

doi:10.19306/j.cnki.2095-8110.2024.02.011

基于 IMM-UIF 的多无人机纯角度机动目标跟踪

吴亚妃, 张 民, 贾大成, 邹浩文

(南京航空航天大学自动化学院, 南京 211106)

摘要:针对单无人机不能及时捕捉到目标的运动状态信息, 很容易跟丢目标的问题, 结合无迹信息滤波(UIF)算法和交互多模型(IMM)算法, 提出了基于 IMM-UIF 的多无人机分布式融合估计算法。将各个无人机上的观测信息传输至中心节点, 并统一优化各无人机的控制输入。仿真结果表明, 基于 IMM-UIF 的多无人机分布式融合估计算法比基于 IMM-UIF 的单无人机跟踪精度提高了约 30%, 有效融合多无人机平台的量测信息, 实现对目标稳定的高精度跟踪。

关键词: 无人机; 目标跟踪; 交互多模型; 无迹信息滤波; 分布式融合

中图分类号: V279

文献标志码: A

文章编号: 2095-8110(2024)02-0111-11

Angle-only maneuvering target tracking by multi-UAV based on IMM-UIF

WU Yafei, ZHANG Min, JIA Dacheng, ZOU Haowen

(College of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: In view of the problem that a single UAV cannot timely capture the movement status information of the target, it is easy to lose track of the target. Combining the unscented information filtering (UIF) algorithm with the interactive multiple model (IMM) algorithm, a multi-UAV distributed fusion estimation algorithm based on IMM-UIF is proposed. The observation information from each UAV is transferred to a central node and the control inputs of each UAV is uniformly optimized. The simulation results show that the tracking accuracy of the multi-UAV distributed fusion estimation algorithm based on IMM-UIF is about 30% higher than that of the single UAV based on IMM-UIF, and the measurement information of the multi-UAV platform is effectively integrated to achieve stable and high-precision target tracking.

Key words: Unmanned aerial vehicle; Target tracking; Interactive multiple models; Unscented information filtering; Distributed fusion

0 引言

近年来, 无人机应用在各个领域都呈现出广泛发展的趋势。无人机的目标跟踪技术也成为了一个备受关注的研究热点^[1-2]。无人机在现代军事和

民用领域具有多种任务, 包括情报侦察、目标打击、通信中继和电子干扰等。然而, 由于无人机的运动、传感器观测范围以及环境条件等方面存在的限制, 通常单架无人机难以实现对目标的精确和持续跟踪, 多架无人机的协同合作可以共同覆盖更大的

收稿日期: 2023-09-07; 修订日期: 2023-10-16

基金项目: 上海航天科技创新基金(SAST2021-053)

作者简介: 吴亚妃(1998—), 女, 硕士研究生, 主要从事无人机协同控制技术方面的研究。

通信作者: 张民(1973—), 男, 博士, 副研究员, 主要从事无人机飞行控制与仿真及导弹控制方面的研究。

区域,提供更多的观测数据,并通过相互通信协作改善目标跟踪的准确性和持续性^[3]。

多传感器数据融合是一项重要的技术,它将来自多种不同传感器的信息进行协同整合,旨在显著提升数据处理的准确性、可靠性以及系统的鲁棒性^[4]。这一技术的应用范围非常广泛,已经成功应用于众多工程领域,如车辆定位、组合导航及目标跟踪等^[5-6]。融合了信息滤波特性的卡尔曼滤波在多传感器数据融合领域被广泛地应用。该算法在处理线性系统的数据融合问题方面表现出色,但在处理非线性系统的数据融合时效果不佳^[7]。Sasaoka等^[8]在多机器人系统中将扩展卡尔曼滤波(extended Kalman filtering, EKF)与信息滤波(information filtering, IF)相结合,提出了扩展卡尔曼信息滤波(extended information filtering, EIF)。但在非线性强的系统中,用线性逼近的方法会产生较大的线性化误差从而影响算法精度。2008年, Lee^[9]提出了无迹信息滤波(unscented information filtering, UIF),该算法旨在处理非线性系统的数据融合问题。UIF引入无迹变换,通过一组特殊选择的 Sigma 点来近似非线性变换,从而更准确地反映真实的非线性关系。这种方法避免了传统线性化带来的误差,使得滤波结果更加准确可靠。交互多模型(interactive multiple model, IMM)是无人机跟踪目标最常用的多模型算法之一,它是针对无人机跟踪目标而设计的多模型算法,通过动态地选择合适的运动模型以提高目标跟踪的准确性^[10-11]。2018年,欧阳泽方等^[12]将 UIF 算法与 IMM 算法结合,对弹道导弹助推段进行了目标状态估计,通过对比不同算法验证了 IMM-UIF 算法的优势,其避免了线性化误差且滤波效果更好。

本文结合了 UIF 和 IMM 各自的优势,提出了一种多无人机分布式协同目标运动状态估计算法,旨在最小化估计误差。这一算法的主要目标是通过充分利用 UIF 的非线性系统处理能力和 IMM 的多模型自适应性,融合来自多个无人机上的观测信息,实现对目标运动状态的准确估计。本算法考虑实际跟踪的应用场景并进行建模,实现了对二维地面机动目标的跟踪,并将其与单架无人机的交互多模型卡尔曼滤波(IMM-KF)、交互多模型粒子滤波(interactive multiple model-particle filter, IMM-PF)及 IMM-UIF 算法进行比较,验证了该算法的快速性和准确性。

1 问题描述

1.1 模型建立

1.1.1 系统模型

假设机动目标在二维平面内运动,量测信息来自空中 2 架无人机的单目摄像头,目标跟踪系统所使用的目标运动模型如下

$$\begin{cases} \mathbf{X}(k+1) = f(\mathbf{x}(k), \mathbf{W}(k)) \\ \mathbf{Z}_1(k) = h_1(\mathbf{x}(k), \mathbf{V}_1(k)) \\ \mathbf{Z}_2(k) = h_2(\mathbf{x}(k), \mathbf{V}_2(k)) \end{cases} \quad (1)$$

式中, $\mathbf{X} = [x, \dot{x}, y, \dot{y}]^T$ 为目标在 x, y 方向上的位置和速度; f 为非线性状态方程函数; $\mathbf{Z}_1(k)$ 和 $\mathbf{Z}_2(k)$ 分别为摄像头 1 和摄像头 2 在 k 时刻的量测信息; h_1 和 h_2 分别为 2 个传感器的非线性观测方程函数; \mathbf{W} 为系统过程噪声; \mathbf{V}_1 和 \mathbf{V}_2 分别为 \mathbf{Z}_1 和 \mathbf{Z}_2 的量测噪声,且假定都是独立的高斯白噪声,协方差分别为 $\mathbf{Q}, \mathbf{R}_1, \mathbf{R}_2$ 。

1.1.2 目标机动模型

假定传感器站点的每个局部滤波器使用由匀速直线运动(CV)模型和匀速转弯(CT)模型组成的 IMM^[13]。

则 CV 模型为

$$\mathbf{X}(k+1) = \mathbf{A}\mathbf{X}(k) + \mathbf{G}\mathbf{v}(k) \quad (2)$$

式中, $\mathbf{X}(k) = [x(k) \quad v_x(k) \quad y(k) \quad v_y(k)]^T$ 为系统在 k 时刻的状态向量; $x(k)$ 为 k 时刻目标在 x 轴方向的位置; $v_x(k)$ 为 k 时刻目标在 x 轴方向的速度; $y(k)$ 为 k 时刻目标在 y 轴方向的位置; $v_y(k)$ 为 k 时刻目标在 y 轴方向的速度; $\mathbf{v}(k)$ 为过程噪声,即目标在运动过程中受到的随机加速度扰动。矩阵 \mathbf{A} 和 \mathbf{G} 分别为状态转移矩阵和噪声输入矩阵,分别为

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{G} = \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix} \quad (3)$$

式中, T 为系统的采样时间。


CT 模型为

$$\mathbf{X}(k+1) = \mathbf{A}_\omega \mathbf{X}(k) + \mathbf{G}\mathbf{v}(k) \quad (4)$$

式中, $\mathbf{X}(k)$ 为 k 时刻目标的状态向量; \mathbf{A}_ω 为 k 时刻的状态转移矩阵; \mathbf{G} 为输入噪声矩阵; $\mathbf{v}(k)$ 为零均值的高斯白噪声。目标的状态向量 $\mathbf{X}(k)$ 、过程噪

声 $\mathbf{v}(k)$ 、噪声转移矩阵 \mathbf{G} 均与 CV 模型一样, 状态转移矩阵 \mathbf{A}_ω 为

$$\mathbf{A}_\omega = \begin{bmatrix} 1 & \frac{\sin\omega T}{\omega} & 0 & -\frac{1-\cos\omega T}{\omega} \\ 0 & \cos\omega T & 0 & -\sin\omega T \\ 0 & \frac{1-\cos\omega T}{\omega} & 1 & \frac{\sin\omega T}{\omega} \\ 0 & \sin\omega T & 0 & \cos\omega T \end{bmatrix} \quad (5)$$



式中, ω 表示转弯速率, 如果 ω 为常数, 该模型表示匀速转弯的线性模型, 所以在使用该模型时需要对其进行转弯的目标运动情况有一定的先验信息。

1.1.3 目标观测模型

目标跟踪如图 1 所示, 2 架无人机处在不同高度上协同跟踪地面机动目标。

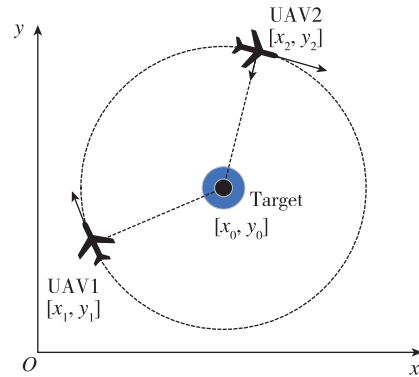


图 1 目标跟踪示意图

Fig. 1 Target tracking diagram

假设 2 架无人机均搭载了单目摄像头作为测量传感器, 以无人机起飞点为坐标原点 $[0, 0]$, 摄像头在 k 时刻采集到的目标位置经一系列坐标变换后为 $[x_0(k), y_0(k)]$, 无人机位置由 GPS 模块实时提供, 2 架无人机位置为

$$\text{UAV}_1(k) = [x_1(k), y_1(k)]^T$$

$$\text{UAV}_2(k) = [x_2(k), y_2(k)]^T$$

测量测方程为^[14]

$$\mathbf{Z}_1(k) = \arctan\left(\frac{y_0(k) - y_1(k)}{x_0(k) - x_1(k)}\right) + \mathbf{V}_1(k)$$

$$\mathbf{Z}_2(k) = \arctan\left(\frac{y_0(k) - y_2(k)}{x_0(k) - x_2(k)}\right) + \mathbf{V}_2(k) \quad (6)$$

1.2 跟踪策略

无人机跟踪目标时, 可以采用多种轨迹策略实现有效的追踪。主要有:

1) 直线轨迹: 无人机可以选择直线轨迹, 沿着目标所在的直线路径进行跟踪。这种轨迹常用于跟踪目标在平直区域运动的情况, 如追踪行驶中的车辆或船只。

2) 圆周轨迹: 无人机可以选择绕目标做圆周运动, 保持相对于目标的固定距离和角度。这种轨迹适用于围绕目标进行环绕观察的场景, 如拍摄航拍视频或监测目标周围的环境。

3) 螺旋轨迹: 无人机可以选择螺旋上升或下降的轨迹, 绕着目标以螺旋形式运动。这种轨迹适用于对目标进行逐渐靠近或离开的操作, 如在搜索和救援任务中。

4) 自适应轨迹: 自适应轨迹是根据目标的运动模式和环境条件实时调整的轨迹。无人机可以根据目标的速度、方向和加速度等信息, 动态调整飞行轨迹, 以实现更精确和稳定的跟踪。

由于地面目标做无规则运动, 本文采用圆周轨迹跟踪地面目标, 多无人机协同以圆周轨迹跟踪目标为合围攻击奠定了基础。

2 IMM-UIF 算法设计

2.1 UIF

无迹卡尔曼滤波 (unscented Kalman filter, UKF) 主要通过状态估计和协方差矩阵实现系统状态估计。信息滤波则使用信息状态和 Fisher 信息代替状态估计和协方差矩阵, 可以看作是卡尔曼滤波的对偶形式^[15]。通过将 IMM 无迹卡尔曼滤波扩展到信息滤波的形式, 即 IMM-UIF, 可以更容易地将局部滤波器扩展到后续的多传感器融合估计中, 以提高系统的整体性能。

将信息状态与 Fisher 信息 \mathbf{Y} 代替状态估计与

协方差 \mathbf{P} , 可得卡尔曼滤波的信息形式, 通常称为信息滤波。 \mathbf{Y} 与定义如下^[16]

$$\begin{aligned} \mathbf{Y}[i|j] &= \mathbf{P}^{-1}[i|j] \\ \hat{\mathbf{y}}[i|j] &= \mathbf{P}^{-1}[i|j]\hat{\mathbf{x}}[i|j] \end{aligned} \quad (7)$$

对于离散时刻 k 的观测 $\mathbf{z}[k]$, 其对应信息状态 $\hat{\mathbf{y}}$ 的贡献 $\mathbf{i}[k]$ 及对 Fisher 信息 \mathbf{Y} 的贡献 $\mathbf{I}[k]$ 为

$$\begin{aligned} \mathbf{I}[k] &= \mathbf{H}^T[k]\mathbf{R}^{-1}[k]\mathbf{H}[k] \\ \mathbf{i}[k] &= \mathbf{H}^T[k]\mathbf{R}^{-1}[k]\mathbf{z}[k] \end{aligned} \quad (8)$$

对于信息滤波来说, 可以通过递归计算 Fisher 信息和信息状态矩阵, 实现系统的预测步和更新步^[17]。对于如下线性状态空间模型

$$\begin{aligned} \mathbf{x}[k] &= \mathbf{A}[k-1]\mathbf{x}[k-1] + \mathbf{q}[k-1] \\ \mathbf{z}[k] &= \mathbf{H}[k]\mathbf{x}[k] + \mathbf{r}[k] \end{aligned} \quad (9)$$

其中, $\mathbf{x}[k] \in \mathbf{R}^n$ 表示 k 时刻系统状态; $\mathbf{z}[k] \in \mathbf{R}^m$ 表示 k 时刻预测的观测量; $\mathbf{q}[k] \sim N(0, \mathbf{Q}[k])$ 表示 k 时刻过程噪声; $\mathbf{r}[k] \sim N(0, \mathbf{R}[k])$ 表示 k 时刻测量噪声; $\mathbf{A}[k]$ 为动态模型状态转移矩阵; $\mathbf{H}[k]$ 为测量模型矩阵。状态的预先分布 $\bar{\mathbf{x}}[0], \mathbf{P}[0]$, $\mathbf{x}[0] \sim N(\bar{\mathbf{x}}[0], \mathbf{P}[0])$ 为已知信息。离散时间卡尔曼滤波对应 IF 如下。

预测步 (IF_p):

$$\begin{aligned} \mathbf{Y}[k]^- &= \{\mathbf{A}[k-1]\mathbf{Y}^{-1}[k-1]\mathbf{A}^T[k-1] + \\ &\quad \mathbf{Q}[k-1]\}^{-1} \\ \hat{\mathbf{y}}[k]^- &= \mathbf{Y}[k]^- \mathbf{A}[k-1]\mathbf{Y}^{-1}[k-1]\hat{\mathbf{y}}[k-1] \end{aligned} \quad (10)$$

更新步 (IF_u):

$$\begin{aligned} \mathbf{I}[k] &= \mathbf{H}^T[k]\mathbf{R}^{-1}[k]\mathbf{H}[k] \\ \mathbf{i}[k] &= \mathbf{H}^T[k]\mathbf{R}^{-1}[k]\mathbf{z}[k] \\ \mathbf{Y}[k] &= \mathbf{Y}[k]^- + \mathbf{I}[k] \\ \hat{\mathbf{y}}[k] &= \hat{\mathbf{y}}[k]^- + \mathbf{i}[k] \end{aligned} \quad (11)$$

其中, $\hat{\mathbf{y}}[k]^-$ 与 $\mathbf{Y}[k]^-$ 对应 $\hat{\mathbf{y}}[k|k-1]$ 与 $\mathbf{Y}[k|k-1]$; $\hat{\mathbf{y}}[k]$ 与 $\mathbf{Y}[k]$ 对应 $\hat{\mathbf{y}}[k|k]$ 与 $\mathbf{Y}[k|k]$ 。给定初始条件 $\hat{\mathbf{x}}[0]$ 与 $\mathbf{P}[0]$, 有 $\mathbf{Y}[0] = \mathbf{P}^{-1}[0]$, $\hat{\mathbf{y}}[0] = \mathbf{P}^{-1}[0]\hat{\mathbf{x}}[0]$ 。

对于无迹变换, UIF 预测等式可以写为

$$\mathbf{Y}[k]^- = (\mathbf{P}[k]^-)^{-1}$$

$$\hat{\mathbf{y}}[k]^- = \mathbf{Y}[k]^- \sum_{i=0}^{2n} \mathbf{W}_m^i \mathbf{x}^i[k]^- \quad (12)$$

式中, \mathbf{W}_m^i 表示第 i 个 sigma 点的权值。

对 Fisher 信息与信息状态收益 $\mathbf{I}[k], \mathbf{i}[k]$ 变换为

$$\begin{aligned} \mathbf{I}[k] &= (\mathbf{P}[k]^-)^{-1} \mathbf{P}^{x,z}[k]^- \mathbf{R}^{-1}[k] (\mathbf{P}^{x,z}[k]^-)^T (\mathbf{P}[k]^-)^{-T} \\ \mathbf{i}[k] &= (\mathbf{P}[k]^-)^{-1} \mathbf{P}^{x,z}[k]^- \mathbf{R}^{-1}[k] \{ \mathbf{v}[k] + \\ &\quad (\mathbf{P}^{x,z}[k]^-)^T (\mathbf{P}[k]^-)^{-T} \hat{\mathbf{x}}[k]^- \} \end{aligned} \quad (13)$$

其中, $\mathbf{v}[k] = \tilde{\mathbf{z}}_k - h(\hat{\mathbf{x}}_{k|k-1}, k)$, 可以看出, 上述信息与信息状态收益计算不再与测量方程直接相关。后验状态估计可得

$$\hat{\mathbf{x}}[k] = \mathbf{Y}^{-1}[k]\hat{\mathbf{y}}[k] \quad (14)$$

2.2 基于 IMM 的 UIF 算法

IMM 算法的基本思想是通过混合多个滤波器的估计实现对目标状态的估计。IMM 算法的流程如图 2 所示, 在每个时刻, IMM 算法假设当前时刻存在某个有效模型, 并根据前一时刻所有滤波器的状态估计值来确定与这个特定模型匹配的滤波器的初始条件, 然后以并行的方式对每个模型执行正规滤波的预测和修正步骤。最后, IMM 算法根据模型匹配的似然函数更新每个模型的概率, 并将修正后的状态估计值按照一定的权重进行组合, 最终得到状态估计^[16]。

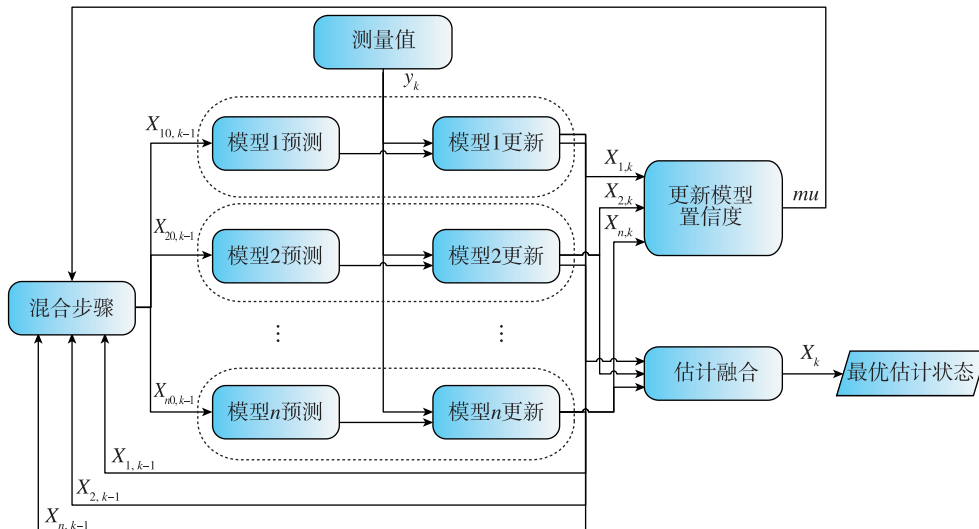


图 2 IMM 算法流程图

Fig. 2 Flow chart of IMM algorithm

IMM 算法是以递推方式进行的,假设目标有 r 种运动状态,对应有 r 个运动模型,每次递推主要有以下 4 个步骤。

步骤 1:输入交互(以模型 j 为例)。

模型 j 的预测概率(归一化常数)为

$$\bar{c}_j = \sum_{i=1}^r p_{ij} \mu_i(k-1) \quad (15)$$

其中, p_{ij} 表示在下一时刻从模型 i 到模型 j 的切换概率; $\mu_i(k-1)$ 表示模型 i 在 $k-1$ 时刻的概率。

模型 i 到模型 j 的混合概率为

$$\mu_{ij}(k-1|k-1) = \sum_{i=1}^r p_{ij} \mu_i(k-1) / \bar{c}_j \quad (16)$$

模型 j 的混合状态估计为

$$\hat{\mathbf{X}}_{0j}(k-1|k-1) = \sum_{i=1}^r \hat{\mathbf{X}}_i(k-1|k-1) \mu_{ij}(k-1|k-1) \quad (17)$$

模型 j 的混合协方差估计为

$$\begin{aligned} \mathbf{P}_{0j}(k-1|k-1) = & \sum_{i=1}^r \mu_{ij}(k-1|k-1) \{ \mathbf{P}_i(k-1|k-1) + \\ & [\hat{\mathbf{X}}_i(k-1|k-1) - \hat{\mathbf{X}}_{0j}(k-1|k-1)] \cdot \\ & [\hat{\mathbf{X}}_i(k-1|k-1) - \hat{\mathbf{X}}_{0j}(k-1|k-1)]^T \} \quad (18) \end{aligned}$$

步骤 2: r 个模型并行滤波(以模型 j 为例)。

以 $\hat{\mathbf{X}}_{0j}(k-1|k-1)$, $\mathbf{P}_{0j}(k-1|k-1)$ 及 $\mathbf{Z}(k)$ 作为输入进行卡尔曼滤波或粒子滤波,以更新预测状态 $\hat{\mathbf{X}}_j(k|k)$ 和滤波协方差 $\mathbf{P}_j(k|k)$ [18]。

步骤 3:模型概率更新。

采用似然函数更新模型概率 $\mu_j(k)$,模型 j 的似然函数为

$$\Lambda_j(k) = \frac{1}{(2\pi)^{n/2} |\mathbf{S}_j(k)|^{1/2}} \exp\left\{-\frac{1}{2} \mathbf{v}_j^T \mathbf{S}_j^{-1}(k) \mathbf{v}_j\right\} \quad (19)$$

式中

$$\mathbf{v}_j(k) = \mathbf{Z}(k) - \mathbf{H}(k) \hat{\mathbf{X}}_j(k|k-1)$$

$$\mathbf{S}_j(k) = \mathbf{H}(k) \mathbf{P}_j(k|k-1) \mathbf{H}^T(k) + \mathbf{R}(k) \quad (20)$$

则模型 j 的概率为

$$\mu_j(k) = \Lambda_j(k) \bar{c}_j / c \quad (21)$$

式中, c 为归一化常数,且 $c = \sum_{j=1}^r \Lambda_j(k) \bar{c}_j$ 。

步骤 4:输出交互。

根据模型概率,对每个滤波器的估计结果加权合并,得到总的信息状态 $\hat{\mathbf{y}}[k|k]$ 和总的 Fisher 信息矩阵 $\mathbf{Y}[k|k]$ 为 [19]

$$\hat{\mathbf{y}}(k|k) = \sum_{j=1}^r \hat{\mathbf{y}}_j(k|k) \mu_j(k) \quad (22)$$

$$\begin{aligned} \mathbf{Y}(k|k) = & \sum_{j=1}^r \mu_j(k) \{ \mathbf{Y}_j(k|k)^T + \\ & [\hat{\mathbf{y}}_j(k|k) - \hat{\mathbf{y}}(k|k)] [\hat{\mathbf{y}}_j(k|k) - \\ & \hat{\mathbf{y}}(k|k)] \} \quad (23) \end{aligned}$$

式(22)作为下一时刻滤波输入,从而实现递推滤波。

2.3 基于 IMM-UIF 的分布式融合估计结构

多无人机分布式协同目标跟踪方法的整体结构如图 3 所示。

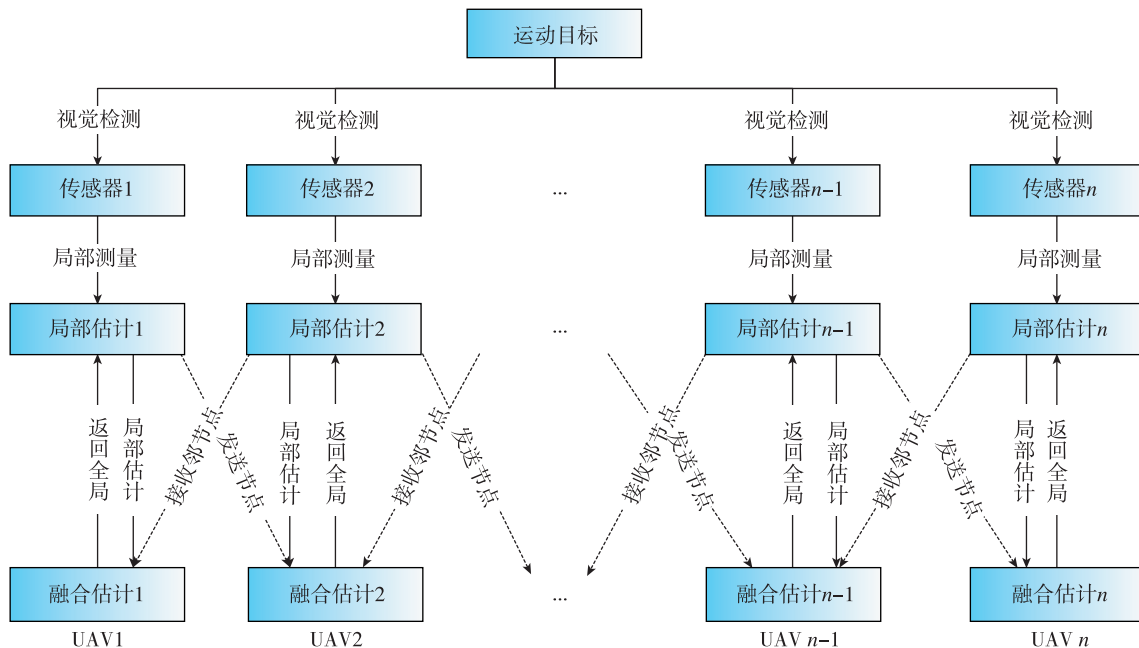


图 3 多无人机分布式协同目标运动状态估计结构

Fig. 3 Multi-UAV distributed cooperative target motion state estimation structure

在传感器观测信息相互独立的假设下,可以推导出信息滤波的累积观测融合方程。对于图3所示的融合结构,无人机数量为 n ,则目标状态的融合估计可以表示为^[20]

$$\begin{aligned} \mathbf{Y}[k] &= \mathbf{Y}[k]^- + \sum_{i=1}^n \mathbf{I}_i[k] \\ \hat{\mathbf{y}}[k] &= \hat{\mathbf{y}}[k]^- + \sum_{i=1}^n \mathbf{i}_i[k] \end{aligned} \quad (24)$$

每架无人机的机载处理器上都搭载了上述局部估计滤波器 IMM-UIF 和融合估计滤波器。在分布式结构中,每架无人机同时充当局部估计节点和融合中心的角色。计算融合估计的信息增益,是将各个模型中通过 UIF 后获得的局部信息收益联合起来,获得多模型情况下的信息增益。计算等式如下

$$\begin{aligned} \mathbf{I}[k] &= \sum_{i=1}^r \mu^i[k] \mathbf{I}^i[k] \\ \mathbf{i}[k] &= \sum_{i=1}^r \mu^i[k] \mathbf{i}^i[k] \end{aligned} \quad (25)$$

3 仿真分析

3.1 仿真场景描述

为了验证基于 IMM-UIF 的融合估计算法在协同跟踪任务中的有效性,仿真实验对比了 IMM-KF, IMM-PF, IMM-UIF 和基于 IMM-UIF 的融合算法。目标轨迹设定如表1所示,速度及角速度单位分别为 m/s 和 rad/s。


表1 目标轨迹设定表

Tab. 1 Target trajectory setting table


时间/s	运动模型	运动参数设定
0~60	CV	$v_x = 10, v_y = 0$
61~105	CT	$\omega = \pi/30$
106~180	CV	$v_{x(t=105)}, v_{y(t=105)}$
181~240	CT	$\omega = -\pi/40$
241~300	CV	$v_{x(t=240)}, v_{y(t=240)}$

设定采样周期为 1 s,蒙特卡罗仿真次数为 100 次,观测方位角的量测误差均为高斯白噪声对应标准差 $R = 0.1 * \pi/180$ 。设定无人机以目标为圆心做环绕跟踪,1号无人机与2号无人机协同跟踪目标,1号无人机在目标上方定高为 7 m,绕飞半径为 50 m,角速率为 $\frac{\pi}{5}$ rad/s。2号无人机在目标上方定

高为 4 m,绕飞半径为 50 m,角速率为 $-\frac{\pi}{5}$ rad/s。为对比融合算法的精度。设定 3 号无人机进行单机跟踪,在单机上分别进行 IMM-KF, IMM-PF, IMM-UIF 的仿真,定高为 10 m,绕飞半径为 50 m,角速率为 $\frac{\pi}{5}$ rad/s。图4为无人机与地面目标运动轨迹的俯视图与三维视图。



(a) 俯视图



(b) 三维视图

图4 无人机与目标运动轨迹图


Fig. 4 UAVs and target movement trajectory

3.2 仿真结果分析


3.2.1 单机滤波与 IMM-UIF 融合仿真分析

图5为目标真实轨迹及4种算法下的跟踪轨迹,可以看出4种算法都能实现对目标跟踪的基本需求,而由局部放大图可以看出双机融合后的跟踪轨迹更靠近真值。

图6为位置误差均值对比和位置误差均方差对比,由图6(a)可以得出双机融合状态估计的位置误差最小,单机跟踪中 IMM-KF 的位置误差最大。根据图6(b)可以看出单机跟踪的 IMM-PF 算法误差标准差最小,其次是双机融合的 IMM-UIF 算法。




(a) 目标跟踪轨迹图



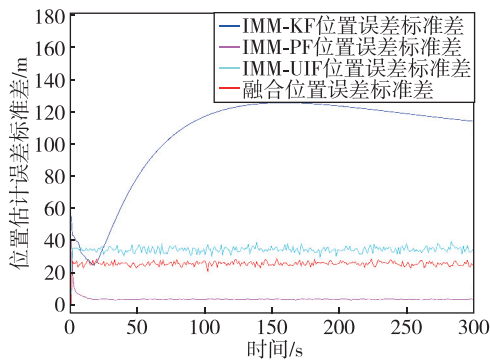
(b) 局部放大图

图 5 目标跟踪轨迹图

Fig. 5 Target tracking trajectory diagram



(a) 位置估计误差均值




(b) 位置估计误差标准差

图 6 4 种算法位置估计误差对比图


Fig. 6 Comparison of estimation error values of four algorithms in position estimation

此外,图 7 和图 8 分别为速度估计曲线及速度估计误差均值。在速度估计精度方面,双机融合后的效果更具优势。

表 2 为 4 种算法的误差对比及蒙特卡罗仿真次数为 100 时的运行时间对比,从表中可以看出,在相同仿真条件下,单架无人机的 IMM-KF 算法位置及速度估计误差最大,而单架无人机的 IMM-PF 算法尽管误差很小,但运行时间最长,且对于粒子群的计算也需要大量内存空间。




(a) x 方向速度估计




(b) y 方向速度估计

图 7 4 种算法速度估计曲线

Fig. 7 Four algorithms speed estimation curves



(a) x 方向速度估计误差均值



(b) y 方向速度估计误差均值

图 8 4 种算法速度估计误差曲线

Fig. 8 Four algorithms speed estimation error curves

表 2 4 种算法的精度和运行时间对比

Tab. 2 Comparison of accuracy and running time of four algorithms

算法	位置误差 均值/m	位置误差 标准差/m	速度误差 均值/(m/s)	运行时间/s
IMM-KF	640.686 5	105.231 6	4.718 1	2.526 1
IMM-PF	3.656 2	3.971 7	0.139 3	99.121 7
IMM-UIF	3.094 0	34.160 6	0.105 5	5.250 2
基于 IMM-UIF 的 双机融合估计	2.367 2	25.488 5	0.102 0	10.419 6

如表 3 所示,4 种算法随着蒙特卡罗仿真次数的逐步增加,位置估计误差均值逐渐递减,IMM-PF,IMM-UIF 及 IMM-UIF 融合算法的位置估计误差均值最终稳定在 0~2 m 左右。且基于 IMM-UIF 的融合估计误差较单机 IMM-UIF 算法降低了约 30%,当仿真次数最高为 500 时,融合算法的位置估计误差均值最小。

表 3 不同蒙特卡罗仿真次数下 4 种算法位置估计误差均值对比

Tab. 3 The comparison of position estimation error mean values of four different algorithms under varying Monte Carlo simulation iterations

算法	仿真次数				
	10	50	100	200	500
单机 IMM-KF	678.699 9	662.197 6	640.686 5	640.716 2	638.015 6
单机 IMM-PF	4.987 1	4.125 6	3.656 2	2.809 5	2.649 7
单机 IMM-UIF	9.906 6	4.313 1	3.094 0	2.157 9	1.414 6
基于 IMM-UIF 的双机融 合估计	6.907 0	3.214 8	2.367 2	1.629 5	1.122 7


综上所述,2 架无人机跟踪融合估计的位置误差比单架无人机估计的位置误差小,相对于单一无人机跟踪系统,多无人机系统具备更大的优势,因为它能够处理更为丰富的测量结果。通过多个无人机协同工作,系统能够从多个视角获取数据,从而更加全面地分析环境信息。这种多视角的数据融合不仅有助于提高跟踪的精度,还在一定程度上降低了来自噪声和外部干扰的误差所带来的影响。

3.2.2 多机融合算法仿真分析


为了验证算法在多机运行下的表现,将 IMM-KF 及 IMM-PF 算法同时运用到多机,并通过权重融合方法对数据进行解算。设置蒙特卡罗仿真次数为 100,多机下的 3 种算法表现如图 9~图 12 所示。

由图 9 可以看出,3 种融合算法中 IMM-KF 在这种非线性系统中并不能很好地实现跟踪,而 IMM-PF 融合精度更高。同时,通过图 10~图 12 可以看出,IMM-PF 融合后的速度估计误差也更小。

根据仿真结果并结合表 4 对比可知,IMM-PF 算法的误差标准差最小,且跟踪曲线更为平滑,但




(a) 目标跟踪轨迹图



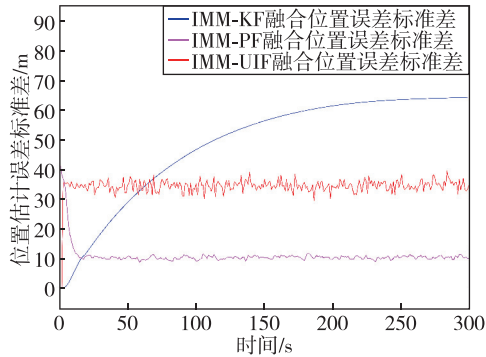
(b) 局部放大图

图 9 多机融合下的 3 种算法跟踪效果

Fig. 9 Tracking effects of three algorithms under multi-UAV fusion




(a) 位置估计误差均值




(b) 位置估计误差标准差

图 10 3 种算法位置估计误差对比图

Fig. 10 Comparison of estimation error values of three algorithms in position estimation




(a) x 方向速度估计




(b) y 方向速度估计

图 11 3 种算法速度估计曲线

Fig. 11 Three algorithms speed estimation curves



(a) x 方向速度估计误差均值



(b) y 方向速度估计误差均值

图 12 3 种算法速度估计误差曲线

Fig. 12 Three algorithms speed estimation error curves

其运算时间过长,内存占用更大,在实际工程应用中对处理器的要求更高,因此 IMM-UIF 融合算法不论在精度还是运算时间上更具优势。

表 4 3 种融合算法的精度和运行时间对比

Tab. 4 Comparison of accuracy and running time of three fusion algorithms

算法	位置误差 均值/m	位置误差 标准差/m	速度误差 均值/(m/s)	运行时间/s
IMM-KF 融合	442.314 6	46.940 8	1.765 8	5.124 7
IMM-PF 融合	3.656 2	10.962 1	0.525 5	267.507
IMM-UIF 融合	2.367 2	25.488 5	0.102 0	10.419 6

4 结论

针对非线性条件下单架无人机跟踪机动目标时产生较大误差的问题,本文详细结合了实际二维机动目标的运动模型,提出了一种融合 IMM 结构和 UIF 的 IMM-UIF 算法。得到如下结论:

1)通过仿真分析可以看出,基于 IMM-UIF 的分布式融合估计算法对比单架无人机跟踪系统有着很好的滤波精度,位置估计误差均值降低了约 30%,保证了对目标的状态估计,满足指标要求。

2)构建了 IMM 算法的模型集合,其中包括具有不同过程噪声矩阵的 CT 和 CV 模型,同时引入无迹变换方法,量测子系统采用 UIF,与传统的 EKF 和卡尔曼滤波相比,避免了雅克比矩阵的计算以及因忽略高阶项所带来的误差。

3)在信息滤波框架下,引入了一种中心节点叠加求和的融合计算形式,通过这一独特的方法,计算的过程变得十分简洁而高效。这种计算形式不仅为系统中无人机的平稳加入和退出提供了便捷的途径,还为未来系统的可扩展性奠定了坚实基础,尤其是在考虑将其应用于分布式融合估计结构时,这种方法的灵活性和适应性使得系统能够随着需求的变化而迅速调整,从而更好地满足不断演变的应用场景和技术要求。

参考文献

- [1] CHUNG S J, PARANJAPE A A, DAMES P, et al. A survey on aerial swarm robotics[J]. *IEEE Transactions on Robotics*, 2018, 34(4): 1-19.
- [2] MARAGOS P, SCHAFER R. Morphological filters-part II: their relations to median, order-statistic, and stack filters[J]. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 1987, 35(8): 1170-1184.
- [3] LU M B, LIU L. Leader-following consensus of second-order nonlinear multi-agent systems subject to disturbances[J]. *Frontiers of Information Technology & Electronic Engineering*, 2019, 20(1): 88-94.
- [4] BANOS O, DAMAS M, GUILLEN A, et al. Multi-sensor fusion based on asymmetric decision weighting for robust activity recognition[J]. *Neural Process Letters*, 2015, 42(1): 5-26.
- [5] 杨春, 郭健, 张磊, 等. 采用无迹信息滤波的多传感器容错融合算法[J]. *南京理工大学学报*, 2017, 41(3): 269-277.
YANG Chun, GUO Jian, ZHANG Lei, et al. Multi-sensor fault-tolerant fusion algorithm using unscented information filter[J]. *Journal of Nanjing University of Science and Technology*, 2017, 41(3): 269-277(in Chinese).
- [6] 孙宁, 秦洪懋, 张利, 等. 基于多传感器信息融合的车辆目标识别方法[J]. *汽车工程*, 2017, 39(11): 1310-1315.
SUN Ning, QIN Hongmao, ZHANG Li, et al. Vehicle target recognition based on multi-sensor information fusion [J]. *Automotive Engineering*, 2017, 39(11): 1310-1315 (in Chinese).
- [7] SAFARI S, SHABANI F, SIMON D. Multirate multi-sensor data fusion for linear systems using Kalman filters and a neural network[J]. *Aerospace Science & Technology*, 2014, 39: 465-471.
- [8] SASAOKA T, KIMOTO I, KISHIMOTO Y, et al. Multi-robot SLAM via information fusion extended Kalman filters[J]. *IFAC-PapersOnLine*, 2016, 49(22): 303-308.
- [9] LEE D J. Nonlinear estimation and multiple sensor fusion using unscented information filtering[J]. *IEEE Signal Processing Letters*, 2008, 15(1): 861-864.
- [10] 李辉, 沈莹, 张安, 等. 交互式多模型目标跟踪的研究现状及发展趋势[J]. *火力与指挥控制*, 2006, 31(11): 1-4.
LI Hui, SHEN Ying, ZHANG An, et al. The status quo and trend of target tracking based on interactive multiple model[J]. *Fire Control and Command Control*, 2006, 31(11): 1-4(in Chinese).
- [11] 周卫东, 刘萌萌, 杨永江. 基于多传感器信息融合理论的交互式多模型算法[J]. *华南理工大学学报(自然科学版)*, 2014, 42(9): 82-89.
ZHOU Weidong, LIU Mengmeng, YANG Yongjiang. An improved interacting multiple model algorithm based on multi-sensor information fusion theory[J]. *Journal of South China University of Technology (Natural Science Edition)*, 2014, 42(9): 82-89(in Chinese).
- [12] 欧阳泽方, 王小平, 吴昊, 等. 机动目标跟踪的 IMM 无迹信息滤波方法[J]. *压电与声光*, 2018, 40(5): 674-679+683.
OUYANG Zefang, WANG Xiaoping, WU Hao, et al. IMM unscented information filtering method for maneuvering target tracking[J]. *Piezoelectrics & Acoustooptics*, 2018, 40(5): 674-679+683(in Chinese).
- [13] DEGHAT M, XIA L, ANDERSON B D O, et al. Multi-target localization and circumnavigation by a single agent using bearing measurements[J]. *International Journal of Robust & Nonlinear Control*, 2015, 25(14): 2362-2374.
- [14] CHU X, LIANG Z, LI Y. Trajectory optimization for rendezvous with bearing-only tracking[J]. *Acta Astronautica*, 2020, 171: 311-322.
- [15] 卢晨, 刘正. 无迹信息滤波耦合交互式多模型的多传感器机器人轨迹控制[J]. *中国工程机械学报*, 2018, 16(6): 544-549.

- LU Chen, LIU Zheng. Trajectory control of multi-sensor robot by unscented information filtering and interacting multiple models[J]. Chinese Journal of Construction Machinery, 2018, 16(6): 544-549 (in Chinese).
- [16] 王林. 多无人机协同目标跟踪问题建模与优化技术研究[D]. 长沙: 国防科学技术大学, 2012.
- WANG Lin. Modeling and optimization for multi-UAVs cooperative target tracking[D]. Changsha: National University of Defense Technology, 2012 (in Chinese).
- [17] 竹博. AR 预测模型的 IMM 跟踪算法[J]. 计算机工程与应用, 2014, 50(24): 222-226.
- ZHU Bo. AR prediction model based IMM tracking algorithm[J]. Computer Engineering and Applications, 2014, 50(24): 222-226 (in Chinese).
- [18] 王林. 一种面向多无人机协同感知的分布式融合估计方法[J]. 控制与决策, 2010, 25(6): 814-820.
- WANG Lin. Distributed fusion estimation algorithm for multi-UAVs cooperative sensing[J]. Control and Decision, 2010, 25(6): 814-820 (in Chinese).
- [19] 王尔申, 翟秋刚, 徐嵩, 等. 基于改进交互式多模型算法的 ADS-B 航迹滤波方法研究[J]. 电光与控制, 2019, 26(4): 71-76.
- WANG Ershen, ZHAI Qiugang, XU Song, et al. An ADS-B track filtering method based on improved interactive multi-model algorithm [J]. Electronics Optics & Control, 2019, 26(4): 71-76 (in Chinese).
- [20] 赵宏宇. 分布式扩散无迹卡尔曼滤波研究[D]. 重庆: 西南大学, 2023.
- ZHAO Hongyu. Research on distributed diffusion unscented Kalman filter[D]. Chongqing: Southwest University, 2023 (in Chinese).

(编辑: 黄利华)