 则增广状态 $x = (\xi, \mu)$, 其中 ξ 为目标状态, $\mu \in \mathcal{M}$ 为模型索引, 那么状态概率密度函数为

$$p(\xi) = \int p(\xi, \mu) d\mu = \sum_{\mu \in \mathcal{M}} p(\mu) p(\xi | \mu) \quad (7)$$

输入航迹 l 在 k 时刻所有模型的条件概率密度 $p_{klk}^{\vartheta}(\xi, l | \mu_i)$, 其混合分布 $p_{klk}^{0, \vartheta}(\xi, \mu_j, l)$ 可由 IMM 混合分布原理得到

$$p_{klk}^{0, \vartheta}(\xi, \mu_j, l) = \sum_{i=1}^{|\mathcal{M}|} u_k^{ij} p_{klk}^{\vartheta}(\xi, l | \mu_i) \quad (8)$$

式中: $u_k^{ij} = p_{ij} p_k(\mu_i, l) / \bar{c}_k^{\mu_j}$, $\bar{c}_k^{\mu_j} = \sum_{i=1}^{|\mathcal{M}|} p_{ij} p_k(\mu_i, l)$, u_k^{ij} 为模型 i 到模型 j 的混合概率, $\bar{c}_k^{\mu_j}$ 为模型 j 的预测概率(归一化参数)。

在高斯过程中, $p_{klk}^{0, \vartheta}(\xi, \mu_j, l)$ 可由混合均值 m_{klk}^{0, μ_j} 和混合协方差 P_{klk}^{0, μ_j} 表示成单一高斯项:

$$p_{klk}^{0, \vartheta}(\xi, \mu_j, l) = w_{klk}^{0, \mu_j} \mathcal{N}(\xi; m_{klk}^{0, \mu_j}, P_{klk}^{0, \mu_j}) \quad (9)$$

$$w_{klk}^{0, \mu_j} = \sum_{i=1}^{|\mathcal{M}|} u_k^{ij} w_{klk}^{\mu_i} \quad (10)$$

$$m_{klk}^{0, \mu_j} = \sum_{i=1}^{|\mathcal{M}|} u_k^{ij} m_{klk}^{\mu_i} \quad (11)$$

$$P_{klk}^{0, \mu_j} = \sum_{i=1}^{|\mathcal{M}|} u_k^{ij} \times [P_{klk}^{\mu_i} + (m_{klk}^{0, \mu_j} - m_{klk}^{\mu_i})(m_{klk}^{0, \mu_j} - m_{klk}^{\mu_i})^T] \quad (12)$$

2.2 预测

将式(5)中的单目标概率分布用式(7)近似, 即 $p^{\vartheta}(x) \approx \sum_{\mu \in \mathcal{M}} p_k(\mu, l) p_{klk}^{0, \vartheta}(\xi, \mu, l)$, 得多模型 δ -GLMB 的先验混合概率密度 $\pi_{klk}(X)$, 然后进行预测步骤, 得到预测概率密度为

$$\pi_{k+1k}(X) = \Delta(X) \sum_{(I, \vartheta) \in \mathcal{J}(L_{k+1k}) \times \Xi} w_{k+1k}^{(I, \vartheta)} \delta_I(\mathcal{L}(X)) [p_{k+1k}^{(\vartheta)}]^X \quad (13)$$

式中:

$$\begin{cases} w_{k+1k}^{(I, \vartheta)} = w_{k+1k, S}^{(\vartheta)} (I \cap L_k) w_{k, b} (I \cap B_k) \\ w_{k+1k, S}^{(\vartheta)} = [\eta_S^{(\vartheta)}]^L \sum_{I \subseteq L_k} 1_I(L) [1 - \eta_S^{(\vartheta)}]^{I-L} w_{klk}^{(I, \vartheta)} \\ p_{k+1k}^{(\vartheta)}(x, l) = \sum_{j=1}^{|\mathcal{M}|} \bar{c}_k^{\mu_j} p_{k+1k}^{(0, \vartheta)}(\xi, \mu_j, l) \\ p_{k+1k}^{(0, \vartheta)}(\xi, \mu, l) = 1_{L_k}(l) p_{k+1k, S}^{(0, \vartheta)}(\xi, \mu, l) + 1_{B_k}(l) p_{k, b}^{(0, \vartheta)}(\xi, \mu, l) \\ p_{k+1k, S}^{(0, \vartheta)}(\xi, \mu, l) = \frac{\langle p_S(\cdot, \mu, l) \varphi(\xi | \cdot, \mu, l), p_{klk}^{(0, \vartheta)}(\cdot, \mu, l) \rangle}{\eta_S^{(\vartheta)}(l)} \\ \eta_S^{(\vartheta)}(l) = \sum_{\mu \in \mathcal{M}} \langle p_S(\cdot, \mu, l), p_{klk}^{(0, \vartheta)}(\cdot, \mu, l) \rangle \end{cases}$$

其中,预测标签空间 $\mathbf{L}_{k+1|k} = \mathbf{L}_k \cup \mathbf{B}_k$, $\mathbf{B}_k$ 为新生目标的标签空间。 $\langle f, g \rangle$ 为内积, $1_Y(X)$ 为广义指示函数,也称包含函数。 $w_{k+1|k}^{(l, \vartheta)}$ 为预测假设分量的权重,表示存活和新生分量权重的乘积。 $p_{k+1|k}^{(0, \vartheta)}(\xi, \mu, l)$ 表示运动模型为 μ 的单目标预测混合状态概率密度,由存活目标密度 $p_{k+1|k}^{(0, \vartheta)}(\xi, \mu, l)$ 和新生目标密度 $p_{k,b}(\xi, \mu, l)$ 组成,其高斯混合实现如下:

对于线性高斯模型,存活概率密度设为常数 p_S (ξ, μ, l) = p_S , 概率转移密度 $\phi(\xi_{k+1} | \xi_k, \mu, l) = (\xi_{k+1}; \mathbf{F}^\mu \xi_k, \mathbf{Q}_k^{(\mu, l)})$, 其中 $\mathbf{F}^\mu$ 为运动模型为 μ 的状态转移矩阵, $\mathbf{Q}_k^{(\mu, l)}$ 为相应的过程噪声协方差,由后续模糊算法得到。若单目标先验混合密度 $p_{k+1|k}^{(0, \vartheta)}(\xi, \mu, l)$ 和新生目标密度 $p_{k,b}(\xi, \mu, l)$ 均为高斯混合形式,那么预测密度 $p_{k+1|k}^{(0, \vartheta)}(\xi, \mu, l)$ 也为高斯形式,则有:

$$p_{k+1|k}^{(0, \vartheta)}(\xi, \mu, l) = w_{k+1|k}^{(0, \vartheta, \mu, l)} \mathcal{N}(\xi; \mathbf{m}_{k+1|k}^{(0, \vartheta, \mu, l)}, \mathbf{P}_{k+1|k}^{(0, \vartheta, \mu, l)}) + 1_{\mathbf{L}_k}(l) w_{k+1|k, S}^{(0, \vartheta, \mu, l)}(\xi; \mathbf{m}_{k+1|k, S}^{(0, \vartheta, \mu, l)}, \mathbf{P}_{k+1|k, S}^{(0, \vartheta, \mu, l)}) + 1_{\mathbf{B}_k}(l) w_{k,b}^{(\mu, l)} \mathcal{N}(\xi; \mathbf{m}_{k,b}^{(\mu, l)}, \mathbf{P}_{k,b}^{(\mu, l)}) \quad (14)$$

$$\eta_S^{(0, \vartheta)}(l) = p_S \quad (15)$$

式中:

$$w_{k+1|k, S}^{(0, \vartheta, \mu, l)} = p_S w_{k|k}^{(0, \vartheta, \mu, l)} \quad (16)$$

$$\mathbf{m}_{k+1|k, S}^{(0, \vartheta, \mu, l)} = \mathbf{F}^\mu \mathbf{m}_{k|k}^{(0, \vartheta, \mu, l)} \quad (17)$$

$$\mathbf{P}_{k+1|k, S}^{(0, \vartheta, \mu, l)} = \mathbf{F}^\mu \mathbf{P}_{k|k}^{(0, \vartheta, \mu, l)} (\mathbf{F}^\mu)^T + \mathbf{Q}_k^{(\mu, l)} \quad (18)$$

2.3 DUCM 量测转换

在滤波更新前,对量测信息进行预处理,可有效增加滤波精度。对于传感器捕获到的非线性量测信息,利用 DUCM 算法进行位置量测的无偏转换和量测转换误差的去相关。

$k+1$ 时刻的位置量测为 $\mathbf{z}_{k+1}^m = [\gamma_{k+1}^m, \beta_{k+1}^m]^T$, 传统量测转换 $\mathbf{z}_{k+1}^v$ 及其数学期望为:

$$\mathbf{z}_{k+1}^v = \begin{bmatrix} x_{k+1}^v \\ y_{k+1}^v \end{bmatrix} = \begin{bmatrix} \gamma_{k+1}^m \cos(\beta_{k+1}^m) \\ \gamma_{k+1}^m \sin(\beta_{k+1}^m) \end{bmatrix} \quad (19)$$

$$\mathbf{E}_{k+1}^v = \begin{bmatrix} E[x_{k+1}^v] \\ E[y_{k+1}^v] \end{bmatrix} = \begin{bmatrix} E[(\gamma_{k+1} + \tilde{\gamma}_{k+1}^m) \cos(\beta_{k+1} + \tilde{\beta}_{k+1}^m)] \\ E[(\gamma_{k+1} + \tilde{\gamma}_{k+1}^m) \sin(\beta_{k+1} + \tilde{\beta}_{k+1}^m)] \end{bmatrix} = \begin{bmatrix} \lambda_\beta \gamma_{k+1} \cos(\beta_{k+1}) \\ \lambda_\beta \gamma_{k+1} \sin(\beta_{k+1}) \end{bmatrix} \quad (20)$$

式中: $\gamma_{k+1}, \beta_{k+1}$ 为真实量测; $\lambda_\beta = e^{-\sigma_\beta^2/2}$ 为偏差因子^[18]。可知,当 $\lambda_\beta \neq 1$ 时, $\mathbf{z}_{k+1}^v$ 转换有偏。因此,可用 λ_β^{-1} 作为补偿因子进行乘性去偏,则从极坐标系到笛卡尔坐标系的无偏转换为

$$\mathbf{z}_{k+1}^c = \begin{bmatrix} x_{k+1}^c \\ y_{k+1}^c \end{bmatrix} = \begin{bmatrix} e^{\sigma_\beta^2/2} \gamma_{k+1}^m \cos(\beta_{k+1}^m) \\ e^{\sigma_\beta^2/2} \gamma_{k+1}^m \sin(\beta_{k+1}^m) \end{bmatrix} \quad (21)$$

无偏量测转换误差的均值为

$$\mathbf{E}_{k+1}^c = E[(\tilde{x}_{k+1}^c, \tilde{y}_{k+1}^c)^T] = \mathbf{0}_{2 \times 1} \quad (22)$$

传统量测转换算法基于量测值计算量测转换误差的协方差,这使得量测转换误差的协方差和量测噪声具有相关性,进而导致滤波估计偏差。为去除相关性,使用预测状态 $\mathbf{m}_{k+1|k}$ 和预测协方差 $\mathbf{P}_{k+1|k}$ 推导量测转换误差的协方差 $\mathbf{R}_{k+1}^c$

$$\mathbf{R}_{k+1}^c = \text{cov}\{(\tilde{x}_{k+1}^c, \tilde{y}_{k+1}^c)^T | \gamma_t, \beta_t\} = \begin{bmatrix} R_{k+1}^{xx} & R_{k+1}^{xy} \\ R_{k+1}^{yx} & R_{k+1}^{yy} \end{bmatrix} \quad (23)$$

其中:

$$\left\{ \begin{aligned} R_{k+1}^{xx} &= \frac{1}{2} [\gamma_t^2 + \sigma_\gamma^2 + \sigma_{\gamma_t}^2] e^{\sigma_\beta^2} [1 + \cos(2\beta_t) e^{-2\sigma_\beta^2} e^{-2\sigma_{\beta_t}^2}] - \frac{1}{2} [\gamma_t^2 + \sigma_{\gamma_t}^2] [1 + \cos(2\beta_t) e^{-2\sigma_{\beta_t}^2}] \\ R_{k+1}^{yy} &= \frac{1}{2} [\gamma_t^2 + \sigma_\gamma^2 + \sigma_{\gamma_t}^2] e^{\sigma_\beta^2} [1 - \cos(2\beta_t) e^{-2\sigma_\beta^2} e^{-2\sigma_{\beta_t}^2}] - \frac{1}{2} [\gamma_t^2 + \sigma_{\gamma_t}^2] [1 - \cos(2\beta_t) e^{-2\sigma_{\beta_t}^2}] \\ R_{k+1}^{xy} &= R_{k+1}^{yx} = \frac{1}{2} [\gamma_t^2 + \sigma_\gamma^2 + \sigma_{\gamma_t}^2] e^{\sigma_\beta^2} [\sin(2\beta_t) e^{-2\sigma_\beta^2} e^{-2\sigma_{\beta_t}^2}] - \frac{1}{2} [\gamma_t^2 + \sigma_{\gamma_t}^2] [\sin(2\beta_t) e^{-2\sigma_{\beta_t}^2}] \\ \sigma_{\gamma_t}^2 &= (P_{xx} \gamma_t^2 - 2P_{xy} \gamma_t x_t + P_{yy} x_t^2) / (x_t^2 + y_t^2) \\ \sigma_{\beta_t}^2 &= (P_{xx} \gamma_t^2 - 2P_{xy} x_t y_t + P_{yy} x_t^2) / (x_t^2 + y_t^2)^2 \end{aligned} \right.$$

式中: γ_t, β_t 为距离和角度的预测值; x_t, y_t 为笛卡尔坐标系目标预测位置,可由 $\mathbf{m}_{k+1|k}$ 提取得到; $\sigma_{\gamma_t}^2, \sigma_{\beta_t}^2$ 为距离和角度的预测误差方差,可由 $\mathbf{P}_{k+1|k}$ 经计算得到。由 $p_{k+1|k}^{(0, \vartheta)}(\xi, \mu, l)$ 可计算相应航迹转换后的量测噪声协方差 $\mathbf{R}_{k+1}^c$ 。

2.4 联合波门杂波滤除

转换后的量测需进行杂波滤除,多模型的滤波过程采用多个并行滤波器^[19],这导致多模型 δ -GLMB 中目标假设航迹的数量大幅度增加,通过设置门限过滤杂波已经不能有效地减少无效航迹的数量。为此本文提出了一种适用于机动多目标跟踪的联合波门杂波滤除策略,如下:

预测航迹与量测的关联新息 $d^{[20]}$ 为

$$d(\mathbf{x}_{k+1|k}^{\mu, l}, \mathbf{z}_{k+1}^{c, z_i}) =$$

$$(\mathbf{z}_{k+1}^{c, z_i} - \mathbf{H} \mathbf{x}_{k+1|k}^{\mu, l})^T (\mathbf{W}_{k+1}^{\mu, l})^{-1} (\mathbf{z}_{k+1}^{c, z_i} - \mathbf{H} \mathbf{x}_{k+1|k}^{\mu, l}) \quad (24)$$

式中: $\mathbf{H}$ 为线性观测矩阵, $\mathbf{W}_{k+1}^{\mu, l}$ 为新息协方差。

$$\mathbf{W}_{k+1}^{\mu, l} = \mathbf{H} \mathbf{F}^\mu \mathbf{P}_{k|k}^{\mu, l} (\mathbf{H} \mathbf{F}^\mu)^T + \mathbf{H} \mathbf{Q}_k^{\mu, l} \mathbf{H}^T + \mathbf{R}_{k+1}^{c, \mu, l} \quad (25)$$

预设关联门限,则预测航迹周围的量测 $\hat{Z}_{k+1}^{c, l, 1}$ 可由下式提取

$$\hat{Z}_{k+1}^{c, l, 1} = \{z | d(\mathbf{x}_{k+1|k}^{\mu, l}, \mathbf{z}_{k+1}^{c, z_i}) < \varepsilon, \mathbf{z}_{k+1}^{c, z_i} \in \mathbf{Z}_{k+1}^c\} \quad (26)$$

门限 ε 的选择可依据逆卡方分布确定, 门限之外的量测被认为是杂波, 不予考虑。然而在高杂波场景下, 目标量测附近也密布杂波, 且多模型的场景会有更多假设航迹, 门限过滤的方法效果大打折扣。为进一步降低量测关联的复杂度, 减少门限内的杂波量测对状态更新的影响, 本文利用 k 时刻的目标后验信息对杂波进行二次处理:

θ 为航迹标签到量测索引的映射函数, 则 $\theta_k(l)$ 为航迹 l 在 k 时刻的关联量测索引, μ 为模型索引, $\hat{Z}_k^c$ 为 k 时刻的关联量测集合, 那么预测航迹在 k 时刻的关联量测为

$$\mathbf{z}_k^{c,\mu,l} = \hat{Z}_k^c(\theta_k(l), \mu) \quad (27)$$

航迹 l 符合机动约束的量测可由下式提取:

$$\hat{Z}_{k+1}^{c,l,2} = \{ \mathbf{z} | d(\mathbf{z}_k^{c,\mu,l}, \mathbf{z}_{k+1}^{c,z_i}) < T_{k+1}^{\mu,l}, \mathbf{z}_{k+1}^{c,z_i} \in Z_{k+1}^c \} \quad (28)$$

其中:

$$d(\mathbf{z}_k^{c,\mu,l}, \mathbf{z}_{k+1}^{c,z_i}) = (\mathbf{z}_k^{c,\mu,l} - \mathbf{z}_{k+1}^{c,z_i})^T (\mathbf{R}_{k+1}^{c,\mu,l})^{-1} (\mathbf{z}_k^{c,\mu,l} - \mathbf{z}_{k+1}^{c,z_i}) \quad (29)$$

$$T_{k+1}^{\mu,l} = \eta \left(\sqrt{(\dot{x}_{k+1|k}^{\mu,l})^2 + (\dot{y}_{k+1|k}^{\mu,l})^2} + 2 \sqrt{R_{k+1}^{\mu,xx} + R_{k+1}^{\mu,yy}} \right) \quad (30)$$

$$\left\{ \begin{aligned} w_{k+1|k+1}^{(I,\vartheta,\theta)}(Z_{k+1}) &= \frac{\delta_{\theta^{-1}(\{0;|Z_{k+1}| \})}(I) [\eta_{Z_{k+1}}^{(\vartheta,\theta)}]^T w_{k+1|k}^{(I,\vartheta)}(Z_{k+1})}{\sum_{(I,\vartheta) \in \mathcal{I}(L_{k+1|k+1}) \times \Xi \theta \in \Theta(I)} \sum_{\delta_{\theta^{-1}(\{0;|Z_{k+1}| \})}(I) [\eta_{Z_{k+1}}^{(\vartheta,\theta)}]^T w_{k+1|k}^{(I,\vartheta)}(Z_{k+1})} \\ \eta_{Z_{k+1}}^{(\vartheta,\theta)}(l) &= \sum_{\mu \in \mathcal{M}} \langle p_{k+1|k}^{(0,\vartheta)}(\cdot, \mu, l), \varphi_{Z_{k+1}}(\cdot, \mu, l; \theta) \rangle \\ p_{k+1|k+1}^{(\vartheta,\theta)}(x, l | Z_{k+1}) &= \sum_{\mu \in \mathcal{M}} p_{k+1}(\mu, l) p_{k+1|k+1}^{(\vartheta,\theta)}(\xi, \mu, l | Z_{k+1}) \\ p_{k+1|k+1}^{(\vartheta,\theta)}(\xi, \mu, l | Z_{k+1}) &= \frac{p_{k+1|k}^{(0,\vartheta)}(\xi, \mu, l) \varphi_{Z_{k+1}}(\xi, \mu, l; \theta)}{\eta_{Z_{k+1}}^{(\vartheta,\theta)}(l)} \\ \varphi_{Z_{k+1}}(\xi, \mu, l; \theta) &= \begin{cases} \frac{p_D(\xi, \mu, l) g(z_{\theta(l)}^c | \xi, \mu, l)}{\kappa(z_{\theta(l)}^c)} & \theta(l) > 0 \\ 1 - p_D(\xi, \mu, l) & \theta(l) = 0 \end{cases} \end{aligned} \right.$$

式中: Θ 是 $k+1$ 时刻的关联映射空间, 代表所有映射关系 θ 的集合, $\Theta(I)$ 为关联映射的子集。 $p_D(\xi, \mu, l)$ 是检测概率; $\varphi_{Z_{k+1}}(\xi, \mu, l; \theta)$ 是伪量测似然函数, 包含检测 ($\theta(l) > 0$) 和漏检 ($\theta(l) = 0$) 两部分。 $w_{k+1|k+1}^{(I,\vartheta,\theta)}(Z_{k+1})$ 为后验假设分量的权重, $p_{k+1|k+1}^{(\vartheta,\theta)}(\xi, \mu, l | Z_{k+1})$ 是模型为 μ 的单目标后验概率密度, 可由卡尔曼单目标更新得到, 其高斯混合实现如下:

对于线性高斯模型, 检测概率设为常数 $p_D(\xi, \mu, l) = p_D$, 单目标量测似然函数 $g(\mathbf{z} | \xi, \mu, l) = \mathcal{N}(\mathbf{z}; \mathbf{H}\xi, \mathbf{R}^{\mu,l})$, 若单目标预测密度 $p_{k+1|k}^{(0,\vartheta)}(\xi, \mu, l)$ 符合如式 (14) 的高斯混合形式, 则 $p_{k+1|k+1}^{(\vartheta,\theta)}(\xi, \mu, l | Z_{k+1})$ 也为高斯形式

$$p_{k+1|k+1}^{(\vartheta,\theta)}(\xi, \mu, l | Z_{k+1}) = w_{k+1|k+1}^{(\vartheta,\theta,\mu,l)} \mathcal{N}(\xi; \mathbf{m}_{k+1|k+1}^{(\vartheta,\theta,\mu,l)}, \mathbf{P}_{k+1|k+1}^{(\vartheta,\theta,\mu,l)}) \quad (33)$$

门限 $T_{k+1}^{\mu,l}$ 由目标的预测速度和量测噪声决定, $\eta = (1 + \kappa(Z_{k+1}^c))$ 为调整因子, $\kappa(Z)$ 为杂波密度函数, 在观测空间中服从均匀分布, 每一帧量测产生的杂波数量服从期望为 λ 的泊松分布, 可知 η 随着杂波的数量增加而增大。

综合式 (26)、(28) 得 $k+1$ 时刻关联量测为

$$\hat{Z}_{k+1}^c = \bigcup_{l \in L} (\hat{Z}_{k+1}^{c,l,1} \cap \hat{Z}_{k+1}^{c,l,2}) \quad (31)$$

由于新生、漏检的目标在上一时刻无关联量测, 所以新生航迹及漏检航迹仅使用式 (26) 椭圆波门保留关联量测, 存活假设航迹使用式 (31) 联合波门保留关联量测。

2.5 更新

假设经过量测转换和杂波滤除得到的线性量测集合为 Z_{k+1} , 则更新后的多目标后验密度

$$\pi_{k+1|k+1}(X | Z_{k+1}) = \Delta(X) \sum_{(I,\vartheta) \in \mathcal{I}(L_{k+1|k+1}) \times \Xi \theta \in \Theta(I)} \sum_{w_{k+1|k+1}^{(I,\vartheta,\theta)}(Z_{k+1}) \delta_I(\mathcal{L}(X)) [p_{k+1|k+1}^{(\vartheta,\theta)}(\cdot | Z_{k+1})]^X \quad (32)$$

其中:

若目标未被检测到, 即 $\theta(l) = 0$, 式中:

$$\left\{ \begin{aligned} w_{k+1|k+1}^{(\vartheta,\theta,\mu,l)} &= (1 - p_D) w_{k+1|k}^{(0,\vartheta,\mu,l)} \\ \mathbf{m}_{k+1|k+1}^{(\vartheta,\theta,\mu,l)} &= \mathbf{m}_{k+1|k}^{(0,\vartheta,\mu,l)} \\ \mathbf{P}_{k+1|k+1}^{(\vartheta,\theta,\mu,l)} &= \mathbf{P}_{k+1|k}^{(0,\vartheta,\mu,l)} \end{aligned} \right.$$

若目标被检测到, 即 $\theta(l) > 0$, 式中:

$$\left\{ \begin{aligned} w_{k+1|k+1}^{(\vartheta,\theta,\mu,l)} &= w_{k+1|k}^{(0,\vartheta,\mu,l)} p_D q_{k+1}^{(\vartheta)}(\mathbf{z}_{\theta(l)}^c; \mu, l) / \kappa(\mathbf{z}_{\theta(l)}^c) \\ \mathbf{m}_{k+1|k+1}^{(\vartheta,\theta,\mu,l)} &= \mathbf{m}_{k+1|k}^{(0,\vartheta,\mu,l)} + \mathbf{G}_{k+1}^{(0,\vartheta,\mu,l)} (\mathbf{z}_{\theta(l)}^c - \mathbf{H} \mathbf{m}_{k+1|k}^{(0,\vartheta,\mu,l)}) \\ \mathbf{P}_{k+1|k+1}^{(\vartheta,\theta,\mu,l)} &= (\mathbf{I} - \mathbf{G}_{k+1}^{(0,\vartheta,\mu,l)} \mathbf{H}) \mathbf{P}_{k+1|k}^{(0,\vartheta,\mu,l)} \\ q_{k+1}^{(\vartheta)}(\mathbf{z}^c; \mu, l) &= \mathcal{N}(\mathbf{z}^c; \mathbf{H} \mathbf{m}_{k+1|k}^{(0,\vartheta,\mu,l)}, \mathbf{H} \mathbf{P}_{k+1|k}^{(0,\vartheta,\mu,l)} \mathbf{H}^T + \mathbf{R}_{k+1}^{c,\mu,l}) \\ \mathbf{G}_{k+1}^{(0,\vartheta,\mu,l)} &= \mathbf{P}_{k+1|k}^{(0,\vartheta,\mu,l)} \mathbf{H}^T (\mathbf{H} \mathbf{P}_{k+1|k}^{(0,\vartheta,\mu,l)} \mathbf{H}^T + \mathbf{R}_{k+1}^{c,\mu,l})^{-1} \end{aligned} \right.$$

模型概率 $p_{k+1}(\mu_j, l)$ 更新为

$$p_{k+1}(\mu_j, l) = \begin{cases} \bar{c}_k^{\mu_j} \langle p_{k+1|k}^{(0, \theta)}(\cdot, \mu_j, l), \varphi_{Z_{k+1}}(\cdot, \mu_j, l; \theta) \rangle / c_{k+1} & \theta(l) > 0 \\ \bar{c}_k^{\mu_j} / c_{k+1} & \theta(l) = 0 \end{cases}$$

(34)

式中 $c_{k+1} = \sum_{j=1}^{|M|} p_{k+1}(\mu_j, l)$ 为归一化参数。

量测更新后,可用 $k+1$ 时刻的模型概率对每个滤波器的估计结果加权合并,输出混合,得到单目标航迹的后验估计 $p_{k+1|k+1}^{(\vartheta, \theta)}(\mathbf{x}, l | Z_{k+1})$ 。同时,将模型概率输入到模糊控制器,执行模糊算法。

2.6 模糊算法

在目标跟踪中,算法的跟踪效果很大程度上依赖于运动模型的匹配程度,所建立的运动模型越符合目标真实运动轨迹,跟踪精度越高。但是,现实中的目标往往有一定的机动性,其轨迹是多模型的、易变的,因此无法建立与之完全匹配的运动模型。过程噪声一方面刻画了运动模型的不匹配程度,另一方面也为滤波过程提供了更大的缓冲空间。在滤波过程中,实时的调整过程噪声的大小可以有效增加滤波精度。文献[21]在单目标跟踪中引入模糊算法,将 Kalman 滤波器的新息及新息变化率的归一化值作为模糊系统的输入变量,来确定过程噪声的协方差,但其需要大量的先验信息,且需频繁调整归一化参数,不适用于多目标跟踪。本文在多目标跟踪中引入模糊算法,以每个航迹的模型概率为输入,相应的过程噪声协方差系数为输出,不需要归一化输入参数,且可自适应调整运动模型中的过程噪声,具体如下:

模糊系统的输入变量 I_1 、 I_2 、 I_3 分别为 $k+1$ 时刻航迹 l 的模型概率 $p_{k+1}(\mu_1, l)$ 、 $p_{k+1}(\mu_2, l)$ 、 $p_{k+1}(\mu_3, l)$,输出变量 U 为过程噪声协方差系数。

- 1)输入变量、输出变量的论域
- $$\begin{cases} I_1, I_2, I_3: [0, 1] \\ U: [0, 2] \end{cases}$$
- 2)输入变量、输出变量的模糊子集
- $$\begin{cases} I_1, I_2, I_3: \{ \text{小}(P_S), \text{中}(P_M), \text{大}(P_B) \} \\ U: \{ \text{极小}(F_Z), \text{小}(F_S), \text{中}(F_M), \text{大}(F_B), \text{极大}(F_L) \} \end{cases}$$
- 3)隶属度函数
- 4)模糊规则的建立

文献[21]分析了单目标跟踪中,过程噪声的大小和跟踪精度的关系。当运动模型与真实目标轨迹匹配时,过程噪声越小跟踪精度越高;当运动模型与真实目标轨迹不匹配时,过程噪声越大跟踪精度越高。基于此推出模糊规律:当模型概率的分离度高

时,减小过程噪声;当模型概率较为平均时,增大过程噪声。相应的模糊规则见表 1。




图 2 I_1 、 I_2 、 I_3 输入隶属度函数
Fig. 2 I_1 、 I_2 、 I_3 input membership function




图 3 输出隶属度函数
Fig. 3 Output membership function

表 1 模糊规则表

Tab. 1 Fuzzy rules table				
规则号	I_1	I_2	I_3	U
1	P_S	P_S	P_B	F_Z
2	P_S	P_S	P_M	F_M
3	P_S	P_M	P_S	F_M
4	P_S	P_M	P_M	F_B
5	P_S	P_M	P_B	F_S
6	P_S	P_B	P_S	F_Z
7	P_S	P_B	P_M	F_S
8	P_M	P_S	P_S	F_M
9	P_M	P_S	P_M	F_B
10	P_M	P_S	P_B	F_S
11	P_M	P_M	P_S	F_B
12	P_M	P_M	P_M	F_L
13	P_M	P_B	P_S	F_S
14	P_B	P_S	P_S	F_Z
15	P_B	P_S	P_M	F_S
16	P_B	P_M	P_S	F_S

使用重心法解模糊化,输出航迹 l 过程噪声协方差的系数 $U(l)$,由此可得 $k+1$ 时刻的过程噪声协方差 $\mathbf{Q}_{k+1}^{\mu,l} = U(l)\mathbf{Q}_0^{\mu}$,可用于目标的预测和杂波滤除,来增加跟踪精度。

3 仿真分析

为了评估所提算法的性能,本文在 $[0,10\ 000] \times [0,10\ 000]$ m 的非线性观测区域中,将所提非线性量测转换算法和 EKF、UKF、CKF 中精度最高、计算量最小的 CKF 比较。设置 2 个仿真场景:场景一在固定杂波率的情况下,比较了 DUCM-FIMM- δ -GLMB 滤波器与 CKF- δ -GLMB^[7]、CKF-JMS- δ -GLMB^[13] 及 CKF-IMM- δ -GLMB^[14] 滤波器的性能;场景二根据杂波率的变化情况评估 DUCM-FIMM- δ -GLMB 滤波器的鲁棒性。

在这 2 种场景下,每个目标都可以在 3 种不同的运动模型下随机改变机动。模型一是匀速直线(CV)模型,过程噪声标准差 $\sigma_{\text{CV}} = 5$ m/s;模型二是协同转弯(CT)模型,向左转动 $10(^{\circ})/\text{s}$,过程噪声标准差 $\sigma_{\text{CT}} = 5$ m/s;模型三是协同转弯(CT)模型,向右转动 $10(^{\circ})/\text{s}$,过程噪声标准差 $\sigma_{\text{CT}} = 5$ m/s。

CV、CT 模型的状态转移矩阵,过程噪声初始协方差矩阵如下式:

$$\mathbf{F}^{\text{CV}} = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (35)$$

$$\mathbf{F}^{\text{CT}} = \begin{bmatrix} 1 & (\sin(\theta T))/\theta & 0 & -(1 - \cos(\theta T))/\theta \\ 0 & \cos(\theta T) & 0 & -\sin(\theta T) \\ 0 & (1 - \cos(\theta T))/\theta & 1 & (\sin(\theta T))/\theta T \\ 0 & \sin(\theta T) & 0 & \cos(\theta T) \end{bmatrix} \quad (36)$$

$$\mathbf{Q}_0^{\text{CV}} = \sigma_{\text{CV}}^2 \begin{bmatrix} T^4/4 & T^3/2 & 0 & 0 \\ T^3/2 & T^2 & 0 & 0 \\ 0 & 0 & T^4/4 & T^3/2 \\ 0 & 0 & T^3/2 & T^2 \end{bmatrix} \quad (37)$$

$$\mathbf{Q}_0^{\text{CT}} = \sigma_{\text{CT}}^2 \begin{bmatrix} T^4/4 & T^3/2 & 0 & 0 \\ T^3/2 & T^2 & 0 & 0 \\ 0 & 0 & T^4/4 & T^3/2 \\ 0 & 0 & T^3/2 & T^2 \end{bmatrix} \quad (38)$$

每个场景都有 5 个机动目标,为了使目标的机动轨迹显示得更加直观,这里采用笛卡尔坐标系表示,其初始位置、出生时刻、消亡时刻及机动情况见表 2。目标的真实运动轨迹和传感器位置见图 4。




图 4 目标真实运动航迹

Fig. 4 Real track of target

表 2 目标初始状态表

Tab. 2 Initial states of targets

目标	初始位置/m	出生时刻/s	消亡时刻/s	机动/s
1	[1 000;7 500]	1	100	31~42 左转
				66~77 右转
				其余匀速
2	[1 000;2 500]	1	100	31~42 右转
				66~77 左转
				其余匀速
3	[8 000;8 000]	10	100	21~35 右转
				41~70 左转
				其余匀速
4	[7 000;5 000]	10	80	31~42 右转
				49~80 左转
				86~95 右转
5	[3 000;8 500]	20	100	其余匀速

目标出生时的初始模型分布概率 $p(\mu) = [0.4, 0.3, 0.3]$,运动模型之间的切换由马尔科夫状态概率转移矩阵 $\mathbf{T}_{\text{PM}}$ 给出

$$\mathbf{T}_{\text{PM}} = \begin{bmatrix} 0.8 & 0.1 & 0.1 \\ 0.1 & 0.8 & 0.1 \\ 0.1 & 0.1 & 0.8 \end{bmatrix}$$

此外,采样周期 $T = 1$ s,方位角量测噪声 $\sigma_{\gamma} = 0.1^{\circ}$,径向距离量测噪声 $\sigma_{\beta} = 10$ m,目标存活概率 $P_s = 0.99$,目标检测概率 $P_d = 0.98$,每次扫描中的杂波均匀分布在探测区域,数量服从期望为 λ 的泊松分布。最优子模型分配(optimal sub-pattern assignment,OSPA)的参数设定 $c = 100, p = 1$ 。

1) 场景一。本场景为了评估 DUCM-FIMM- δ -GLMB 滤波器在杂波环境下对机动目标的跟踪性能。设置杂波率 $\lambda = 30$, CKF-JMS- δ -GLMB、CKF-IMM- δ -GLMB、DUCM-FIMM- δ -GLMB 滤波器参数与上文所述完全一致, CKF- δ -GLMB 滤波器始终认为目标符合 CV 模型,过程噪声标准差 $\sigma = 30 \text{ m/s}^{[12]}$ 。对权重大于 10^{-2} 的 GLMB 分量所对应的假设航迹引入模糊算法。每个算法执行 100 次蒙特卡洛实验,具体结果见图 5。




图5 目标1的模型概率及过程噪声系数

Fig. 5 Model probability and process noise of object 1

图5直观展示了模糊算法的作用,可以看出所提算法能实现对目标运动模型的实时估计,并由此自适应改变其过程噪声的大小。目标1在1~30 s、43~65 s、78~100 s 做匀速直线运动,31~42 s 左转,66~77 s 右转,均能估计准确。当目标的运动模型保持稳定时,模型概率的分离度高,相应时刻的过程噪声系数变小;当目标转换运动模型时,模型概率的分离度低,相应时刻的过程噪声系数变大。

图6、图7为4种滤波器的目标数量估计和 OSPA 误差随时间的变化曲线,由图所示 CKF- δ -GLMB、CKF-JMS- δ -GLMB、CKF-IMM- δ -GLMB 都有一定程度的漏警,而 DUCM-FIMM- δ -GLMB 在目标数目估计中表现优异。另外,模糊算法的引入使得 DUCM-FIMM- δ -GLMB 在跟踪机动目标时可以根据运动模型概率的分离度而调整过程噪声的大小,增加了多模型滤波的包容性,因此 DUCM-FIMM- δ -GLMB 的跟踪精度最高,CKF-JMS- δ -GLMB、CKF-IMM- δ -GLMB 的效果次之,CKF- δ -GLMB 跟踪误差最大。由于 δ -GLMB 系列滤波器均采用多帧量测信息计算假设航迹,所以在检测目标的新生和消亡时,4种滤波器都有一定的滞后性,但 DUCM-FIMM- δ -GLMB 的表现更好。




图6 不同滤波器目标数量估计对比

Fig. 6 Comparison of potential estimation for different filters




图7 不同滤波器 OSPA 误差对比

Fig. 7 Comparison of OSPA error for different filters

在量测处理方面,CKF- δ -GLMB、CKF-JMS- δ -GLMB、CKF-IMM- δ -GLMB 滤波器均使用了式(26)过滤杂波,DUCM-FIMM- δ -GLMB 滤波器采用了本文所提 DUCM 和联合波门过滤杂波算法,图8、图9、表3为4种滤波器每帧的平均关联量测个数和计算时间。上述3种多模型算法均使用多个并行的滤波器,计算复杂度要高于采用单模型的CKF- δ -GLMB。另外,JMS算法在混合和更新阶段使用了分支真实密度,相比于IMM的合并分支密度,计算量更大,所以即使CKF-JMS- δ -GLMB相较于CKF-IMM- δ -GLMB关联量测数量更小,计算时间却更大。DUCM-FIMM- δ -GLMB一方面使用DUCM的方式,避免了UKF、CKF等算法采用多个离散采样点来近似随机变量的统计特性而造成的计算复杂度增加的问题,降低了计算量;另一方面,加入机动约束的联合波门杂波过滤算法显著降低了关联量测的个数,使得计算时间大幅度减少,相较于CKF-JMS- δ -GLMB下降了82.8%,相较于CKF-IMM- δ -GLMB降低了74.1%。




图 8 不同滤波器关联量测数量对比

Fig. 8 Comparison of correlation measurements number for different filters




图 9 不同滤波计算时间对比

Fig. 9 Comparison of running time for different filters

表 3 量测和时间对比

Tab. 3 Comparison of measurements and time

滤波器	每帧平均 量测个数	每帧平均计算 时间/s
CKF-δ-GLMB	10.55	0.51
CKF-JMS-δ-GLMB	17.32	5.25
CKF-IMM-δ-GLMB	27.42	3.47
DUCM-FIMM-δ-GLMB	7.56	0.90

2) 场景二。本场景主要为了评估所提 DUCM-FIMM-δ-GLMB 滤波器在不同杂波环境下的鲁棒性, 设置杂波率 $\lambda = 1, 20, 30, 60, 100$, 其他参数与场景一保持一致。每个杂波场景进行 100 次蒙特卡洛实验, 评估了目标数量估计、OSPA 误差、关联量测个数和计算时间等多项指标, 具体结果见图 10、11。

由图 10、11 所示, DUCM-FIMM-δ-GLMB 滤波器在不同杂波环境下具有较好的鲁棒性。随着杂波率的上升, 所提算法目标数量估计和 OSPA 误差变化

并不明显, 即使在杂波率 $\lambda = 100$, 即远超常规情况的高杂波场景下^[12], 仍然可以实现准确的跟踪。可惜在目标数量变化时, 虚警量测的增加会导致滤波器检测新生目标的时间更久。




图 10 不同杂波率目标数量估计对比

Fig. 10 Comparison of potential estimation for different clutter rates




图 11 不同杂波率 OSPA 误差对比

Fig. 11 Comparison of OSPA error for different clutter rates

表 4 不同杂波率参数对比

Tab. 4 Comparison of different clutter rates

杂波率	每帧平均 量测个数	每帧平均计算 时间/s
$\lambda = 1$	4.44	0.56
$\lambda = 20$	6.50	0.76
$\lambda = 30$	7.56	0.90
$\lambda = 60$	10.69	0.94
$\lambda = 100$	14.32	1.17

由表 4 可知, 关联量测个数和计算时间成正比, 杂波率的提高会使滤波器的关联量测个数和计算时间都有所增加。然而得益于所提联合波门杂波滤除

算法,相较于杂波率的增加速度,关联量测个数和计算时间的增加都是更加平缓的。

4 结 论

本文首先在标准 δ -GLMB 滤波器的基础上推导了 IMM- δ -GLMB 的预测和更新方程;其次,采用 DUCM 量测转换和联合波门杂波滤除策略,解决了多模型滤波器在非线性质量测的杂波环境下计算速度下降和跟踪精度下降的问题;最后,将模糊算法引入到 MTT 领域,提出了 DUCM-FIMM- δ -GLMB 滤波器,自适应改变运动模型的过程噪声,进一步降低了 OSPA 误差,提高了目标跟踪的精度。

仿真结果表明,DUCM-FIMM- δ -GLMB 滤波器在非线性质量测的机动多目标跟踪场景下,跟踪精度比 CKF- δ -GLMB、CKF-JMS- δ -GLMB、CKF-IMM- δ -GLMB 滤波器更高,计算时间比 CKF-JMS- δ -GLMB 下降 82.8%,比 CKF-IMM- δ -GLMB 下降 74.1%。另外,所提滤波器对环境杂波的变化具有较好的鲁棒性,无论在低杂波场景还是高杂波场景,滤波器的跟踪精度与目标数量估计都比较稳定。

参考文献

- [1] GARCIA-FERNANDEZ A F, MORELANDE M R, GRAJAL J. Bayesian sequential track formation [J]. IEEE Transactions on Signal Processing, 2014, 62 (24): 6366. DOI: 10.1109/TSP.2014.2364013
- [2] RONALD P, MAHLER S. Statistical multisource-multitarget information fusion[M]. Norwood: Artech House, 2013: 1
- [3] FORTMANN T E, BAR-SHALOM Y, SCHEFFE M. Sonar tracking of multiple targets using joint probabilistic data association [J]. IEEE Journal Oceanic Engineering, 1983, 8 (3): 173. DOI: 10.1109/JOE.1983.1145560
- [4] RONALD P, MAHLER S. Multitarget filtering via first-order multitarget moments [J]. IEEE Transactions Aerospace and Electronic Systems, 2003, 39 (4): 1175. DOI: 10.1109/TAES.2003.1261119
- [5] RONALD P, MAHLER S. PHD filters of higher order in target number[J]. IEEE Transactions Aerospace and Electronic Systems, 2007, 43 (3): 1523. DOI: 10.1109/TAES.2007.4441756
- [6] VO B T, VO B N, CANTONI A. The cardinality balanced multi-target multi-Bernoulli filter and its implementations [J]. IEEE Transactions on Signal Processing, 2009, 57 (2): 409. DOI: 10.1109/TSP.2008.2007924
- [7] VO B T, VO B N, PHUNG D. Labeled random finite sets and the Bayes multi-target tracking filter[J]. IEEE Transactions on Signal Processing, 2014, 62 (24): 6554. DOI: 10.1109/TSP.2014.2364014
- [8] JETTO L, LONGHI S, VENTURINI G. Development and experimental validation of an adaptive extended Kalman filter for the localization of mobile robots[J]. IEEE Transactions on Robotics and Automation, 1999, 15 (2): 219. DOI: 10.1109/70.760343
- [9] JULIER S, UHLMANN J K. Unscented filtering and nonlinear

- estimation[J]. Proceedings of IEEE, 2004, 92 (3): 401. DOI: 10.1109/JPROC.2003.823141
- [10] ARASARATNAM I, HAYKIN S. Cubature Kalman filters [J]. IEEE Transactions on Automatic Control, 2009, 54 (6): 1254. DOI: 10.1109/TAC.2009.2019800
- [11] LERRO D, BAR-SHALOM Y. Tracking with debiased consistent converted measurements versus EKF [J]. IEEE Transactions on Aerospace & Electronic Systems, 1993, 29 (3): 1015. DOI: 10.1109/7.220948
- [12] WEI Yi, MENG Jiang, HOSEINNEZHAD R. The multiple model Vo-Vo filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2017, 53 (2): 1045. DOI: 10.1109/TAES.2017.2667300
- [13] PUNCHIHEWA Y, VO B T, VO B N. A generalized labeled multi-Bernoulli filter for maneuvering targets [C]//19th International Conference on Information Fusion. Heidelberg: IEEE, 2016: 980
- [14] 辛怀声, 宋鹏汉, 曹晨. 多模型广义标签多伯努利滤波器[J]. 系统工程与电子技术, 2022, 44 (12): 3603
XIN Huaisheng, SONG Penghan, CAO Chen. Multiple model based generalized labeled multi-Bernoulli filter [J]. Systems Engineering and Electronics, 2022, 44 (12): 3603. DOI: 10.12305/j.issn.1001-506X.2022.12.03
- [15] BORDONARO S, WILLETT P, BAR-SHALOM Y. Decorrelated unbiased converted measurement Kalman filter [J]. IEEE Transactions on Aerospace & Electronic Systems, 2014, 50 (2): 1431. DOI: 10.1109/TAES.2014.120563
- [16] 国强, 贺紫兰. 一种新的模糊控制多模型算法在目标跟踪中的应用[J]. 哈尔滨工业大学学报, 2016, 48 (11): 123
GUO Qiang, HE Zilan. Application of a new fuzzy control multi model algorithm in target tracking[J]. Journal of Harbin Institute of Technology, 2016, 48 (11): 123. DOI: 10.11918/j.issn.0367-6234.2016.11.019
- [17] 王晓, 韩崇昭. 用于机动目标跟踪的多模型概率假设密度滤波器[J]. 西安交通大学学报, 2011, 45 (12): 1
WANG Xiao, HAN Chongzhao. A probability hypothesis density filter with multiple models for maneuvering target tracking [J]. Journal of Xi'an JiaoTong University, 2011, 45 (12): 1
- [18] 彭瀚, 程婷. 基于预测信息的量测转换序贯滤波目标跟踪[J]. 系统工程与电子技术, 2019, 41 (3): 549
PENG Han, CHENG Ting. Measurement conversion sequential filtering target tracking based on prediction information[J]. System Engineering and Electronic Technology, 2019, 41 (3): 549. DOI: 10.3969/j.issn.1001-506X.2019.03.13
- [19] WAN Jian, REN Peiwen, GUO Qiang. Application of interactive multiple model adaptive five-degree cubature Kalman algorithm based on fuzzy logic in target tracking[J]. Symmetry, 2019, 11 (6): 767. DOI: 10.3390/SYM11060767
- [20] 辛怀声, 曹晨. 基于交互多模型的分组 δ -广义标签多伯努利算法[J]. 系统工程与电子技术, 2022, 44 (4): 1128
XIN Huaisheng, CAO Chen. Interacting multiple model based grouping δ -generalized labeled multi-Bernoulli algorithm [J]. Systems Engineering and Electronics, 2022, 44 (4): 1128. DOI: 10.12305/j.issn.1001-506X.2202.04.08
- [21] DING Z, LEUNG H, CHAN K, et al. Model-set adaptation using a fuzzy Kalman filter[J]. Mathematical and Computer Modelling: An International Journal, 2001, 34 (7): 799. DOI: 10.1016/S0895-7177(01)00100-5