



不完全建模下具有未知机动的任意形状集群目标自适应跟踪

杨衍波^{1,2*}, 丁皓莹^{1,2}, 刘准钊^{1,2}, 丁润泽^{1,2}

1. 西北工业大学自动化学院, 西安 710129

2. 信息融合技术教育部重点实验室, 西安 710129

* E-mail: yangyanbo@nwpu.edu.cn

收稿日期: 2025-07-31; 接受日期: 2025-11-10; 网络版发表日期: 2026-02-03

国家自然科学基金(批准号: 62473315, U24B20178)和陕西省自然科学基金基础研究计划(编号: 2024JC-YBMS-457, 2024JC-TBZC-03)资助项目

摘要 以“无人机蜂群”为典型代表的空间难分辨集群目标作为实例化具身智能系统, 因其低成本、大规模、高灵活性等特点, 正成为防空反无的主要监视对象之一. 传统集群目标跟踪方法依赖于集群质心运动与外形轮廓的精细化建模, 当集群目标进行难以预测机动飞行或集群外形展现为非规则几何形状时, 往往会因为先验模型失配而导致难以接受的跟踪误差. 因此, 提出了一种不完全建模下考虑机动运动的任意形状集群目标自适应跟踪方法. 首先, 利用基准模型联合函数拟合的方式对时间维度集群机动运动进行建模, 借助高斯过程对非规则集群几何外形进行表征, 构建带未知权重的集群目标机动运动质心/轮廓时空演化模型; 其次, 通过低差异序列自适应构造权重基准点以辅助刻画集群机动运动, 从而有效降低后续滤波算法计算量; 最后, 设计了质心伪量测辅助下迭代扩展卡尔曼滤波以获得机动运动集群目标精准、高效的质心/轮廓递推估计, 并分析了所设计方法的计算复杂度. “T”型不规则外形集群目标典型机动运动仿真实验结果表明, 所提方法在兼顾计算效率的同时, 可以在机动运动模型未知情况下获得高精度的集群质心和轮廓估计.

关键词 集群目标跟踪, 未知机动, 任意形状, 自适应递推估计

1 引言

无人机集群目标, 作为一种新型实例化具身智能系统, 广泛应用于侦查探测、要地打击、精准救援等军民领域^[1]. 集群目标通常由一组空间距离相距较近且具有相似运动特征的多点目标构成, 如无人机蜂群. 精准可靠地监视跟踪无人机集群目标是实现态势

感知的核心技术之一. 受雷达视距和空间分辨能力的限制, 集群内多个相邻目标通常出现在雷达同一探测单元, 产生一个回波量测, 从而导致传统多目标跟踪方法的失效. 对于这类目标跟踪系统而言, 状态估计主要聚焦于两个核心任务: 其一是集群质心的估计, 其二是集群轮廓的估计. 这里, 集群质心状态估计可以采取类似点目标跟踪滤波方法实现, 如卡尔曼滤波

引用格式: 杨衍波, 丁皓莹, 刘准钊, 等. 不完全建模下具有未知机动的任意形状集群目标自适应跟踪. 中国科学: 技术科学, 2026, 56: 328–341
Yang Y B, Ding H Y, Liu Z G, et al. Adaptive tracking of arbitrary-shaped group targets with unknown maneuvering based on partially modelling (in Chinese). Sci Sin Tech, 2026, 56: 328–341, doi: [10.1360/SST-2025-0205](https://doi.org/10.1360/SST-2025-0205)

及其衍生方法. 因此, 集群目标跟踪重点关注集群轮廓的空间演化建模及递推估计.

根据集群外形特征, 现有集群轮廓建模方法可分为两类, 包括规则外形建模法和任意外形(非规则外形)建模法.

规则外形建模法主要包括诸如椭圆/矩形等简单外形建模法和星凸外形建模法. 椭圆外形建模法由 Koch^[2]最先提出, 其使用随机矩阵描述集群轮廓, 并将其演化过程建模为 Wishart 分布, 在忽略量测噪声的前提下, 给出了贝叶斯滤波框架下集群目标状态递推估计. Feldmann 等人^[3]则认为忽略量测噪声会损失估计精度, 因此重新修改了上述模型, 并利用矩匹配理论实现了交互式多模型框架下集群目标的状态估计. Yang 和 Baum^[4]将椭圆半轴长、方向角作为参数, 在乘性噪声的假设下重新构建了量测方程. 基于此, 文献^[5]将该方法嵌入交互式多模型框架, 实现了机动集群目标的状态估计. 鉴于乘性噪声会带来复杂的递推计算, 文献^[6]利用变分贝叶斯推断实现了集群方向角的估计. 陈辉等人^[7]在随机矩阵的框架下, 通过建模高斯噪声与后尾噪声之间的非平稳过程, 实现了异常噪声条件下目标状态的估计. 相比椭圆建模, 星凸外形建模能够提供更丰富的轮廓细节. 基于星凸外形假设, Baum 和 Hanebeck^[8]提出了随机超曲面模型(random hypersurface model, RHM), 其对径向距(由集群质心指向集群轮廓)进行傅里叶展开, 并对展开系数进行递推估计, 联合集群质心, 实现了集群轮廓的估计; 文献^[9~13]则利用高斯过程对径向距建模, 相比于 RHM, 高斯过程计算复杂度更低, 且能够处理未观测部分的不确定性. 此外, 陈辉等人^[14]利用 alpha-shape 算法构建星凸外形演化模型, 并结合集群质心估计, 实现了目标状态的估计.

非规则外形建模法主要包括水平集 RHM、多椭圆和高斯过程法. 水平集 RHM 通过给定形状函数的水平集实现轮廓的转化^[15]; 多椭圆法将目标外形建模为多个椭圆的组合以此实现形态估计^[16,17]; 考虑高斯过程对后验递推分布的天然支持能力, 其在任意外形轮廓建模方面也受到了广泛关注, 不同于使用高斯过程拟合星凸轮廓的方法, 该方法定义了一个表征基准位置点标签的势函数, 通过递推估计基准点处势函数的值实现集群轮廓的拟合^[18].

然而, 上述这些集群目标跟踪或质心/轮廓递推估

计方法往往聚焦于集群内目标进行非机动或弱机动运动的情形, 即利用先验标称模型能够对目标运动进行有效刻画的情形. 事实上, 无人机集群受任务驱动总是会出现各式各样难以预测的机动飞行. 对于机动点目标跟踪状态估计, 目前研究方法较多, 大致可分为如下三类, 即模型驱动、数据驱动、模型/数据混合驱动方法.

模型驱动方法总是希望建立理想的运动学方程, 并以此设计最优或次优的滤波方法^[19~24], 包括 Singer 模型^[19]、当前统计模型^[19]、交互式多模型(interacting multiple model, IMM)^[20]及其相关改进算法^[21~24]等. 考虑精确的先验运动模型难以构建的问题, 文献^[25]提出利用基函数展开法建模目标的未知机动运动, 并以此构建状态空间模型, 在贝叶斯滤波框架下实现了未知机动下目标状态的精准估计. 数据驱动方法则聚焦于从训练集中提取尽可能多的目标运动特征, 借助机器学习或神经网络实现目标状态的估计, 包括高斯过程法^[26]、LSTM^[27,28]、Transformer^[29]、可在线学习的循环 Kalman 神经网络^[30]等. 考虑到先验运动模型难以构建, 而数据集完备性又难以保证的缺点, 模型/数据混合驱动方法应运而生, 其旨在结合模型驱动方法的鲁棒性和数据驱动方法对特征挖掘的能力, 如 Kalman-Net^[31]、Latent KalmanNet^[32]、模型辅助下数据驱动机动目标状态估计算法^[33]等.

但是, 对于具有机动运动的集群目标跟踪, 少量研究聚焦于规则几何外形下机动运动集群目标跟踪^[3,5]; 对于非规则外形下机动运动集群目标跟踪, 由于时间维度集群不可预测机动运动往往与非规则集群外形空间维度的柔性演化相互影响, 进一步制约着现有集群目标跟踪精细模型构建的困难. 针对非规则外形下机动运动集群目标, 如何设计自适应的递推滤波方法, 获得高精度的质心/轮廓估计, 就作者目前知识而言, 这仍然是一个重要且开放的问题.

因此, 本文提出了一种不完全建模下具有未知机动的任意形状集群目标自适应跟踪方法, 相应创新点如下:

(1) 利用基准模型联合函数拟合的方式对时间维度集群机动运动进行建模, 并借助高斯过程对非规则集群几何外形进行表征, 从而构建带未知权重的集群目标机动运动质心/轮廓时空演化模型;

(2) 引入低差异序列自适应构造权重基准点以辅

助刻画集群机动运动, 有效降低后续递推滤波算法计算复杂度;

(3) 设计质心伪量测辅助下迭代扩展卡尔曼滤波, 实现对机动目标集群精准、高效的质心/轮廓递推估计, 并分析了所设计方法的计算复杂度.

本文剩余章节结构安排如下: 第2节阐述了任意形状集群目标机动运动建模过程; 第3节提出了一种低差异序列拟合下集群目标机动运动自适应跟踪方法; 第4节给出了两种典型仿真场景下不同算法实验对比结果, 验证了所提算法的有效性; 第5节对本文工作进行了总结.

2 任意形状集群目标机动运动建模

鉴于集群内目标运动的相似性, 集群随时间的机动运动可以由集群质心的机动运动统一表征. 因此, 机动目标集群的运动模型构建将聚焦于集群任意形态轮廓建模与集群质心机动运动建模两个方面, 下面分别进行介绍.

2.1 集群形态轮廓建模

考虑如图1所示任意形状(非规则的几何外形, 即非椭圆/椭球、矩形、星凸等外形)的集群目标示例.

对于该任意形状集群轮廓的建模, 定义如下势函数:

$$f(\mathbf{u}) = \begin{cases} +1, & \mathbf{u} \in \Xi, \\ -1, & \mathbf{u} \notin \Xi, \end{cases} \quad (1)$$

其中, Ξ 代表集群的真实轮廓范围, $\mathbf{u} \in \mathbb{R}^d$ 代表定义在目标局部坐标系下的 d 维坐标点. 当坐标点 $\mathbf{u} \in \Xi$ 时, 势函数值取+1, 反之取-1. 因此, 通过递推估计如图1所示的基准点处的势函数值, 即可获得集群轮廓范围的估计. 针对典型集群目标跟踪场景, 考虑如下标签量测方程:

$$s_{k,l} = f(\mathbf{u}_{k,l}^L) + e_{k,l}, \quad e_{k,l} \sim \mathcal{N}(0, R), \quad (2)$$

其中, $s_{k,l}$ 代表 k 时刻全局坐标系下第 l 个标签量测(可由激光雷达、深度相机等生成^[18]), $\mathbf{u}_{k,l}^L$ 代表 k 时刻集群目标局部坐标系下第 l 个位置量测, $e_{k,l}$ 代表高斯白噪声, 服从均值为0、方差为 R 的高斯分布. 根据几何关系:




图1 (网络版彩图)集群结构示意图

Figure 1 (Color online) Illustration of the group structure.

$$\mathbf{u}_{k,l}^L = \mathbf{z}_{k,l} - \mathbf{x}_k^c, \quad (3)$$

其中, $\mathbf{z}_{k,l}$ 代表 k 时刻全局坐标系下第 l 个位置量测, $\mathbf{x}_k^c$ 代表 k 时刻集群质心的位置(上标 c 用来表示质心). 考虑高斯过程(Gaussian process, GP)对后验递推分布的天然支持能力, 式(2)中非线性势函数 $f(\cdot)$ 可以使用高斯过程进行建模.

高斯过程是定义在连续域的随机过程, 其可以视为一种函数上的分布, 该分布由均值函数和协方差函数唯一定义, 记作:

$$f_k \sim \mathcal{GP}(\mathbb{E}(f(\mathbf{u}_k)), \kappa(\mathbf{u}_k, \mathbf{u}'_k)), \quad (4)$$

其中, $\mathbf{u}_k$ 代表函数 f 的输入, $\kappa(\cdot, \cdot)$ 代表协方差函数, 描述数据点之间的相似性, 一种常见的协方差函数形式如下:

$$\kappa(\mathbf{u}_k, \mathbf{u}'_k) = \sigma_f^2 e^{-\frac{\|\mathbf{u}_k - \mathbf{u}'_k\|^2}{2\ell^2}}, \quad (5)$$

其中, σ_f 和 ℓ 代表高斯过程的超参数.

高斯过程回归是一种非参数贝叶斯回归方法, 但其实现过程受限于批处理结构, 并不适用于目标跟踪这种实时性需求较高的场景. 为此, 文献[9]给出了一种近似递归形式, 通过已知输入 $\mathbf{u}_{k,l}^L$ 与观测数据 $s_{k,l}$ 去学习其他输入处 $\mathbf{u}^* = [(\mathbf{u}_1^*)^T, (\mathbf{u}_2^*)^T, \dots, (\mathbf{u}_N^*)^T]^T$ 的函数值 $\mathbf{f}_k = [f_k(\mathbf{u}_1^*), f_k(\mathbf{u}_2^*), \dots, f_k(\mathbf{u}_N^*)]^T$. 根据高斯过程的基本理论, 观测数据和函数值的联合分布如下:

$$\begin{bmatrix} s_{k,l} \\ \mathbf{f}_k \end{bmatrix} \sim \mathcal{N} \left(0, \begin{bmatrix} \kappa(\mathbf{u}_{k,b}^L, \mathbf{u}_{k,l}^L) + R & \mathbf{K}(\mathbf{u}_{k,b}^L, \mathbf{u}^*) \\ \mathbf{K}(\mathbf{u}^*, \mathbf{u}_{k,l}^L) & \mathbf{K}(\mathbf{u}^*, \mathbf{u}^*) \end{bmatrix} \right). \quad (6)$$

因此, $p(s_{k,l} | \mathbf{f}) = \mathcal{N}(s_{k,l}; \mathbf{H}_{k,l}^f \mathbf{f}_k, \tilde{R}_{k,l}^f)$, 其中,

$$\mathbf{H}_{k,l}^f = \mathbf{K}(\mathbf{u}_{k,b}^L, \mathbf{u}^*) [\mathbf{K}(\mathbf{u}^*, \mathbf{u}^*)]^{-1}, \quad (7)$$

$$\tilde{R}_{k,l}^f = \kappa(\mathbf{u}_{k,b}^L, \mathbf{u}_{k,l}^L) + R - \mathbf{K}(\mathbf{u}_{k,b}^L, \mathbf{u}^*) \mathbf{K}^{-1}(\mathbf{u}^*, \mathbf{u}^*) \mathbf{K}(\mathbf{u}^*, \mathbf{u}_{k,l}^L), \quad (8)$$

其中, $\mathbf{K}(\cdot, \cdot)$ 代表协方差矩阵, 即

$$\mathbf{K}(\mathbf{u}, \mathbf{v}) = \begin{bmatrix} \kappa(\mathbf{u}_b, \mathbf{v}_b) & \cdots & \kappa(\mathbf{u}_b, \mathbf{v}_q) \\ \vdots & \ddots & \vdots \\ \kappa(\mathbf{u}_p, \mathbf{v}_b) & \cdots & \kappa(\mathbf{u}_p, \mathbf{v}_q) \end{bmatrix}, \quad (9)$$

其中, $\mathbf{u} = (\mathbf{u}_1^T, \dots, \mathbf{u}_p^T)^T$, $\mathbf{v} = (\mathbf{v}_1^T, \dots, \mathbf{v}_q^T)^T$, 且 $\mathbf{u}_a$ 和 $\mathbf{v}_b$ 与式(4)中 $\mathbf{u}_k$ 维数相同, $a = 1, 2, \dots, p$, $b = 1, 2, \dots, q$.

根据式(6)~(9), 等价的状态空间模型形式如下:

$$\mathbf{x}_{k+1}^f = \mathbf{x}_k^f + \mathbf{w}_k^f, \quad \mathbf{w}_k^f \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k^f), \quad (10)$$

$$s_{k,l} = \mathbf{H}_{k,l}^f \mathbf{x}_k^f + e_{k,l}^f, \quad e_{k,l}^f \sim \mathcal{N}(\mathbf{0}, \tilde{R}_{k,l}^f), \quad (11)$$

其中,

$\mathbf{x}_k^f = \mathbf{f}_k = [f_k(\mathbf{u}_1^*), f_k(\mathbf{u}_2^*), \dots, f_k(\mathbf{u}_{N^*}^*)]^T$, $\mathbf{Q}_k^f = \mathbf{K}^{-1}(\mathbf{u}^*, \mathbf{u}^*)$. 假设同一时刻各量测相互独立, 对量测进行扩维, 式(11)可重构如下:

$$\mathbf{s}_k = \mathbf{H}_k^f \mathbf{x}_k^f + \mathbf{e}_k^f, \quad \mathbf{e}_k^f \sim \mathcal{N}(\mathbf{0}, \tilde{\mathbf{R}}_k^f), \quad (12)$$

其中,

$$\mathbf{s}_k = [s_{k,1}, s_{k,2}, \dots, s_{k,N_k}]^T, \quad (13)$$

$$\mathbf{H}_k^f = [(\mathbf{H}_{k,1}^f)^T, (\mathbf{H}_{k,2}^f)^T, \dots, (\mathbf{H}_{k,N_k}^f)^T]^T, \quad (14)$$

$$\tilde{\mathbf{R}}_k^f = \text{blkdiag}(\tilde{R}_{k,1}^f, \tilde{R}_{k,2}^f, \dots, \tilde{R}_{k,N_k}^f), \quad (15)$$

其中, N_k 代表 k 时刻的标签量测个数.

最后, 通过递推滤波得到状态 $\mathbf{x}_k^f$ 的估计及估计误差协方差后, 根据预设的函数阈值判断每一基准点的类别标签或根据下式计算相应类别标签的概率:

$$p(c_{k,i} = 1) = C \left(\frac{\alpha \mu_{k,i} + \beta}{\sqrt{1 + \alpha^2 \sigma_{k,i}^2}} \right), \quad (16)$$

其中, $C(\cdot)$ 代表正态分布的累积密度函数, α 和 β 为所对应参数, $\mu_{k,i}$ 和 $\sigma_{k,i}^2$ 分别代表 k 时刻状态 $\mathbf{x}_k^f$ 估计的第 i 维均值与方差. $p(c_{k,i} = -1) = 1 - p(c_{k,i} = 1)$. 同样地, 根据预设的概率阈值, 也可获得每一基准点的类别标签, 从而实现集群轮廓的估计.

2.2 集群质心机动建模

传统以卡尔曼滤波为代表的标称模型中点目标状态估计方法在先验模型匹配的情况下可以获得令人满意的性能, 然而实际机动形式复杂多样, 仅靠单一或有限的模型去描述目标复杂的运动不总能得到满意的结果. 因此, 考虑利用基准模型联合函数拟合的方式对集群目标时间维度上的机动运动进行建模, 其中, 基准模型能够有效利用已知的先验信息, 而函数拟合则可以充分刻画未知的机动特性. 这里, 利用 $\mathbf{g}(\cdot)$ 代表基准模型未能刻画的集群质心机动运动, 因此, 集群质心运动的状态空间模型可构建如下:

$$\mathbf{x}_{k+1}^c = \mathbf{F}_k^c \mathbf{x}_k^c + \mathbf{g}_k(\mathbf{x}_k^c) + \mathbf{w}_k^c, \quad (17)$$

其中, $\mathbf{x}_k^c = ((\mathbf{x}_k^c)^T, (\mathbf{v}_k^c)^T)^T$ 代表集群质心的状态向量, 包括位置、速度等. $\mathbf{g}_k(\mathbf{x}_k^c)$ 代表所建模的未知机动项, $\mathbf{w}_k^c$ 代表均值为 $\mathbf{0}$ 、协方差为 $\mathbf{Q}_k^c$ 的高斯白噪声. $\mathbf{F}_k^c$ 代表基准模型的状态转移矩阵, 可根据已知先验信息选取. 对于式(17), 若 $\mathbf{g}_k(\mathbf{x}_k^c) = \mathbf{0}$, 即 $\mathbf{x}_{k+1}^c = \mathbf{F}_k^c \mathbf{x}_k^c + \mathbf{w}_k^c$, 则其退化为集群质心运动的基准模型.

为充分利用状态空间模型便于递推估计的优势, 使用基函数展开的方法拟合未知函数 $\mathbf{g}(\cdot)$, 即

$$[\mathbf{g}_k]_i = \Phi_k^T \boldsymbol{\lambda}_{i,k}, \quad (18)$$

其中, $\boldsymbol{\lambda}_{i,k} = (\lambda_{i,k,1}, \lambda_{i,k,2}, \dots, \lambda_{i,k,N^o})^T$ 代表状态第 i 维对应的权重向量(下标 i 代表第 i 维), Φ_k 代表基函数项, 且

$$\Phi_k = \{\phi_{k,j}\}_{j=1}^{N^o} = (\phi_{k,1}, \phi_{k,2}, \dots, \phi_{k,N^o})^T, \quad (19)$$

$$\phi_{k,j} = e^{-\frac{\|\mathbf{x}_k^c - \boldsymbol{\xi}_j\|^2}{\epsilon^2}}, \quad (20)$$

其中, N^o 代表基函数 $\phi_{k,j}$ 的个数, ϵ 代表超参数, $\boldsymbol{\xi}_j \in \Omega$, $j = 1, 2, \dots, N^o$. Ω 是先验权重基准点集, 代表了目标所有可能出现的位置集合. 联合式(17)~(20), 并将权重扩

维至状态向量中, 可构建如下带未知权重的集群质心运动状态空间模型:

$$\begin{bmatrix} \mathbf{x}_{k+1}^c \\ \boldsymbol{\lambda}_{k+1} \end{bmatrix} = \begin{bmatrix} \mathbf{F}_k^c \mathbf{x}_k^c + \mathbf{g}_k(\mathbf{x}_k^c) \\ \boldsymbol{\lambda}_k \end{bmatrix} + \begin{bmatrix} \mathbf{w}_k^c \\ \mathbf{w}_k^\lambda \end{bmatrix}. \quad (21)$$

类似的, $\mathbf{w}_k^\lambda \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k^\lambda)$ 表示权重的过程噪声项.

这里, $\boldsymbol{\lambda}_k = (\lambda_{1,k}^T, \dots, \lambda_{n_x,k}^T)^T$, n_x 代表状态向量 $\mathbf{x}_k^c$ 的维度.

上述模型使用基函数展开的方法拟合集群质心未知机动函数项. 显然, 该方法的估计精度与先验权重基准点集 $\boldsymbol{\Omega}$ 的密度和覆盖范围成正比关系, 但是这也直接导致了权重状态向量维数的线性增加以及基函数项计算复杂度的显著提升, 尽管文献[25]通过引入紧支撑基函数与近似分解策略来降低时空复杂度, 但在先验信息不足的场景下, 其仍然面临较高计算复杂度的问题. 因此, 如何在有效降低时空复杂度的同时, 依然能够获得高精度的状态估计结果, 正是本文所关注的核心问题.

3 低差异序列拟合下集群目标机动运动自适应跟踪

针对上述状态空间模型下递推状态估计计算复杂度较高的问题, 通过构建低差异序列自适应替代先验权重基准点集 $\boldsymbol{\Omega}$, 并提出了一种质心伪量测辅助下高效的迭代扩展卡尔曼滤波递推实现.

3.1 基于低差异序列的集群机动运动建模

与常见的伪随机数相比, 低差异序列在空间中的分布更加均匀, 如Halton序列[34]、Sobol序列[35]等. 以Halton序列为例, 其构造方法如下所述: 给定整数 c 和 m , 假设整数 m 以 c 为底数的表示形式为 $b_K b_{K-1} \dots b_0$. 那么 m 对应的Halton序列可构造为

$$H_c(m) = \sum_{k=0}^K b_k c^{-k-1}. \quad (22)$$

对单维Halton序列进行增广即可获得多维Halton序列. 例如, 对一个二维整数点 $\mathbf{L} = (L_x, L_y)^T$, 其对应的Halton序列为 $\mathbf{H} = (H_{c_1}(L_x), H_{c_2}(L_y))^T$, 构造过程中需要保证底数 c_1 和 c_2 互质.

通过一系列低差异序列可获得伪蒙特卡罗(quasi-Monte Carlo, QMC)点. 假设 k 时刻状态的估计均值与协方差分别为 $\boldsymbol{\mu}_k$ 和 $\boldsymbol{\Sigma}_k = \boldsymbol{\Sigma}_k^{T/2} \boldsymbol{\Sigma}_k^{1/2}$, 则通过低差异序列构造QMC点如下式所示:

$$\mathbf{Q}_k = \boldsymbol{\mu}_k + \boldsymbol{\Sigma}_k^{1/2} (C^{-1}(\mathbf{H})), \quad (23)$$

其中, $C^{-1}(\cdot)$ 代表累积正态分布函数的反函数, $\mathbf{Q}_k$ 代表由 $\mathbf{H}$ 构造的QMC点.

根据每一时刻集群质心状态估计及其估计误差协方差, 可由固定的一组低差异序列转化得到当前时刻对应的QMC点集 $\tilde{\boldsymbol{\Omega}}_k$ 以自适应地替代先验权重基准点集 $\boldsymbol{\Omega}$, 实现对目标状态空间的自适应采样, 即使用目标最可能出现的位置点集动态地替代目标所有可能出现的先验权重基准点集. 该方法能够在保证估计精度的前提下, 显著降低后续递推滤波的计算复杂度, 提升了所提方法的适用性.

假设基函数项只与集群目标质心的位置有关, 且集群质心状态向量的各维取相同的基函数形式, 此时, 式(21)可重构如下:

$$\begin{bmatrix} \mathbf{x}_{k+1}^c \\ \boldsymbol{\lambda}_{k+1} \end{bmatrix} = \begin{bmatrix} \mathbf{F}_k^c \mathbf{x}_k^c + \tilde{\mathbf{G}}_k \mathbf{g}_k(\mathbf{x}_k^c) \\ \boldsymbol{\lambda}_k \end{bmatrix} + \begin{bmatrix} \mathbf{w}_k^c \\ \mathbf{w}_k^\lambda \end{bmatrix}, \quad (24)$$

其中,

$$\mathbf{g}_k = (\mathbf{I}_d \otimes \boldsymbol{\Phi}_k) \boldsymbol{\lambda}_k, \quad (25)$$

$$\tilde{\mathbf{G}}_k = \begin{bmatrix} T^2/2 & T \end{bmatrix}^T \otimes \mathbf{I}_d, \quad (26)$$

其中, d 代表目标运动场景的维度, 如 $d=2$ 代表目标在二维平面运动, T 表示采样间隔.

3.2 质心伪量测辅助下迭代扩展卡尔曼滤波实现

根据式(10)和(24), 联合状态方程可构建如下:

$$\begin{bmatrix} \mathbf{x}_{k+1}^c \\ \boldsymbol{\lambda}_{k+1} \\ \mathbf{x}_{k+1}^f \end{bmatrix} = \begin{bmatrix} \mathbf{F}_k^c & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{I}_{dN^o} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{I}_{N^*} \end{bmatrix} \begin{bmatrix} \mathbf{x}_k^c \\ \boldsymbol{\lambda}_k \\ \mathbf{x}_k^f \end{bmatrix} + \begin{bmatrix} \tilde{\mathbf{G}}_k \mathbf{g}_k \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} + \begin{bmatrix} \mathbf{w}_k^c \\ \mathbf{w}_k^\lambda \\ \mathbf{w}_k^f \end{bmatrix}. \quad (27)$$

另外, 式(12)所对应的量测方程主要关注于标签量测, 这种量测信息的不完备性可能会造成微小误差的累积放大, 从而削弱后续跟踪滤波算法的精度与鲁棒性. 为解决这一问题, 引入质心伪量测, 修正后的量测方程如下:

$$\mathbf{y}_k = \begin{bmatrix} \mathbf{z}_k^c \\ \mathbf{s}_k \end{bmatrix} = \begin{bmatrix} \mathbf{x}_k^c \\ \mathbf{H}_{k,1}^f \mathbf{x}_k^f \\ \vdots \\ \mathbf{H}_{k,N_k}^f \mathbf{x}_k^f \end{bmatrix} + \mathbf{e}_k = \tilde{\mathbf{h}}(\mathbf{x}_k) + \mathbf{e}_k, \quad (28)$$

其中, $\mathbf{z}_k^c$ 代表质心的伪量测, 即

$$\mathbf{z}_k^c = \sum_{l=1}^{N_k} \mathbf{z}_{k,l} / N_k, \quad (29)$$

且扩维量测噪声 $\mathbf{e}_k = ((\mathbf{e}_k^c)^T, (\mathbf{e}_k^f)^T)^T \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_k)$,

$$\mathbf{R}_k = \text{blkdiag}(\mathbf{R}_k^c, \tilde{\mathbf{R}}_{k,1}^f, \dots, \tilde{\mathbf{R}}_{k,N_k}^f), \quad (30)$$

其中, $\mathbf{R}_k^c$ 表示质心伪量测的噪声协方差矩阵.

考虑上述联合状态空间模型的非线性以及基函数项只与目标位置有关的假设带来的潜在不准确性, 通过迭代扩展卡尔曼滤波器完成具有未知机动的任意形状集群目标的递推状态估计, 并利用位置差分代替集群质心速度的滤波估计.

基于上述讨论, 现给出所提滤波算法从 $k-1$ 时刻到 k 时刻的递推步骤如下所述.

(i) 状态预测. 记 $k-1$ 时刻集群目标状态估计及其估计误差协方差分别为 $\hat{\mathbf{x}}_{k-1|k-1}$ 和 $\hat{\mathbf{P}}_{k-1|k-1}$, 根据式(27), 一步状态预测如下:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{f}(\hat{\mathbf{x}}_{k-1|k-1}), \quad (31)$$

$$\mathbf{P}_{k|k-1} = \mathcal{F}_{k-1} \hat{\mathbf{P}}_{k-1|k-1} \mathcal{F}_{k-1}^T + \mathbf{Q}_{k-1}, \quad (32)$$

式中, $\mathbf{Q}_{k-1} = \text{blkdiag}(\mathbf{Q}_{k-1}^c, \mathbf{Q}_{k-1}^{\lambda}, \mathbf{Q}_{k-1}^f)$, $\mathcal{F}_{k-1}$ 表示非线性函数 $\mathbf{f}_{k-1} = \text{blkdiag}(\mathbf{F}_{k-1}^c \mathbf{x}_{k-1}^c + \tilde{\mathbf{G}}_{k-1} \mathbf{g}_{k-1}, \mathbf{I}_{dN} \odot \boldsymbol{\lambda}_{k-1}, \mathbf{I}_N * \mathbf{x}_{k-1}^f)$ 在状态估计 $\hat{\mathbf{x}}_{k-1|k-1}$ 处的雅可比矩阵.

(ii) 量测预测与新息协方差计算.

$$\hat{\mathbf{y}}_{k|k-1} = \tilde{\mathbf{h}}(\hat{\mathbf{x}}_{k|k-1}), \quad (33)$$

$$\mathbf{N}_{k|k-1} = \mathcal{H}_k \mathbf{P}_{k|k-1} \mathcal{H}_k^T + \mathbf{R}_k, \quad (34)$$

式中, $\mathcal{H}_k$ 表示非线性函数 $\tilde{\mathbf{h}}(\cdot)$ 在状态预测 $\hat{\mathbf{x}}_{k|k-1}$ 处的雅可比矩阵.

(iii) 滤波增益计算.

$$\mathcal{K}_k = \mathbf{P}_{k|k-1} \mathcal{H}_k^T \mathbf{N}_{k|k-1}^{-1} \quad (35)$$

(iv) 状态更新.

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathcal{K}_k (\mathbf{y}_k - \hat{\mathbf{y}}_{k|k-1}), \quad (36)$$

$$\hat{\mathbf{P}}_{k|k} = (\mathbf{I} - \mathcal{K}_k \mathcal{H}_k) \mathbf{P}_{k|k-1} (\mathbf{I} - \mathcal{K}_k \mathcal{H}_k)^T + \mathcal{K}_k \mathbf{R}_k \mathcal{K}_k^T. \quad (37)$$

根据上述估计结果, k 时刻集群质心速度估计修正为

$$\hat{\mathbf{v}}_{k|k}^c = (\hat{\mathbf{x}}_{k|k}^c - \hat{\mathbf{x}}_{k-1|k-1}^c) / T. \quad (38)$$

(v) 状态估计迭代. 令 $\hat{\mathbf{x}}_{k|k-1} \leftarrow \hat{\mathbf{x}}_{k|k}$, 重复步骤(ii)~(iv) n 次, n 为预设的迭代次数. 以最后一次迭代输出的状态估计作为最终的集群目标质心/轮廓状态估计.

3.3 算法复杂度分析

为直观评估所提算法的计算复杂度, 采用浮点运算(floating-point operations, FLOPs)数量作为衡量指标, 表1给出了所提算法各计算步骤的FLOPs数量. 这里, 对于 $n \times n$ 的矩阵, 定义其逆矩阵的FLOPs数量为 n^3 .

4 仿真实验

4.1 场景设置

考虑外形为“T”形的集群目标, 假设集群质心位于坐标系原点, “T”形集群内上半部分目标在 x 轴的位置分布范围为 $[-30 \text{ m}, 30 \text{ m}]$, 在 y 轴的位置分布范围为 $[10 \text{ m}, 30 \text{ m}]$; “T”形集群内下半部分目标在 x 轴的位置分布范围为 $[-10 \text{ m}, 10 \text{ m}]$, 在 y 轴的位置分布范围为 $[-30 \text{ m}, 10 \text{ m}]$. 集群内所有目标在 x 轴和 y 轴方向上均以 5 m 的间隔等间距排列, 集群内共包含 105 个目标.

为验证所提算法的有效性, 考虑如下两个集群目标机动运动典型场景.

场景1: 集群目标在 $o\text{-}xy$ 平面上运动, 初始位置 $(100 \text{ m}, 50 \text{ m})^T$, 初始速度 $(50 \text{ m/s}, 50 \text{ m/s})^T$, 仿真总时长为 100 s , 采样间隔 $T = 1 \text{ s}$. 目标在 $0 \sim 10$, $51 \sim 60$ 和 $81 \sim 90 \text{ s}$ 做匀速直线运动, $21 \sim 30$, $41 \sim 50$, $71 \sim 80$ 和 $91 \sim 100 \text{ s}$ 做转弯角速度 $\omega = 15^\circ/\text{s}$ 的匀速左转弯运动, 其余时间做转弯角速度 $\omega = -24^\circ/\text{s}$ 的匀速右转弯运动. 在整个运动过程中, 集群目标不发生旋转变化.

场景2: 集群目标运动模式、初始状态均与场景1保持一致, 但在整个过程中, 集群会发生额外的旋转变化, 即集群在 $0 \sim 10 \text{ s}$ 不发生旋转, 在 $11 \sim 20$, $41 \sim 60$

和81 ~ 100 s以集群质心为参考点做角速度为 $\pi/20$ rad/s的匀速旋转运动, 其余时间则以 $-\pi/20$ rad/s的角速度绕集群质心做匀速旋转运动.

两个场景下集群目标运动轨迹如图2所示.

该集群目标被位于平面坐标原点的雷达探测, 每一时刻雷达随机获得60个位置量测及其对应的标签量测信息, 量测噪声协方差 $R = \text{blkdiag}(3^2, 3^2)$.

选取匀速直线运动模型作为所提算法(QMBGP)

的基准模型, 并与如下三种算法进行仿真对比, 以验证所提方法的有效性, 即参数完全匹配下基于IMM的任意外形集群目标跟踪算法(MIMM)、参数不完全匹配下基于IMM的任意外形集群目标跟踪算法(UMIMM)和基于基准模型的任意外形集群目标跟踪算法(CVAGP). 两种基于IMM的对比算法的模型集均包含匀速、匀速左转、匀速右转三种运动模式. 这里, 匀速、匀速左转、匀速右转描述的是集群质心的运动模式, 其余状

表 1 基于浮点运算数的所提算法复杂度分析

Table 1 The computational complexity of the proposed algorithm based on FLOPs

公式	FLOPs数量
$\hat{\mathbf{x}}_{k k-1} = \tilde{\mathbf{f}}(\hat{\mathbf{x}}_{k-1 k-1})$	$2(n_x^2 + dn_x + 2dN^o + d^2(N^o)^2 + (N^*)^2)$
$\mathbf{P}_{k k-1} = \mathcal{F}_{k-1} \hat{\mathbf{P}}_{k-1 k-1} \mathcal{F}_{k-1}^T + \mathbf{Q}_{k-1}$	$4(n_x + dN^o + N^*)^3 + (n_x + dN^o + N^*)^2$
$\hat{\mathbf{y}}_{k k-1} = \tilde{\mathbf{h}}(\hat{\mathbf{x}}_{k k-1})$	$2N_k((N^*)^2 + N^*) + 2dn_x$
$\mathbf{N}_{k k-1} = \mathcal{H}_k \mathbf{P}_{k k-1} \mathcal{H}_k^T + \mathbf{R}_k$	$2((N_k + d)(n_x + dN^o + N^*)^2 + (N_k + d)^2(n_x + dN^o + N^*)) + (N_k + d)^2$
$\mathcal{K}_k = \mathbf{P}_{k k-1} \mathcal{H}_k^T \mathbf{N}_{k k-1}^{-1}$	$2((N_k + d)(n_x + dN^o + N^*)^2 + (N_k + d)^2(n_x + dN^o + N^*)) + (N_k + d)^3$
$\hat{\mathbf{x}}_{k k} = \hat{\mathbf{x}}_{k k-1} + \mathcal{K}_k(\mathbf{y}_k - \hat{\mathbf{y}}_{k k-1})$	$2(N_k + d)(n_x + dN^o + N^*) + (n_x + dN^o + N^*)^2$
$\hat{\mathbf{P}}_{k k} = (\mathbf{I} - \mathcal{K}_k \mathcal{H}_k) \mathbf{P}_{k k-1} (\mathbf{I} - \mathcal{K}_k \mathcal{H}_k)^T + \mathcal{K}_k \mathbf{R}_k \mathcal{K}_k^T$	$2(n_x + dN^o + N^*)^2(3(N_k + d) + 2) + 2(n_x + dN^o + N^*) + 2(n_x + dN^o + N^*)(N_k + d)^2$
$\hat{\mathbf{v}}_{k k}^c = (\hat{\mathbf{x}}_{k k}^c - \hat{\mathbf{x}}_{k-1 k-1}^c) / T$	$2d$




图 2 (网络版彩图)集群目标运动轨迹示意图. (a) 场景1集群目标运动轨迹; (b) 场景2集群目标运动轨迹

Figure 2 (Color online) Illustration of group target motion trajectories. (a) The motion trajectory in Scenario 1; (b) the motion trajectory in Scenario 2.

态变量的运动模式则与QMBGP保持一致, 且不随集群质心运动模式的改变而改变. MIMM中匀速左转弯的转弯角速度 $\omega = 15^\circ/\text{s}$, 匀速右转弯的转弯角速度 $\omega = -24^\circ/\text{s}$. UMIMM中匀速左转弯的转弯角速度 $\omega = 55^\circ/\text{s}$, 匀速右转弯的转弯角速度 $\omega = -85^\circ/\text{s}$. 所有算法中描述轮廓外形的基准点均在 $[-50 \text{ m}, 50 \text{ m}] \times [-50 \text{ m}, 50 \text{ m}]$ 的网格上以5 m的间距等间隔分布, $N^* = 441$; 权重基准点均在 $[1 \text{ m}, 500 \text{ m}] \times [1 \text{ m}, 500 \text{ m}]$

的网格上以1 m的间隔均匀分布, $N^o = 500$. 所有算法中过程噪声标准差均为0.1, 滤波器迭代次数 $n = 2$, GP中所涉及的超参数取值为 $\ell = 8$, $\sigma_f = 2$. 各算法在得到相应滤波结果后, 根据预设的函数阈值对每一基准点的类别标签进行判断, 并设置阈值为0.

4.2 不同算法跟踪滤波精度实验结果与分析

图3~6分别给出了各对比算法(QMBGP、MIMM、




图3 (网络版彩图)QMBGP跟踪滤波结果示意图. (a) 场景1跟踪结果; (b) 场景2跟踪结果

Figure 3 (Color online) Tracking results of QMBGP. (a) Tracking results of Scenario 1; (b) tracking results of Scenario 2.




图4 (网络版彩图)MIMM跟踪滤波结果示意图. (a) 场景1跟踪结果; (b) 场景2跟踪结果

Figure 4 (Color online) Tracking results of MIMM. (a) Tracking results of Scenario 1; (b) tracking results of Scenario 2.




图 5 (网络版彩图)UMIMM跟踪滤波结果示意图. (a) 场景1跟踪结果; (b) 场景2跟踪结果

Figure 5 (Color online) Tracking results of UMIMM. (a) Tracking results of Scenario 1; (b) tracking results of Scenario 2.




图 6 (网络版彩图)CVAGP跟踪滤波结果示意图. (a) 场景1跟踪结果; (b) 场景2跟踪结果

Figure 6 (Color online) Tracking results of CVAGP. (a) Tracking results of Scenario 1; (b) tracking results of Scenario 2.

UMIMM和CVAGP)在上述两个仿真场景下的跟踪滤波结果示意图.

为进一步量化跟踪结果, 基于100次蒙特卡罗仿真实现, 图7和8分别给出了相应估计的均方根误差(root mean square error, RMSE)和轮廓交并比(intersection over union, IOU)的统计结果. 这里, RMSE和IOU的计算公式如式(39)和(40)所示:

$$\text{RMSE}_k^{(j)} = \sqrt{\frac{\sum_{i=1}^M (\hat{\mathbf{x}}_{i,k}^{(j)} - \mathbf{x}_{i,k}^{(j)})^2}{M}}, \quad (39)$$

$$\text{IOU}_k = \frac{1}{M} \sum_{i=1}^M \frac{A_{i,k} \cap \hat{A}_{i,k}}{A_{i,k} \cup \hat{A}_{i,k}}, \quad (40)$$

其中, $\hat{\mathbf{x}}_{i,k}^{(j)}$ 代表 k 时刻第 i 次蒙特卡罗仿真下第 j 维状态




图 7 (网络版彩图)场景1下不同算法集群质心位置估计RMSE(a)和轮廓估计的IOU(b)

Figure 7 (Color online) The RMSE of the estimated group centroid position (a) and IOU of the estimated group contour (b) for different algorithms in Scenario 1.




图 8 (网络版彩图)场景2下不同算法集群质心位置估计RMSE(a)和轮廓估计的IOU(b)

Figure 8 (Color online) The RMSE of the estimated group centroid position (a) and IOU of the estimated group contour (b) for different algorithms in Scenario 2.

估计, $\hat{A}_{i,k}$ 代表 k 时刻第 i 次蒙特卡罗仿真下集群轮廓范围的估计, $\mathbf{x}_{i,k}^{(j)}$ 和 $A_{i,k}$ 为相应的第 j 维状态真值与真实的轮廓范围, M 是蒙特卡罗仿真的次数.

从图3~8可以看出, 无论是集群质心位置估计

RMSE还是集群轮廓估计的IOU, 所提算法的估计性能均优于UMIMM和CVAGP, 且仅略低于MIMM, 所提算法在未知机动条件下展现出了较强的自适应性. 进一步地, 在前10 s, 所有算法的估计误差都很小, 这是由于在0~10 s目标未发生未知机动, 三种对比算法

的模型匹配度都较高. 随着集群目标发生未知机动而导致模型不匹配程度增加, UMIMM和CVAGP的性能逐渐下降, 但所提QMBGP则几乎不受影响. 此外, 通过对比两个场景下的跟踪结果, 可以发现, 当集群目标发生旋转变换时, 对比算法的精度均有所下降, 但所提QMBGP的滤波精度并未受到明显影响, 这也证明了

所提算法的适用性与鲁棒性.

4.3 不同量测噪声水平下实验结果与分析

为了定性分析所提算法的效果, 基于100次蒙特卡罗仿真实现, 图9和10分别给出了所有算法在不同量测噪声水平下RMSE均值(average value of RMSE,




图9 (网络版彩图)场景1下不同算法集群质心位置估计的ARMSE(a)和轮廓估计的AIOU(b)

Figure 9 (Color online) The ARMSE of the estimated group centroid position (a) and AIOU of the estimated group contour (b) for different algorithms in Scenario 1.




图10 (网络版彩图)场景2下不同算法集群质心位置估计的ARMSE(a)和轮廓估计的AIOU(b)

Figure 10 (Color online) The ARMSE of the estimated group centroid position (a) and AIOU of the estimated group contour (b) for different algorithms in Scenario 2.

ARMSE)和IOU均值(average value of IOU, AIOU)的统计结果. 这里, ARMSE和AIOU的计算分别如式(41)和(42)所示:

$$\text{ARMSE}_i = \frac{1}{K} \sum_{k=1}^K \text{RMSE}_{i,k}, \quad (41)$$

$$\text{AIOU}_i = \frac{1}{K} \sum_{k=1}^K \text{IOU}_{i,k}, \quad (42)$$

其中, $\text{RMSE}_{i,k}$ 和 $\text{IOU}_{i,k}$ 分别代表 k 时刻第 i 个量测噪声水平下的RMSE和IOU统计结果, K 代表仿真总时刻数.

从图9和10可以看出, 所提QMBGP在不同量测噪声水平下均能保持较为稳定的跟踪结果. 相比之下, UMIMM和CVAGP的跟踪滤波精度随量测噪声水平的增大而显著下降, 而MIMM的滤波性能随着量测噪声水平的增加先提升后趋于稳定, 这种现象主要是由于随着量测噪声标准差的增加, MIMM会降低对量测的信任度, 转而更依赖集群目标运动模型, 而由于该算法所使用的集群目标运动模型本身具有较高的准确性, 这种调整反而降低了量测噪声对滤波精度的影响, 从而在一定程度上提升了跟踪效果. 同时, 通过对比图9和10的结果, 仍然可以发现, 当目标发生旋转变化时, 对比算法的跟踪效果均有所下降, 而所提QMBGP则受影响较小, 这也进一步验证了所提算法具有较强的鲁棒性.

4.4 算法运行时间实验结果与分析

此外, 为了进一步验证所提算法的实际运行效率, 基于13th Gen Intel(R) Core(TM) i7-13700KF处理器, 在MATLAB 2023b上统计了各对比算法单次蒙特卡罗仿真的平均运行时间, 相关数据如表2所示.

综合表1和2以及上述实验结果, 相比于MIMM和UMIMM, 由于所提QMBGP无需考虑运行多个不同运

表2 各算法的平均运行时间^{a)}

Table 2 Average running time of different algorithms

算法	运行时间 (s)
QMBGP	45.60
MIMM	68.63
UMIMM	69.73
CVAGP	23.84

a) 加粗数据表明该方法为本文所提方法

动模式下的子滤波器以尽可能覆盖集群机动运动且避免了多个子滤波器之间的交互输入及输出, 因此显著降低了计算量, 同时也能够保证良好的滤波精度, 证明所提方法可以获得高效且精准鲁棒的跟踪结果.

5 结论

针对未知机动下任意形状集群目标跟踪问题, 提出了一种不完全建模下自适应跟踪方法, 以获得集群质心/形态轮廓的高精度递推估计. 首先, 利用势函数对集群轮廓外形建模, 获得了高斯过程框架下集群轮廓的参数化表征, 并联合基准模型与函数拟合方法实现了时间维度上集群机动运动的建模, 避免了对先验模型的严重依赖; 其次, 通过引入低差异序列自适应地构造了权重基准点进行质心机动运动的建模优化; 最后, 在质心伪量测辅助下利用迭代扩展卡尔曼滤波获得了集群目标状态高效精准的递推估计, 并分析了所提方法计算复杂度. 典型场景仿真结果表明, 所提方法在保证计算效率的同时, 显著提升了集群未知机动运动下质心位置和轮廓外形的估计精度.

未来工作将进一步关注非高斯噪声场景下集群目标机动运动质心/轮廓的递推估计方法, 以期在实际场景复杂非高斯环境下获得更高精度的跟踪结果.

参考文献

- Xu L, Luo Z. Anti-UAV detection and identification technology: Fundamentals, methods and challenges. *Phys Commun*, 2025, 71: 102676
- Koch J W. Bayesian approach to extended object and cluster tracking using random matrices. *IEEE Trans Aerosp Electron Syst*, 2008, 44: 1042–1059
- Feldmann M, Franken D, Koch W. Tracking of extended objects and group targets using random matrices. *IEEE Trans Signal Process*, 2011, 59: 1409–1420
- Yang S, Baum M. Tracking the orientation and axes lengths of an elliptical extended object. *IEEE Trans Signal Process*, 2019, 67: 4720–4729
- Wang S, Men C, Li R, et al. A maneuvering extended target tracking IMM algorithm based on second-order EKF. *IEEE Trans Instrum Meas*,

- 2024, 73: 1–11
- 6 Tuncer B, Ozkan E. Random matrix based extended target tracking with orientation: A new model and inference. *IEEE Trans Signal Process*, 2021, 69: 1910–1923
- 7 Chen H, Zhang X Y, Lian F, et al. Extended target tracking method under non-stationary abnormal noise conditions (in Chinese). *J Electron Inf Technol*, 2025, 47: 803–813 [陈辉, 张欣雨, 连峰, 等. 非平稳异常噪声条件下的扩展目标跟踪方法. *电子与信息学报*, 2025, 47: 803–813]
- 8 Baum M, Hanebeck U D. Shape tracking of extended objects and group targets with star-convex RHMs. In: *Proceedings of the 14th International Conference on Information Fusion*. Chicago: IEEE, 2011. 1–8
- 9 Wahlstrom N, Ozkan E. Extended target tracking using Gaussian processes. *IEEE Trans Signal Process*, 2015, 63: 4165–4178
- 10 Aftab W, Hostettler R, De Freitas A, et al. Spatio-temporal Gaussian process models for extended and group object tracking with irregular shapes. *IEEE Trans Veh Technol*, 2019, 68: 2137–2151
- 11 Akbari B, Zhu H. Tracking dependent extended targets using multi-output spatiotemporal Gaussian processes. *IEEE Trans Intell Transp Syst*, 2022, 23: 18301–18314
- 12 Kumru M, Ozkan E. Three-dimensional extended object tracking and shape learning using Gaussian processes. *IEEE Trans Aerosp Electron Syst*, 2021, 57: 2795–2814
- 13 Guo Y F, Li Y, Ren X, et al. Multiple maneuvering extended target tracking based on Gaussian process (in Chinese). *Acta Autom Sin*, 2020, 46: 2392–2403 [郭云飞, 李勇, 任昕, 等. 基于高斯过程的多机动扩展目标跟踪. *自动化学报*, 2020, 46: 2392–2403]
- 14 Chen H, Bian B C, Lian F, et al. A novel method for tracking complex maneuvering star convex extended targets using transformer network (in Chinese). *J Radars*, 2024, 13: 629–645 [陈辉, 边斌超, 连峰, 等. 基于Transformer复杂运动辨识的机动星凸形扩展目标跟踪方法. *雷达学报*, 2024, 13: 629–645]
- 15 Zea A, Faion F, Baum M, et al. Level-set random hypersurface models for tracking nonconvex extended objects. *IEEE Trans Aerosp Electron Syst*, 2016, 52: 2990–3007
- 16 Lan J, Li X R. Tracking of maneuvering non-ellipsoidal extended object or target group using random matrix. *IEEE Trans Signal Process*, 2014, 62: 2450–2463
- 17 Hu Q, Ji H, Zhang Y. Tracking of maneuvering non-ellipsoidal extended target with varying number of sub-objects. *Mech Syst Signal Process*, 2018, 99: 262–284
- 18 Kumru M, Özkan E. Tracking arbitrarily shaped extended objects using Gaussian processes. In: *Proceedings of the 2024 27th International Conference on Information Fusion (FUSION)*. Venice: IEEE, 2024. 1–8
- 19 Ghosh S, Mukhopadhyay S. Tracking reentry ballistic targets using acceleration and jerk models. *IEEE Trans Aerosp Electron Syst*, 2011, 47: 666–683
- 20 Di Y, Li R, Tian H, et al. A maneuvering target tracking based on fastIMM-extended Viterbi algorithm. *Neural Comput Applic*, 2025, 37: 7925–7934
- 21 Lim J, Kim H S, Park H M. Interactive-multiple-model algorithm based on minimax particle filtering. *IEEE Signal Process Lett*, 2020, 27: 36–40
- 22 Yang Y, Liang Y, Pan Q, et al. Distributed fusion estimation with square-root array implementation for Markovian jump linear systems with random parameter matrices and cross-correlated noises. *Inf Sci*, 2016, 370–371: 446–462
- 23 Wang J, Zhou L H, Chen J F, et al. Time-varying smooth variable structure filter based on interactive multi-model (in Chinese). *Acta Aeronaut Astronaut Sin*, 2024, 45: 330167 [王健, 周立辉, 陈家福, 等. 基于交互多模型的时变平滑变结构滤波算法. *航空学报*, 2024, 45: 330167]
- 24 Lan C F, Zhang T J, Chen H. Time-series information-driven parallel interactive multiple model algorithm for underwater target tracking (in Chinese). *J Electron Inf Technol*, 2025, 47: 2685–2693 [兰朝凤, 张桐基, 陈欢. 时序信息驱动的并行交互式多模型水下目标跟踪算法. *电子与信息学报*, 2025, 47: 2685–2693]
- 25 Kullberg A, Skog I, Hendeby G. Online joint state inference and learning of partially unknown state-space models. *IEEE Trans Signal Process*, 2021, 69: 4149–4161
- 26 Aftab W, Mihaylova L. A Gaussian process regression approach for point target tracking. In: *Proceedings of the 2019 22th International Conference on Information Fusion (FUSION)*. Ottawa: IEEE, 2019. 1–8
- 27 Jouaber S, Bonnabel S, Velasco-Forero S, et al. NNAKF: A neural network adapted Kalman filter for target tracking. In: *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Toronto: IEEE, 2021. 4075–4079
- 28 Gao C, Yan J, Zhou S, et al. Long short-term memory-based deep recurrent neural networks for target tracking. *Inf Sci*, 2019, 502: 279–296

- 29 Zhang Y, Li G, Zhang X P, et al. A deep learning model based on transformer structure for radar tracking of maneuvering targets. *Inf Fusion*, 2024, 103: 102120
- 30 Xiong W, Zhu H F, Cui Y Q. Recurrent adaptive maneuvering target tracking algorithm based on online learning (in Chinese). *Acta Aeronaut Astronaut Sin*, 2022, 43: 325250 [熊伟, 朱洪峰, 崔亚奇. 在线学习的循环自适应机动目标跟踪算法. *航空学报*, 2022, 43: 325250]
- 31 Revach G, Shlezinger N, Ni X, et al. KalmanNet: Neural network aided Kalman filtering for partially known dynamics. *IEEE Trans Signal Process*, 2022, 70: 1532–1547
- 32 Buchnik I, Revach G, Steger D, et al. Latent-KalmanNet: Learned Kalman filtering for tracking from high-dimensional signals. *IEEE Trans Signal Process*, 2023, 72: 352–367
- 33 Liu Z, Wang Z, Yang Y, et al. A data-driven maneuvering target tracking method aided with partial models. *IEEE Trans Veh Technol*, 2024, 73: 414–425
- 34 Guo D, Wang X. Quasi-Monte Carlo filtering in nonlinear dynamic systems. *IEEE Trans Signal Process*, 2006, 54: 2087–2098
- 35 Atanassov E, Ivanovska S. On the use of Sobol' sequence for high dimensional simulation. In: *Proceedings of the 22nd Annual International Conference on Computational Science (ICCS)*. Cham: Springer, 2022. 646–652

Adaptive tracking of arbitrary-shaped group targets with unknown maneuvering based on partially modelling

YANG YanBo^{1,2}, DING HaoYing^{1,2}, LIU ZhunGa^{1,2} & DING RunZe^{1,2}

¹ School of Automation, Northwestern Polytechnical University, Xi'an 710129, China

² The Key Laboratory of Information Fusion Technology, Ministry of Education, Xi'an 710129, China

Drone swarm, as an instantiation of embodied intelligence and a typical example of spatially indistinguishable group targets, is emerging as one of the main surveillance objects for air defense and anti-drone systems due to its low-cost, large-scale, and high-flexibility characteristics. Traditional methods for group target tracking rely on the fine-grained modelling of the group's centroid motion and its contour. However, when the group target performs unpredictable maneuvers or exhibits an irregular geometric shape, these methods often suffer from unsatisfactory tracking errors due to the mismatch between the prior model and the actual one. Therefore, this paper proposes an adaptive tracking method for arbitrary-shaped group targets with unknown maneuvers based on incomplete modeling. First, the temporal maneuvering motion of the group is modeled using a nominal model combined with function fitting, while the Gaussian process is employed to depict the irregular group geometry. This establishes a spatio-temporal evolution model for the maneuvering group target, incorporating unknown weights. Second, basis points for the above weights are adaptively constructed using a low-discrepancy sequence to assist in describing the group's maneuvering motion, which effectively decreases the computational cost of the subsequent filtering algorithm. Finally, an iterated extended Kalman filter, aided by the pseudo-measurements of centroid, is designed to obtain a precise and efficient recursive estimate of the maneuvering group's centroid and contour, and the computational complexity of the proposed method is also analyzed. Simulation results for tracking "T"-shaped irregular group target with typical maneuvers demonstrate that the proposed method attains high-precision estimate results for the group centroid and shape while maintaining computational efficiency, in the case of unknown maneuvering.

group target tracking, unknown maneuvering, arbitrary-shaped group, adaptive recursive estimation

doi: [10.1360/SST-2025-0205](https://doi.org/10.1360/SST-2025-0205)