

DOI: 10.19650/j.cnki.cjsi.J2312280

基于改进 ESKF 的植保无人机时延位姿补偿算法^{*}

刘 慧,施志翔,沈亚运,储金城,沈 跃
(江苏大学电气信息工程学院 镇江 212013)

摘 要:为解决全球导航卫星系统和惯性测量单元融合时间不同步问题,提高植保无人机位姿估计精度,本文根据植保无人机大惯性、强振动的特性提出一种基于改进误差状态卡尔曼的时延位姿补偿算法。首先对名义状态变量线性预测,引入渐消因子提高强振动环境下的系统稳定性;接着采用互补滤波对角速度补偿,对姿态误差状态变量修正;最后结合测量的延迟时间,使用互补滤波外推数据,提高大惯性特性下的速度位置精度。实验结果表明,相较于误差状态卡尔曼算法,横滚角和俯仰角均方根误差减少 0.266 9°和 0.241 4°,偏航角均方根误差减少 0.076 4°;正常航迹植保作业下,东北天方向速度均方根误差减少 0.210 5、0.184 9、0.238 8 m/s;东北天方向位置均方根误差分别减少 0.21、0.19、0.23 m,有效提高位姿估计精度。

关键词: 植保无人机;误差状态卡尔曼滤波;延时补偿;信息融合;组合导航

中图分类号: TH391.4 TH39 **文献标识码:** A **国家标准学科分类代码:** 520.60

Time delay and attitude compensation algorithm for plant protection UAV based on the improved ESKF

Liu Hui, Shi Zhixiang, Shen Yayun, Chu Jincheng, Shen Yue

(School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: To solve the problem of global navigation satellite systems and inertial measurement unit fusion time asynchronous and improve the accuracy of pose estimation of plant protection UAV, this article proposes a delay pose compensation algorithm based on the improved error state Kalman filter by using the characteristics of large inertia and strong vibration of plant protection UAV. Firstly, the nominal state variables are linearly predicted, and a fading factor is introduced to improve the system stability in strong vibration environments. Then, complementary filtering is used to compensate for diagonal velocity and correct the attitude error state variables. Finally, combined with the delay time measured, complementary filtering is used to extrapolate the data and improve the velocity and position accuracy under high inertia characteristics. Experimental results show that, compared with the error state Kalman filter algorithm, the root mean square error of roll angle and pitch angle is reduced by 0.266 9° and 0.241 4°, and the root mean square error of yaw angle is reduced by 0.076 4°. Under normal track plant protection operation, the root mean square error of velocity in the northeast sky direction values are decreased by 0.210 5, 0.184 9, and 0.238 8 m/s. The root mean square errors of the northeast celestial position are reduced by 0.21, 0.19, and 0.23 m, respectively. The algorithm effectively improves the accuracy of pose estimation.

Keywords: plant protection UAV; error state Kalman filter; delay compensation; information fusion; integrated navigation

0 引 言

随着我国农业航空技术的发展,植保无人机广泛应用在种料播撒^[1]、病害检测^[2]及农药喷洒^[3]等环节,愈发需求高精度的位姿信息以完成复杂的作业任务。受制于成本、体积等因素,植保无人机上的惯性器件常采用微机

电传感器,这类器件输出噪声大,误差模型具有非线性^[4],无法单独使用。因此,植保无人机一般采用全球导航卫星系统(global navigation satellite systems, GNSS)和惯性测量单元(inertial measurement unit, IMU)的组合导航方案^[5]。

相较于传统无人机,植保无人机由于负载过重具有大惯性、强振动^[6]的特点。大惯性的特性需求更加精准的速

度和位置信息用于闭环控制,强振动的特性不利于姿态长时间解算。为获得更高精度的位姿信息,需保证融合信息的数据处于同一时刻。根据 GNSS 接受器设备的不同及处理器性能差异,通常一帧 GNSS 数据时延为 15~95 ms^[7]。在植保无人机爬升、加速等场景,时间异步所带来的误差会影响滤波器的精度,甚至导致滤波器发散^[8]。

针对这一问题,国内外学者对 GNSS 和 IMU 融合的时间延迟进行分析补偿^[9-11]。宏观来说,补偿方法分为硬件方法和软件方法。硬件方法需不同传感器有相应的时间戳,或者传感器与处理器间有双向精准时间协议,如 IEEE1588 协议^[12],但这势必会增加系统的制造成本和复杂程度。软件方法更加依赖于算法本身,基于量测对象的状态特征,设计相适应的时延补偿算法。

卡尔曼滤波因其精度高、速度快等特点,在多传感器信息融合领域得到了广泛应用^[13-14]。各国学者在卡尔曼的融合框架上,设计了不同的时延补偿算法。张涛等^[15]提出一种在 FPGA 上检测 PPS 脉冲信号,从而中断时间同步的组合导航方案,其考虑了高中低 3 种动态情况的延时补偿,但低动态环境下提升不明显。章红平等^[16]采用定时中断与数据缓存对 GNSS 和 IMU 的数据进行机械编排实现时间对准,可满足车载组合导航系统要求。Gamagedara 等^[17]提出使用 IMU 的数据短时预测量测更新到当前时刻,采用误差状态卡尔曼 (error state Kalman filter, ESKF) 融合 GNSS 数据,计算效率得到提高,但实际使用时会因过度收敛导致滤波器精度下降。

上述方法要缓存大量数据或通过 IMU 数据进行多步预测。若采用算法更大的处理器势必会增加无人机的飞行质量与制造成本^[18]。相较于传统 ESKF,本文做了如下改进:针对植保无人机强振动的特性,引入渐消因子避免系统随时间推移整体协方差的过度收敛,对低动态场景姿态使用加速度计补偿;针对植保无人机大惯性的特性,在速度和位置上,采用互补滤波对时延信息进行外推融合补偿,获得当前时刻的伪量测,进而实现融合校准。本文阐述了 GNSS 和 IMU 融合算法与时延位姿补偿算法的实现过程,并通过仿真和实际飞行实验对算法进行验证,最后分析结果表明算法的有效性。

1 IMU/GNSS 组合导航模型

1.1 组合导航整体思路

本文使用改进的 ESKF 融合 IMU 和 GNSS 数据。如图 1 所示,为 IMU/GNSS 组合导航算法的基本框架。IMU 数据判断低动态状态,低动态状态通过加速度计数据对角速度补偿,优化不考虑噪声的线性预测中的姿态求解;使用 GNSS 的姿态数据对姿态误差状态变量修正,实现姿态的最优估计;结合 IMU 的短时最优性,对相对延迟下的 GNSS 数据修正,使用基于互补滤波补偿时间不同步误差,获得当前时间的伪量测;基于量测误差建立速度位置观测方程,实现对速度位置的误差状态变量的修正,最终归入名义状态变量,获得实际状态变量的最优估计。




图 1 组合导航算法基本框架

Fig. 1 Basic framework of integrated navigation

1.2 传感器模型建立

定义坐标系 b 为机体坐标系,原位于机体重心;坐标系 i 与机体固连且与安装位置有关,原位于 GNSS 接收器中心,为 GNSS 传感器坐标系;坐标系 n 为本地东北天(ENU)坐标系,原位于无人机的起始点。 R 表示向量空间,任意的旋转矩阵 $R \in R^{3 \times 3}$ 可通过流形上的三维旋转正交群 $SO(3)$ 来描述:

$$SO(3) = \{R \in R^{3 \times 3} \mid R^T R = I_{3 \times 3}, \det[R] = +1\} \quad (1)$$

将 IMU 测量的三轴加速度信息和角速度信息记为 $a_{\text{IMU}} \in R^3$ 和 $\omega_{\text{IMU}} \in R^3$ 。对于低精度惯导系统,一般有确定性误差和随机游走。假设有高斯白噪声向量 $\varepsilon_a \in R^3$ 和 $\varepsilon_\omega \in R^3$,有零偏向量 $b_a \in R^3$ 和 $b_\omega \in R^3$ 。

IMU 测量的加速度需通过旋转矩阵 $R_b^n \in R^{3 \times 3}$ 将其转于 n 坐标系下,考虑到重力加速度 $g \in R^3$, n 坐标系下的加速度 $\dot{v} \in R^3$ 可表示为:

$$\dot{v} = R_b^n(a_{\text{IMU}} - b_a + \varepsilon_a) + g \quad (2)$$

在 b 坐标系下的真实角速度 $\omega^l \in R^3$ 为:

$$\omega^l = \omega_{\text{IMU}} - b_\omega + \varepsilon_\omega \quad (3)$$

如图 2 所示,IMU 和 GNSS 两类传感器时间滞后并不相同,GNSS 传感器的时间滞后较长。以 IMU 到达时序为基准,会产生一定的相对延迟时间为 T_d 。




图2 量测时序图

Fig. 2 Timing diagram of measurements

假设 t_d 时刻 GNSS 测量的位置、速度、姿态信息为 $x_{\text{GNSS}} \in R^3$, $v_{\text{GNSS}} \in R^3$, $R_{\text{GNSS}} \in R^{3 \times 3}$, 和 IMU 数据一起到达中心处理器的时间为 t_k , 且满足 $t_{k-1} \leq t_d < t_k, k > 1$ 。

引入观测噪声 $s_x \in R^3$, $s_v \in R^3$ 和 $s_R \in R^3$, $\hat{s}_R$ 表示 s_R 的反对称矩阵, t_k 时刻的位置 $x' \in R^3$ 、速度 $v' \in R^3$ 、姿态 $R' \in R^{3 \times 3}$ 可表示为:

$$x'_{(k)} = x_{\text{GNSS}(d)} + s_x \quad (4)$$

$$v'_{(k)} = v_{\text{GNSS}(d)} + s_v \quad (5)$$

$$R'_{(k)} = R_{\text{GNSS}(d)} \exp(\hat{s}_R) \quad (6)$$

2 基于改进 ESKF 的位姿补偿算法

2.1 状态变量预测

不失一般性,定义名义状态变量 X 和误差状态变量

δX 。 δ 修饰的变量为名义状态变量 $X \in R^3$ 和实际状态变量 $X^l \in R^{18}$ 的误差量,其中 $\eta \in R^3$ 表示姿态误差向量,其反应姿态误差矩阵 $\delta R \in R^{3 \times 3}$ 局部的导数特性,是 $SO(3)$ 的 δR 对应的李代数向量。

$$X = [x \quad v \quad R_b^n \quad b_a \quad b_\omega \quad g]^T \quad (7)$$

$$\delta X = [\delta x \quad \delta v \quad \eta \quad \delta b_a \quad \delta b_\omega \quad \delta g]^T \quad (8)$$

$$X^l = [x^l \quad v^l \quad R^l \quad b_a^l \quad b_\omega^l \quad g^l]^T \quad (9)$$

式中: $\delta x \in R^3$ 和 $\delta v \in R^3$ 表示坐标系 n 下的位置误差向量和速度误差向量; $\eta \in R^3$ 表示姿态误差向量,其反应姿态误差矩阵 $\delta R \in R^{3 \times 3}$ 局部的导数特性,是 $SO(3)$ 的 δR 对应的李代数向量; $\delta b_a \in R^3$ 表示加速度计的零偏误差向量; $\delta b_\omega \in R^3$ 表示陀螺仪的零偏误差向量; $\delta g \in R^3$ 表示重力的误差向量。

实际状态变量 X^l 可通过不考虑噪声的名义状态变量和误差状态变量的广义加,姿态部分通过引入指数映射给定, $\hat{\eta}$ 表示 η 的反对称矩阵,具体为:

$$\begin{cases} x^l = x + \delta x \\ v^l = v + \delta v \\ R^l = R_b^n \exp(\hat{\eta}) \\ b_a^l = b_a + \delta b_a \\ b_\omega^l = b_\omega + \delta b_\omega \\ g^l = g + \delta g \end{cases} \quad (10)$$

建立误差状态变量 δX 的状态方程^[19]。

$$\begin{cases} \delta X_{(k)} = F_{(k-1)} \delta X_{(k-1)} + W_{(k-1)} \\ Z_{(k)} = H_{(k)} \delta X_{(k)} + V_{(k)} \end{cases} \quad (11)$$

式中: $F_{(k-1)}$ 为线性系统模型, $W_{(k-1)}$ 为系统噪声, $Z_{(k)}$ 为量测数据, $V_{(k)}$ 为观测噪声。

名义状态变量 X 是直接使用 IMU 数据的线性预测,不考虑噪声项,记系统离散时间为 T_s ,下一时刻估计的名义状态变量可以表示为:

$$\begin{cases} x_{(k)} = x_{(k-1)} + v_{(k-1)} T_s + \frac{1}{2} (R_{b(k-1)}^n (a_{\text{IMU}(k)} - b_{a(k-1)}) + g_{(k-1)}) T_s^2 \\ v_{(k)} = v_{(k-1)} + [R_{b(k-1)}^n (a_{\text{IMU}(k)} - b_{a(k-1)}) + g_{(k-1)}] T_s \\ R_{b(k)}^n = R_{b(k-1)}^n \exp((\omega_{\text{IMU}(k)} - b_{\omega(k-1)})^\wedge T_s) \\ b_{a(k)} = b_{a(k-1)} \\ b_{\omega(k)} = b_{\omega(k-1)} \\ g_{(k)} = g_{(k-1)} \end{cases} \quad (12)$$

无人机位置误差 δx 对时间的微分表示为:

$$\delta \dot{x} = \delta v \quad (13)$$

实际速度对时间的微分可展开如下形式:

$$v'^l = R^l (a_{\text{IMU}} - b_a^l + \varepsilon_a) + g^l \quad (14)$$

对式(10)中的速度项两边求导展开,代入式(2),忽

略高阶小量, $\delta \mathbf{v}$ 对时间的微分为:

$$\dot{\delta \mathbf{v}} = -\mathbf{R}_b^n (\mathbf{a}_{\text{IMU}} - \mathbf{b}_a) \wedge \boldsymbol{\eta} - \mathbf{R}_b^n \delta \mathbf{b}_a + \boldsymbol{\varepsilon}_a + \delta \mathbf{g} \quad (15)$$

无人机相邻时刻最优估计的姿态角误差极小, 一般 $0 < \|\boldsymbol{\eta}\| < 1$ 。式(10)中的姿态项可近似为:

$$\delta \mathbf{R} \approx \mathbf{R}_b^n \hat{\boldsymbol{\eta}} \quad (16)$$

两边求导, 并通过刚体转动公式联立得:

$$\mathbf{R}_b^n \hat{\boldsymbol{\eta}} \dot{\boldsymbol{\omega}} = \mathbf{R}_b^n \hat{\boldsymbol{\omega}} \wedge \hat{\boldsymbol{\eta}} + \mathbf{R}_b^n \dot{\hat{\boldsymbol{\eta}}} \quad (17)$$

两侧左乘逆矩阵 $\mathbf{R}_b^{n-1}$, 移项并根据反对称矩阵性质, 姿态误差向量的微分方程为:

$$\dot{\hat{\boldsymbol{\eta}}} = -(\boldsymbol{\omega}_{\text{IMU}} - \mathbf{b}_\omega) \wedge \hat{\boldsymbol{\eta}} - \boldsymbol{\varepsilon}_\omega \quad (18)$$

$$\mathbf{F}_{(k-1)} = \begin{bmatrix} \mathbf{I}_{3 \times 3} & \mathbf{I}_{3 \times 3} T_s & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} & -\mathbf{R}_{b(k-1)}^n (\mathbf{a}_{\text{IMU}(k)} - \mathbf{b}_{a(k-1)}) \wedge \boldsymbol{\eta}_{(k-1)} T_s & -\mathbf{R}_{b(k-1)}^n T_s & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} T_s \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & -(\boldsymbol{\omega}_{\text{IMU}(k)} - \mathbf{b}_{\omega(k-1)}) \wedge T_s & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} - (\boldsymbol{\tau}_a)^{-1} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} - (\boldsymbol{\tau}_\omega)^{-1} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} \end{bmatrix} \quad (22)$$

连续时间的噪声项可视为随机过程的能量谱密度, 可使用标准差 σ 表征随机变量。

$$\mathbf{W}_{(k)} = [\mathbf{0}_{1 \times 3} \quad \sigma^2(\boldsymbol{\varepsilon}_a) T_{\text{IMU}}^2 \quad \sigma^2(-\boldsymbol{\varepsilon}_\omega) T_{\text{IMU}}^2 \quad \sigma^2(\boldsymbol{\varphi}_a) T_{\text{IMU}} \quad \sigma^2(\boldsymbol{\varphi}_\omega) T_{\text{IMU}} \quad \mathbf{0}_{1 \times 3}]^T \quad (23)$$

因误差状态变量 $\delta \mathbf{X}$ 在一次更新后会被重置, 对其预测意义不大, 故误差部分是通过预测均方误差阵 $\mathbf{P}_{(k,k-1)}$ 指导整个滤波器的估计。

$$\mathbf{P}_{(k,k-1)} = \mathbf{F}_{(k)} (\boldsymbol{\Lambda} \mathbf{P}_{(k)} \boldsymbol{\Lambda}^T + \mathbf{W}_{(k)}) \quad (24)$$

式中: $\boldsymbol{\Lambda}$ 是多重渐消因子矩阵对角阵, 引入待定系数 $\lambda_k (k \geq 1)$, 定义为:

$$\boldsymbol{\Lambda} = \text{diag}(\sqrt{\lambda_1}, \sqrt{\lambda_2}, \dots, \sqrt{\lambda_{18}}) \quad (25)$$

常规卡尔曼滤波可认为待定系数等于单位阵的特殊情况。本质上, 本文是一种强跟踪滤波器, 即扩大了量测数据对状态估计的修正作用。强跟踪是从误差整体上的强跟踪, 很难保证每一个状态分量都有良好的估计效果, 因此需要补偿与校准保证最优性。

2.2 姿态补偿与修正

据矩阵的链式公式, 引入 GNSS 安装误差导致的坐标偏移矩阵 $\mathbf{R}_i^b$, 可表示为:

$$\mathbf{R}' = \mathbf{R}^I \mathbf{R}_i^b \quad (26)$$

将式(6)和(10)中的 $\mathbf{R}'$ 代入式(26), 根据反对称矩阵的性质, 写为:

$$\mathbf{R}_{\text{GNSS}(d)}^n = \mathbf{R}_{b(k)}^n \exp\{\hat{\boldsymbol{\eta}}_{(k)} - (\mathbf{R}_i^b \mathbf{s}_R) \wedge\} \mathbf{R}_i^b \quad (27)$$

式中: $\mathbf{R}_i^b$ 是一个固定矩阵, 其反应了 GNSS 安装误差导致的坐标偏移。

本文假设存在姿态向量 $\delta \mathbf{z}_a \in \mathbb{R}^3$, 使得:

$$\delta \mathbf{z}_{a(k)} = \boldsymbol{\eta}_{(k)} - \mathbf{R}_i^b \mathbf{s}_R \quad (28)$$

考虑到陀螺仪和加速度计的零偏不稳定, 采用一阶马尔科夫激励白噪声对 $\delta \mathbf{b}_a$ 和 $\delta \mathbf{b}_\omega$ 建模。

$$\delta \dot{\mathbf{b}}_a = -(\boldsymbol{\tau}_a)^{-1} \delta \mathbf{b}_a + \boldsymbol{\varphi}_a \quad (19)$$

$$\delta \dot{\mathbf{b}}_\omega = -(\boldsymbol{\tau}_\omega)^{-1} \delta \mathbf{b}_\omega + \boldsymbol{\varphi}_\omega \quad (20)$$

式中: $\boldsymbol{\tau}_a$ 和 $\boldsymbol{\tau}_\omega$ 是反时间相关常数矩阵, $\boldsymbol{\varphi}_a$ 和 $\boldsymbol{\varphi}_\omega$ 是高斯白噪声矩阵。

重力加速度误差 $\delta \mathbf{g}$ 对时间的导数为:

$$\delta \dot{\mathbf{g}} = \mathbf{0} \quad (21)$$

对式(13)、(15)、(18)~(21)微分公式离散化, 得线性化雅克比矩阵 $\mathbf{F}_{(k-1)}$:

根据泰勒公式, 姿态向量 $\delta \mathbf{z}_a$ 又可近似为:

$$\delta \hat{\mathbf{z}}_{a(k)} \approx \mathbf{R}_{b(k)}^{nT} \mathbf{R}_{\text{GNSS}(d)} \mathbf{R}_i^{bT} - \mathbf{I}_{3 \times 3} \quad (29)$$

为保证上述近似值是一个反对称矩阵, 故将其投影到反对称矩阵空间, 并做反对称矩阵逆变换:

$$\delta \mathbf{z}_{a(k)} = \frac{1}{2} (\mathbf{R}_{b(k)}^{nT} \mathbf{R}_{\text{GNSS}(d)} \mathbf{R}_i^{bT} - \mathbf{R}_i^b \mathbf{R}_{\text{GNSS}(d)}^T \mathbf{R}_{b(k)}^n) \sim \quad (30)$$

式中: 逆变换用 $\sim$ 表示

在 $\text{SO}(3)$ 上姿态矩阵 $\mathbf{R}_b^n$ 可通过式(12)迭代计算, 据式(28)可构造误差姿态向量 $\boldsymbol{\eta}$ 的修正方程, 并以 GNSS 数据发送周期 T_{GNSS} 离散噪声项。

$$\begin{cases} \delta \mathbf{z}_{a(k)} = \mathbf{H}_R \delta \mathbf{X}_{(k)} + \mathbf{V} \\ \mathbf{H}_R = [\mathbf{0}_{3 \times 6} \quad \mathbf{I}_{3 \times 3} \quad \mathbf{0}_{3 \times 9}] \\ \mathbf{V}_R = -\mathbf{R}_i^b \sigma^2(\mathbf{s}_R) T_{\text{GNSS}} \end{cases} \quad (31)$$

接着, 就可对误差状态变量 $\delta \mathbf{X}$ 和预测均方误差阵 $\mathbf{P}_{(k,k-1)}$ 修正, 具体为:

$$\begin{cases} \mathbf{K}_{R(k)} = \mathbf{P}_{(k,k-1)} \mathbf{H}_R (\mathbf{H}_R \mathbf{P}_{(k,k-1)} \mathbf{H}_R^T + \mathbf{V}_R)^{-1} \\ \delta \mathbf{X}_{R(k)}^+ = \mathbf{K}_{R(k)} \delta \mathbf{z}_{a(k)} \\ \mathbf{P}_{(k,k-1)}^+ = (\mathbf{I}_{18 \times 18} - \mathbf{K}_R \mathbf{H}_R) \mathbf{P}_{(k,k-1)} \end{cases} \quad (32)$$

修正完毕需将 $\delta \mathbf{X}_{R(k)}^+$ 归入名义状态变量 $\mathbf{X}_{R(k)}^+$ 中, 然后误差状态变量 $\delta \mathbf{X}_R^+$ 置 0, 完成 1 次姿态修正。修正均方误差阵 $\mathbf{P}_{(k,k-1)}^+$ 继续迭代。

为进一步提高系统稳定性, 在姿态修正前, 本文设计了基于互补滤波的角速度补偿算法。其主要作用是低动态情况下对俯仰和横滚值的修正, 以加速度计获取的实时姿态角来修正陀螺仪的累积误差, 设定状态系数 coe 。

$$\text{coe} = \text{abs}(\|\mathbf{a}_{\text{IMU}} - \mathbf{b}_a\| - \|\mathbf{g}\|) \quad (33)$$

通过设定阈值判断有无进低动态状态。当处于低动

态状态时,用单位向量外积表示误差为:

$$\alpha_{\text{error}(k)} = -\mathbf{R}_{n(k-1)}^b \frac{\mathbf{g}(k)}{\|\mathbf{g}(k)\|} \times \frac{\mathbf{a}_{\text{IMU}(k)} - \mathbf{b}_{a(k)}}{\|\mathbf{a}_{\text{IMU}(k)} - \mathbf{b}_{a(k)}\|} \quad (34)$$

使用误差和误差的积分去修正角速度,通过设定变量 KP_R 和 KI_R 补偿角度误差。对于误差积分的累计误差 $\alpha \text{Int}_{\text{error}}$,需在进入低动态状态一段时间才会发挥作用。退出低动态状态时, $\alpha \text{Int}_{\text{error}}$ 默认归 0。

$$\begin{cases} \alpha \text{Int}_{\text{error}(k)} = \alpha \text{Int}_{\text{error}(k-1)} + KI_R \alpha_{\text{error}(k)} \\ \omega_{\text{IMU}(k)}^+ = \omega_{\text{IMU}(k)} + KP_R \alpha_{\text{error}(k)} + \alpha \text{Int}_{\text{error}(k)} \end{cases} \quad (35)$$

低动态情况下在 $SO(3)$ 上的姿态修正为:

$$\mathbf{R}_{b(k)}^n = \mathbf{R}_{b(k-1)}^n \exp\left\{(\hat{\omega}_{\text{IMU}(k-1)}^+ - \mathbf{b}_\omega) T_s\right\} \quad (36)$$

2.3 时延速度位置修正

GNSS 测量的位置、速度存在相对滞后时间 T_d ,这会导致和惯性传感器之间产生时间不同步误差,需对时间不同步误差估计和补偿。 n 坐标系下 t_k 时刻可用 GNSS 接受的相邻两帧数据推测位置 $\tilde{\mathbf{x}}_1$ 和速度 $\tilde{\mathbf{v}}_1$ 。

$$\tilde{\mathbf{x}}_{1(k)} = \mathbf{x}'_{(k)} + \frac{T_d}{T_{\text{GNSS}}}(\mathbf{x}'_{(k)} - \mathbf{x}'_{(k-1)}) \quad (37)$$

$$\tilde{\mathbf{v}}_{1(k)} = \mathbf{v}'_{(k)} + \frac{T_d}{T_{\text{GNSS}}}(\mathbf{v}'_{(k)} - \mathbf{v}'_{(k-1)}) \quad (38)$$

根据捷联惯导算法中时间不同步误差补偿公式, n 坐标系下 t_k 时刻位置 $\tilde{\mathbf{x}}_2$ 、速度 $\tilde{\mathbf{v}}_2$ 可通过不同步时间附近的平均加速度 $\bar{\mathbf{a}}$ 写成:

$$\tilde{\mathbf{x}}_{2(k)} = \mathbf{x}'_{(k)} + \mathbf{v}'_{(k)} T_d + \frac{1}{2} \bar{\mathbf{a}}_{(k)} T_d^2 \quad (39)$$

$$\tilde{\mathbf{v}}_{2(k)} = \mathbf{v}'_{(k)} + \bar{\mathbf{a}}_{(k)} T_d \quad (40)$$

假设 IMU 输出周期为 T_{IMU} , $\bar{\mathbf{a}}$ 可通过惯导在两相邻时间内速度的平均变化来近似,本文使用 t_{k-1} 到 t_k 这段时间平均加速度近似。

$$\bar{\mathbf{a}}_{(k)} \approx \mathbf{R}_{b(k-1)}^n (\mathbf{a}_{\text{IMU}(k)} - \mathbf{b}_{a(k-1)}) + \mathbf{g}_{(k-1)} \quad (41)$$

IMU 积分获得的速度和位置短时间准确,一旦时间拉长存在发散, $\tilde{\mathbf{x}}_2$ 和 $\tilde{\mathbf{v}}_2$ 的噪声具有低频特性;GNSS 长时间平均准确,短时间存在波动, $\tilde{\mathbf{x}}_1$ 和 $\tilde{\mathbf{v}}_1$ 的噪声具有高频特性。本文使用 IMU 推算的位置 $\tilde{\mathbf{x}}_2$ 和速度 $\tilde{\mathbf{v}}_2$ 修正 GNSS 推算的位置 $\tilde{\mathbf{x}}_1$ 和速度 $\tilde{\mathbf{v}}_1$ 。设计基于互补滤波的补偿算法,设定系数变量 KP_x 、 KP_v 、 KI_x 、 KI_v 和累计误差 $\mathbf{xInt}_{\text{error}}$ 、 $\mathbf{vInt}_{\text{error}}$ 。

$$\begin{cases} \mathbf{xInt}_{\text{error}(k)} = \mathbf{xInt}_{\text{error}(k-1)} + KI_x (\tilde{\mathbf{x}}_{1(k)} - \tilde{\mathbf{x}}_{2(k)}) \\ \mathbf{x}_{(k)}^+ = \tilde{\mathbf{x}}_{1(k)} + KP_x (\tilde{\mathbf{x}}_{1(k)} - \tilde{\mathbf{x}}_{2(k)}) + \mathbf{xInt}_{\text{error}(k)} \\ \mathbf{vInt}_{\text{error}(k)} = \mathbf{vInt}_{\text{error}(k-1)} + KI_v (\tilde{\mathbf{v}}_{1(k)} - \tilde{\mathbf{v}}_{2(k)}) \\ \mathbf{v}_{(k)}^+ = \tilde{\mathbf{v}}_{1(k)} + KP_v (\tilde{\mathbf{v}}_{1(k)} - \tilde{\mathbf{v}}_{2(k)}) + \mathbf{vInt}_{\text{error}(k)} \end{cases} \quad (42)$$

在 t_k 时刻最优估计伪量测的 $\mathbf{x}_{(k)}^+$ 和 $\mathbf{v}_{(k)}^+$,据式(12)中名义状态变量的预测值,可计算量测误差 $\delta \mathbf{z}_{\text{xy}}$,代入

ESKF 中进行量测更新,对于噪声阵 $\mathbf{V}_{\text{xy}}$ 以 GNSS 数据发送周期 T_{GNSS} 离散噪声项 $\mathbf{s}_x$ 和 $\mathbf{s}_v$ 。

$$\begin{cases} \delta \mathbf{z}_{\text{xy}(k)} = [\mathbf{x}_{(k)}^+ - \mathbf{x}_{(k)} & \mathbf{v}_{(k)}^+ - \mathbf{v}_{(k)}]^T \\ \delta \mathbf{z}_{\text{xy}(k)} = \mathbf{H}_{\text{xy}} \delta \mathbf{X}_{R(k)}^+ + \mathbf{V}_{\text{xy}} \\ \mathbf{H}_{\text{xy}} = \begin{bmatrix} \mathbf{I}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 12} \\ \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} & \mathbf{0}_{3 \times 12} \end{bmatrix} \\ \mathbf{V}_{\text{xy}} = \begin{bmatrix} \sigma^2(\mathbf{s}_x) T_{\text{GPS}} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \sigma^2(\mathbf{s}_v) T_{\text{GPS}} \end{bmatrix} \end{cases} \quad (43)$$

根据上一个步骤中的修正的均方误差阵 $\mathbf{P}_{(k,k-1)}^+$ 和名义状态变量 $\mathbf{X}_R^+$,计算新的增益矩阵 $\mathbf{K}_{\text{xy}}$;预测新的误差状态变量 $\delta \mathbf{X}^+$;更新均方误差阵 $\mathbf{P}_{(k)}$ 。

$$\begin{cases} \mathbf{K}_{\text{xy}(k)} = \mathbf{P}_{(k,k-1)}^+ \mathbf{H}_{\text{xy}} (\mathbf{H}_{\text{xy}} \mathbf{P}_{(k,k-1)}^+ \mathbf{H}_{\text{xy}}^T + \mathbf{V}_{\text{xy}})^{-1} \\ \delta \mathbf{X}_{\text{xy}(k)}^+ = \mathbf{K}_{\text{xy}(k)} \delta \mathbf{z}_{\text{xy}(k)} \\ \mathbf{P}_{(k)} = (\mathbf{I}_{18 \times 18} - \mathbf{K}_{\text{xy}} \mathbf{H}_{\text{xy}}) \mathbf{P}_{(k,k-1)}^+ \end{cases} \quad (44)$$

将 $\delta \mathbf{X}_{\text{xy}}^+$ 归入上一步骤修正的 $\mathbf{X}_R^+$ 中,实现对实际状态变量 $\mathbf{X}^l$ 的最优估计;误差状态变量 $\delta \mathbf{X}_{\text{xy}}^+$ 置 0,完成一次对速度和位置修正。

3 实验与分析

3.1 仿真实验

为验证改进 ESKF 算法有效性,进行仿真实验验证。如图 3 所示,仿真初始位置为东向 21 m,北向 0 m,天向 0 m;各方向运动初始速度为 0 m/s;初始俯仰角、横滚角、偏航角都为 0°;陀螺仪零偏 1°/h,随机游走 0.1°/(s·√h);加速度计零偏 20 mg,随机游走 0.2 mg/√Hz;GNSS 位置精度 0.1 m,速度精度 0.02 m/s;为模拟植保无人机作业真实环境,GNSS 数据模拟相对延迟 20 ms;因植保无人机机身强振动,GNSS 输出的姿态角误差 4°。




图 3 仿真飞行轨迹图

Fig. 3 Simulated flight trajectory diagram

为提高姿态估计精度和系统的稳定性,本文首先引入渐消因子,并传统 ESKF 算法对比,性能参数如表 1 所示。

表 1 姿态仿真绝对误差分析结果

Table 1 Absolute error analysis results of attitude simulation

欧拉角	方法	平均误差 /(°)	最大误差 /(°)	均方根 误差/(°)
俯仰角	ESKF 算法	0.966 1	3.921 9	0.626
	引入渐消因子	0.926 6	3.015 2	0.195
横滚角	ESKF 算法	1.185 5	0.832 0	0.424
	引入渐消因子	1.061 6	0.507 0	0.185
偏航角	ESKF 算法	0.827 6	2.791 0	0.997
	引入渐消因子	0.740 4	1.703 0	0.594

渐消因子的引入可提高三轴姿态的跟随性能,一定程度减少了误差,并不能根本解决时延问题,速度和位置信息依然存在误差。因此本文在引入渐消因子的基础上,如图 4 和 5 所示,加入基于互补滤波的补偿环节,提高速度和位置的估计精度。




图 4 东北天仿真速度对比

Fig. 4 Northeast day simulation speed comparison diagram





图 5 东北天仿真位置对比

Fig. 5 Northeast day simulation positions comparison diagram

改进后的东北天方向速度平均误差分别减少了 0.09、0.07、0.002 m/s,东北天方向位置平均误差分别减少了 0.214、0.397、0.468 m。

3.2 硬件平台

为了保证实验的安全性,如图 6 所示,本文使用上海中航欣盛航空技公司的 HF22-X80017 植保无人机为载体。植保无人机测量系统板的核心处理器使用 ST 公司的 STM32F407VET6 芯片。板上板载了博世公司的六轴 IMU 测量单元 BMI088 和思南导航的 K823W 定位定向模块。GNSS 天线选用北天公司的 BT-560,使用有人互联网公司的 DR-154 超小型导轨式 Cat-1 模块作为差分数据传输模块。处理器通过 Microhard 公司的 P400 传输模块将数据传输给电脑。



图 6 飞行实验平台

Fig. 6 Flight test platform

为验证位姿估计的精确性,实验采用荷兰 XSSENS 公司的 MTi-680 型惯性导航系统,外置思南导航公司的 K823W 高精度定位定向 GNSS 模块,提供准确的姿态、速度、位置信息。其横滚、俯仰角精度可达 0.2°,偏航精度达 1.0°,速度精度达 0.05 m/s,位置精度 1 cm。

在接收到 IMU 数据后,要对陀螺仪的数据进行均值滤波和对加速度计的数据低通滤波;在接收到 GNSS 数据后,要对 NEMA-0183 报文进行解析与处理。处理时间的不同会带来一定程度的时间误差,对位姿估计精度产生影响。如图 7 所示,本文提出一种纯软件的测量误差

时间。使用定时器精准循环计数,一次循环时间为 1 s。每次在处理完 IMU 和 GNSS 的数据时,获得定时器的计数。使用最近一次 IMU 计数和 GNSS 计数作差,获取相对延时时间。




图 7 时延误差程序流程

Fig. 7 Flow chart of the time delay difference procedure

3.3 定点飞行实验

为验证引入渐消因子后的低动态姿态修正算法的可靠性,2024 年 1 月 18 日在 30°55′43.8″N,121°1′57.9″E 进行 1 min 42 s 定点飞行实验,以 MTi-680 型惯性导航系统提供的姿态信息作为参考值。本文采用 ESKF 算法和改进 ESKF 算法分别姿态估计,对比姿态估计精度。

如图 8 所示。通过无线数传获得的数据进一步分析,实验数据如表 2 所示。与传统 ESKF 算法相比,俯仰和横滚角均方根误差减少了 0.266 9°和 0.241 4°,偏航角均方根误差减少了 0.076 4°,并且平均误差减少了 1.062 3°。

表 2 定点飞行姿态误差分析结果

Table 2 The results of fixed-point flight attitude error analysis

欧拉角	方法	平均误差 /(°)	最大误差 /(°)	均方根 误差/(°)
俯仰角	ESKF	0.272 4	0.853 0	0.357 2
	改进 ESKF	0.061 7	0.399 0	0.090 3
横滚角	ESKF	0.341 9	1.136 4	0.436 0
	改进 ESKF	0.133 4	0.982 0	0.194 6
偏航角	ESKF	1.170 7	1.138 7	0.254 0
	改进 ESKF	0.108 4	1.092 2	0.177 6




图 8 姿态估计对比

Fig. 8 Comparison of estimation of pose diagram

3.4 航迹飞行实验

为验证本文提出的基于互补滤波的速度位置时延补偿环节,在相同场地进行 3 min 58 s 的植保无人机规划航迹飞行实验,飞行航迹图如图 9 所示。软件测量的 IMU 和 GNSS 相对延迟时间 48.6 ms。




图 9 飞行航迹图

Fig. 9 Flight track diagram

采用改进 ESKF 算法和 ESKF 算法分别融合获得东北天三轴位置、速度,误差曲线如图 10 所示。如表 3 所示,以 MTi-680 的输出的东北天速度和位置作为参考值,东向的位置平均绝对误差减少了 0.138 4 m;天向的位置平均绝对误差减少了 0.109 6 m。整体上,速度均方根误

差分别减少 0.210 5、0.184 9、0.238 8 m/s;东北天三向的位置均方根误差分别减少 0.21、0.19、0.23 m。本文提出方法整体优于 ESKF 算法,可有效减少相对时延带来的估计误差,提高位置速度的估计精度,更加有利于植保无人机的精准作业。




图 10 速度位置估计误差对比

Fig. 10 Comparison of velocity position estimation errors diagram

表 3 位置估计误差

Table 3 Position estimation error

方向	方法	误差范围 /m	平均绝对 误差/m	均方根误差 /m
东向	ESKF	-2.83~1.36	0.503 7	0.89
	改进 ESKF	-0.31~0.57	0.365 3	0.68
北向	ESKF	-1.46~1.46	0.491 4	0.63
	改进 ESKF	-1.26~1.36	0.381 8	0.44
天向	ESKF	-1.86~2.75	0.197 0	0.53
	改进 ESKF	-1.36~2.75	0.186 7	0.30

4 结 论

为提高植保无人机的位姿估计精度,解决 IMU 和 GNSS 的时间不同步问题,本文根据植保无人机特性针对性改进 ESKF,充分利用 IMU 和 GNSS 的信息,对时延信息进行外推融合补偿,提高植保无人机的位姿估计精度。为验证算法有效性,通过仿真验证算法有效性,设计搭载

多种传感器的飞行实验平台,自主设计位姿融合板。进行实际飞行实验,验证本文提出的位姿补偿算法的有效性。实验结果表明,与传统 ESKF 算法相比,改进 ESKF 算法有效提高位姿估计的精度,有利于植保作业的顺利完成。

参考文献

[1] 周志艳,明锐,臧禹,等. 中国农业航空发展现状及对策建议[J]. 农业工程学报,2017,33(20):1-13.
ZHOU ZH Y, MING R, ZANG Y, et al. Development status and countermeasures of agricultural aviation in China [J]. Transactions of Society of Agricultural Engineering in China, 2017,33(20):1-13.
[2] ZHANG T, YANG Z, XU Z, et al. Wheat yellow rust severity detection by efficient DF-UNET and UAV multispectral imagery[J]. IEEE Sensors Journal, 2022, 22(9): 9057-9068.
[3] 王大帅,LIU X G,李伟,等. 基于多传感器融合的无人机精准自主飞行控制方法[J]. 农业机械学报,2019,

- 50(12): 98-106.
- WANG D SH, LIU X G, LI W, et al. UAV accurate autonomous flight control method based on multi-sensor fusion[J]. Transactions of Agricultural Machinery in China, 2019, 50(12): 98-106.
- [4] 杨菊花, 李文元, 陈光武, 等. 引入滑模观测器的 GPS/INS 组合导航滤波方法[J]. 仪器仪表学报, 2019, 40(9): 78-86.
- YANG J H, LI W Y, CHEN G W, et al. GPS/INS integrated navigation filtering method with sliding mode observer[J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 78-86.
- [5] 陈红梅, 常林江, 徐振方, 等. 复杂环境下 GNSS/INS/UWB 紧组合的无人机协同导航算法[J]. 仪器仪表学报, 2021, 42(7): 98-107.
- CHEN H M, CHANG L J, XU ZH F, et al. UAV collaborative navigation algorithm based on tight combination of GNSS/INS/UWB in complex environment[J]. Chinese Journal of Scientific Instrument, 2021, 42(7): 98-107.
- [6] 吴和龙, 白越, 裴信彪, 等. 基于 CPF-EKF 算法的大载荷植保无人机姿态解算方法[J]. 农业机械学报, 2018, 49(6): 24-31, 77.
- WU H L, BAI Y, PEI X B, et al. Attitude calculation method of large-load plant protection UAV based on CPF-EKF algorithm [J]. Transactions of Agricultural Machinery in China, 2018, 49(6): 24-31, 77.
- [7] BEVLY D M, RYU J, GERDES J C. Integrating INS sensors with GPS measurements for continuous estimation of vehicle sideslip, roll, and tire cornering stiffness[J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(4): 483-493.
- [8] HANSEN J M, FOSSEN T I, JOHANSEN T A. Nonlinear observer design for GNSS-aided inertial navigation systems with time-delayed GNSS measurements[J]. Control Engineering Practice, 2017, 60: 39-50.
- [9] 刘红光, 陈志刚, 陈刚. 基准信息时间延迟对速度匹配传递对准性能的影响分析[J]. 中国惯性技术学报, 2012, 20(5): 544-551.
- LIU H G, CHEN ZH G, CHEN G. Analysis of effect of time delay of reference information on performance of velocity matching transfer alignment [J]. Journal of Inertia Technology Transactions of Agricultural Machinery in China, 2012, 20(5): 544-551.
- [10] 钱山, 李鹏奎, 张士峰, 等. MIMU/GPS 组合导航建模及 GPS 时间延迟补偿算法研究[J]. 系统工程与电子技术, 2009, 31(6): 1432-1435.
- QIAN SH, LI P K, ZHANG SH F, et al. MIMU/GPS integrated navigation modeling and GPS time delay compensation algorithm [J]. Systems Engineering and Electronics Transactions of Agricultural Machinery in China, 2009, 31(6): 1432-1435.
- [11] 杜瑾, 李杰, 罗丹瑶, 等. 高动态 GPS/INS 组合导航中时间延迟软硬件补偿算法研究[J]. 传感技术学报, 2016, 29(12): 1858-1863.
- DU J, LI J, LUO D Y, et al. Research on software and hardware compensation algorithm for time delay in high dynamic GPS/INS integrated navigation [J]. Journal of Sensing Technology Transactions of Agricultural Machinery in China, 2016, 29(12): 1858-1863.
- [12] EIDSON J, KANG L, IEEE 1588 standard for a precision clock synchronization protocol for networked measurement and control systems [C]. 2nd ISA/IEEE Sensors for Industry Conference. IEEE, 2002.
- [13] 沈跃, 张念, 孙志伟, 等. 基于多速率卡尔曼滤波的植保无人机仿地飞行方法[J]. 农业机械学报, 2023, 54(3): 190-197.
- SHEN Y, ZHANG N, SUN ZH W, et al. Ground simulation flight method of plant protection UAV based on multi-rate Kalman filter [J]. Transactions of Agricultural Machinery in China, 2023, 54(3): 190-197.
- [14] ANSARI K, JAMJAREERULGARN P. Effect of weighted PDOP on performance of linear kalman filter for RTK drone data [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-4.
- [15] 张涛, 徐晓苏, 刘晓东, 等. 不同动态条件下组合导航系统的时间同步 [J]. 中国惯性技术学报, 2012, 20(3): 320-325.
- ZHANG T, XU X S, LIU X D, et al. Time synchronization of integrated navigation system under different dynamic conditions [J]. Journal of Inertia Technology in

China, 2012, 20(3):320-325.

- [16] 章红平, 常乐, 汪宏晨, 等. GNSS/INS 紧组合算法实时性改进与嵌入式验证[J]. 东南大学学报(自然科学版), 2016, 46(4):695-701.

ZHANG H P, CHANG L, WANG H CH, et al. Real-time improvement and embedded verification of GNSS/INS compact combination algorithm [J]. Journal of Southeast University (Natural Science Edition), 2016, 46(4):695-701.

- [17] GAMAGEDARA K, LEE T, SNYDER M. Quadrotor state estimation with IMU and delayed real-time kinematic GPS[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(5):2661-2673.

- [18] 沈跃, 孙志伟, 沈亚运, 等. 直线型植保无人机航姿UKF 两级估计算法[J]. 农业机械学报, 2022, 53(9):151-159.

SHEN Y, SUN ZH W, SHEN Y Y, et al. UKF two-level attitude estimation algorithm for linear plant protection UAV [J]. Transactions of Agricultural Machinery in China, 2022, 53(9):151-159.

- [19] 高胜峰, 陈建华, 朱海. SINS/LBL 组合导航序贯滤波方法[J]. 仪器仪表学报, 2017, 38(5):1071-1078.

GAO SH F, CHEN J H, ZHU H. Sequential filtering method for SINS/LBL integrated navigation [J]. Chinese Journal of Scientific Instrument, 2017, 38(5):1071-1078.

作者简介



E-mail: amity@ujs.edu.cn

Liu Hui received her B. Sc. degree from Jiangsu University of Science and Technology in 1997, received her M. Sc. degree and Ph. D. degree both from Jiangsu University in 2004 and 2019, respectively. She is currently a professor at Jiangsu University. Her main research interests include intelligent perception and control, multi-sensor information fusion, and biomedical signal processing.



E-mail: shen@ujs.edu.cn

Shen Yue (Corresponding author) received his B. Sc. degree from Jiangsu University of Science and Technology in 1997, received his M. Sc. degree from Jiangsu University in 2004 and his Ph. D. degree from Jiangsu University in 2012. He is currently a professor at Jiangsu University. His research interests include unmanned driving, intelligent perception, deep learning and special UAV.

刘慧, 1997 年于江苏理工大学获得学士学位, 2004 年于江苏大学获得硕士学位, 2009 年于江苏大学获得博士学位, 现为江苏大学教授, 主要研究方向为智能感知与控制、多传感器信息融合、生物医学信号处理等。

沈跃 (通信作者), 1997 年于江苏理工大学获得学士学位, 2004 年于江苏大学获得硕士学位, 2012 年于江苏大学获得博士学位, 现为江苏大学教授, 主要研究方向为飞行器系统辨识、多电机协调控制、特种飞行器设计等。

DOI: 10.19650/j.cnki.cjsi.J2312127

海上无人机对运动船舶的长期检测跟踪算法*

范云生^{1,2}, 张凯^{1,2}, 牛龙辉^{1,2}, 刘婷^{1,2}, 费凡^{1,2}

(1. 大连海事大学船舶电气工程学院 大连 116026; 2. 辽宁省智能船舶技术与系统重点实验室 大连 116026)

摘要:针对无人机在海上对船舶进行长时跟踪时,由于船身被遮挡及船舶离开视野导致目标跟踪失败的问题,提出了基于YOLOv5和ECO_HC相结合的海上目标长时检测跟踪算法。首先,利用感知哈希与峰值比例综合评估跟踪过程的可靠性,目标丢失时利用YOLOv5检测器重新定位目标位置,并初始化跟踪器模型,消除累计错误信息。其次针对目标在跟踪过程中存在的旋转变化,利用傅里叶-梅林变换进行旋转参数估计,减少了目标旋转造成的跟踪器性能下降问题。本文算法在OTB-100数据集上的平均精确度和成功率为83.9%和76.7%;在无人机平台上进行实际海上场景船舶跟踪实验,在完全遮挡及离开视野两种情况下精确度和成功率分别为80.9%、60.4%和90.2%、48.3%,实验表明本文算法可以有效抑制常见海面干扰因素的影响。

关键词: 海上无人机; 长时跟踪; 相关滤波; 重新检测; 旋转跟踪框

中图分类号: TP391.4 TH89 文献标识码: A 国家标准学科分类代码: 510.4050

Long-term detection and tracking algorithm for moving vessels by maritime UAVs

Fan Yunsheng^{1,2}, Zhang Kai^{1,2}, Niu Longhui^{1,2}, Liu Ting^{1,2}, Fei Fan^{1,2}

(1. College of Marine Electrical Engineering, Dalian Maritime University, Dalian 116026, China;

2. Key Laboratory of Technology and System for Intelligent Ships of Liaoning Province, Dalian 116026, China)

Abstract: An algorithm for long-term maritime target detection and tracking based on the combination of YOLOv5 and ECO_HC is proposed to address the problem of tracking failure caused by occlusion of ship hulls and ships leaving the field of view during unmanned aerial vehicle (UAV) tracking of ship at sea. First, perceptual hashing and the ratio between the second and first major modes are used to comprehensively assess the reliability of the tracking process. In the event of target loss, the YOLOv5 detector is utilized to reposition the target and initialize the tracking model. Thereby, the accumulation of erroneous information is eliminated. Secondly, to address the rotational changes of the target during tracking, the Fourier-Mellin transform is employed for rotation parameter estimation, mitigating performance decline due to target rotation. The proposed algorithm achieves an average precision and success rate of 83.9% and 76.7%, respectively, on the OTB-100 dataset. Field experiments of ship tracking in actual maritime scenarios on UAV platforms show precision and success rates of 80.9% and 60.4% under complete occlusion, and 90.2% and 48.3% when the target is out of the field of view. The experiments demonstrate that the proposed algorithm can effectively suppress the influence of common maritime interference factors.

Keywords: maritime UAVs; long-term tracking; correlation filtering; re-detection; rotate tracking box

0 引言

海洋防卫对于国家的主权和安全至关重要。无人机对海上船舶的跟踪作为海洋智能感知领域的一个重要研

究方向,是现代海洋防卫不可或缺的一环,在无人系统、海空协同作业等领域有着广泛应用^[1-2]。

近10年来,目标跟踪最主流的两类方法是基于相关滤波和深度学习的方法^[3]。基于判别相关滤波器(discriminative correlation filter, DCF)的目标跟踪^[4-5]算

收稿日期: 2023-11-09 Received Date: 2023-11-09

* 基金项目: 国家重点研发计划(2022YFB4301401)、国家自然科学基金(61976033)、辽宁省中试基地中试验证类科技项目(2022JH24/10200029)资助

法因其优越的实时性能在无人机平台^[6]上得到广泛应用。Danelljan 等^[7]提出高效跟踪卷积算子 (efficient convolution operators, ECO) 算法和基于手工特征的 (ECO_HC) 算法。Li 等^[8]提出时空正则化相关滤波器 (spatial-temporal regularized correlation filters, STRCF), 有效解决了边界效应, 并利用 ADMM (alternating direction method of multipliers) 算法进行求解, 达到实时要求。Fu 等^[9]基于背景感知相关滤波器, 将梯度、颜色、强度和显著性信息进行加权融合, 提高了跟踪算法的鲁棒性。Li 等^[10]提出了在线自动更新和自适应调整时空项的算法, 大大减少了调整预定义参数的工作量。Yuan 等^[11]采用自适应时空上下文感知模型来提高 DCF 模型的表示能力。Zhang 等^[12]通过自适应权重将手工与深度特征融合, 并提出了空间信道选择和时间相关滤波模型。但是随着跟踪时间的增加, 上述短期记忆的跟踪器容易丢失目标。

长时跟踪是指对在一段较宽的时间范围内进行视觉跟踪。相较于短期跟踪, 长时跟踪面临着更严峻的挑战, 如目标消失和误差积累, 是一个更接近实际应用的问题。因此, 长时跟踪要求跟踪器具有可靠的判断机制及较好的重检性能。

在长时跟踪过程丢失目标情况下, 部分经典方法通过支持向量机 (support vector machine, SVM) 和随机森林等方法进行目标重检测。文献[13]将卡尔曼滤波与判别尺度空间相关滤波器结合, 有效解决了目标短期遮挡的问题。文献[14]将归一化互相关 (normalized cross correlation, NCC) 模板匹配与核相关滤波算法相结合, 并提出了新的模型更新策略, 减少了背景信息干扰。文献[15]提出了一种多特征融合且抗遮挡的长时算法, 增强了目标位置预测和抗遮挡能力。文献[16]使用置信度分值加权在线样本学习, 并利用时空约束在有效区域内检测目标。但当目标经历严重遮挡或在较长时间段内离开视野, 上述跟踪算法无法保证精确度, 存在着一定的缺陷。

此外, 随着深度神经网络的应用, 基于深度学习的长时跟踪算法的得到进一步发展。文献[17]通过多个局部跟踪器在全局进行搜索, 并基于可变形注意力机制动态调整局部跟踪器。文献[18]提出了一种基于注意力机制的特征融合网络, 使跟踪器自适应的关注有效信息并提取丰富的语义信息。文献[19]提出了一种通用的目标感知注意机制, 并将其与追踪-检测框架进行联合本地和全局搜索追踪。文献[20]基于提出的一种长短期更新方案的局部搜索模块和重检测模块, 提出了一种新的鲁棒实时长期跟踪框架。

针对长时跟踪过程中由于遮挡或离开视野导致的目标丢失问题, 本文结合团队在无人机海上跟踪与视觉导

航研究方向基础上^[21-22], 提出了 YOLOv5 和 ECO_HC 结合的海上目标长时检测跟踪算法 (maritime target long-term detection and tracking algorithm, M-LTDT), 通过双重置信评估策略综合判断跟踪器可靠性以此提升跟踪器的自检性能; 其次针对目标存在的旋转变换, 采用旋转估计方法来提高跟踪器应对目标旋转的适应能力。

1 相关滤波器原理

ECO 算法^[7]有两种实现方式: 基于卷积神经网络 (convolutional neural network, CNN) 卷积特征的 ECO 算法和基于手工特征的 ECO_HC 算法。由文献[7]可知, 基于卷积特征的 ECO 算法速度未能满足实时性跟踪要求, ECO_HC 算法仅使用了方向梯度直方图 (histogram of oriented gradient, HOG) 和 CN (color names) 特征, 虽然跟踪精度略低于 ECO 算法, 但实时跟踪整体性能明显高于 ECO 算法。

对于 M 个样本 $\{x_j\}_1^M \subset \mathcal{X}$ 中, 每个训练样本 x_j 可以提取 D 维特征, 训练将特征层隐式插值模型的离散空间变量转变为连续的空间域 $t \in (0, T)$, 通过在特征中构造卷积算子进行高效卷积操作, 对于每个特征通道 d , 插值模型运算符 J_d 表示为:

$$J_d\{x^d\}(t) = \sum_{n=0}^{N_d-1} x^d[n] \beta_d\left(t - \frac{T}{N_d}n\right) \quad (1)$$

其中, T 为搜索区域大小, $J_d\{x^d\}$ 表示周期为 T ($T > 0$) 的插值核函数 β_d 计算得到的插值特征层函数, N_d 为 x^d 中的空间样本数, n 为离散空间变量指数。

ECO_HC 算法通过因子化卷积算子优化模型参数的数量以减少滤波器的尺度, 将各个通道的相应位置累加, 可以得到最终结果。因子化卷积算子表示如下:

$$S_{pf}\{x\} = Pf * J\{x\} = \sum_{c,d} P_{d,c} f^c * J_d\{x^d\} = f * P^T J\{x\} \quad (2)$$

其中, $S_{pf}\{x\}$ 为特征响应结果, 定义域为 $t \in (0, T)$, $*$ 代表卷积。选择 d 维滤波器中影响较大的 c 个滤波器, 构造出滤波器 f^c 的线性组合 $\sum_{c=1}^c P_{d,c} f^c, P_{d,c}$ 则为线性降维特征 P 的系数。通过式(2)可以训练得到滤波器 f^c 和矩阵 P , 傅里叶损失函数公式如下:

$$E(f, P) = \|\hat{z}^T P \hat{f} - \hat{y}\|_{\ell^2}^2 + \sum_{c=1}^c \|\hat{w} * \hat{f}^c\|_{\ell^2}^2 + \lambda \|P\|_F^2 \quad (3)$$

式(3)中利用高斯-牛顿法通过一阶泰勒级数展开以优化非线性最小二乘问题, 添加 P 矩阵的 Frobenius 范数作为正则化, λ 为权重参数, 将特征 $J\{x\}$ 转换为 $P^T J\{x\}$, 其中 P^T 可表述为 $\hat{z}^d[k] = X^d[k] \hat{b}_d[k]$, $*$ 代表卷积。

2 本文算法

本文主要解决无人机在海上进行船舶跟踪时,由于遮挡、船舶离开视野导致目标丢失的问题。在跟踪

过程中实时判断跟踪可靠性,当候选区域与实际目标偏差较大时,使用 YOLOv5 算法对目标进行重定位从而提高算法跟踪精度,优化待解决问题,本文所提算法精度和速度接近实时性要求,算法框架如图 1 所示。




图 1 M-LTDT 算法流程

Fig. 1 Flowchart of the M-LTDT algorithm

2.1 重检测模块

在长时跟踪中,重检测模块对于相关跟踪器是必不可少的;当判断丢失目标时,检测器重新定位目标所在位置,并更新跟踪器初始状态后再次进行目标跟踪。

YOLO^[23] (you only look once) 是端到端的目标检测算法。将整幅图片作为输入,在一个步骤中完成目标分类及定位,检测速度可达 45 fps。从 2016 年提出后,到目前已经发展到 YOLOv8 版本。考虑无人机实际跟踪时精度和速度的平衡,本文选取精确度和实时速度均衡的 YOLOv5s 作为本文检测器的基线模型。

YOLOv5s 算法框架如图 2 所示,由输入端(input)、主干网络(backbone)、颈部模块(neck)和输出(output) 4 个部分组成。输入端(input)对原始图片进行预处理操作,即将输入图像尺寸缩放到 640×640,并且使用马赛克数据增强,提升训练效率的同时并加强模型的泛化能力。主干网络(backbone)主要作用是提取目标的通用特征图。输出(output)是利用提取的特征进行预测,在本文中使用预测坐标信息更新跟踪器初始状态。

2.2 联合置信策略

本文通过感知哈希算法和峰值比例方法综合评估跟踪结果的可靠性,以此来决定检测器启动时机。

1) 感知哈希

图像感知哈希算法^[24]是数据集感知摘要的一类单项映射,通过对图像感知信息的摘要提取并生成哈希值,找到与已知模板相似的图片,感知哈希算法流程如图 3 所示。具体步骤如下:




图 2 YOLOv5s 整体结构

Fig. 2 YOLOv5s overall structure

(1) 缩小尺寸:图像预处理,缩小尺寸为 32×32。

(2) 简化色彩:转化为灰度图,将 RGB 颜色空间转化为 YUV 空间,如式(4)所示。

$$\begin{bmatrix} Y \\ U \\ V \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ -0.147 & -0.289 & 0.436 \\ 0.615 & -0.515 & -0.100 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (4)$$

其中, Y 近似代表灰度图, U 和 V 表示彩色分量。

(3) 计算 DCT:对预处理图像进行 DCT 换,表达式为:

$$f(u, v) = c(u) c(v) \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \cdot \cos \frac{\pi(2x+1)}{2M} \cos \frac{\pi(2y+1)}{2N} \quad (5)$$




图 3 感知哈希流程

Fig. 3 Flowchart of perceptual hash

在式(5)中:

$$c(u)=\begin{cases}\sqrt{\frac{1}{M}}, & u=0 \\ \sqrt{\frac{2}{M}}, & u\neq 0\end{cases}\quad c(v)=\begin{cases}\sqrt{\frac{1}{N}}, & u=0 \\ \sqrt{\frac{2}{N}}, & u\neq 0\end{cases}\quad (6)$$

其中, $f(u,v)$ 为 DCT 变换后的交流系数, $f(x,y)$ 为变换前的系数, M,N 分别为 x,y 两个方向上的总像素点数。

(4) 计算均值: 计算 64 个 DCT 系数的均值 E :

$$E=\frac{1}{64}\sum_{v=1}^8\sum_{u=1}^8f(u,v)\quad (7)$$

将 DCT 变换后的交流系数 $f(u,v)$ 与均值 E 进行比较。当 $f(u,v) < E$, 记为 1; 当 $f(u,v) \geq E$, 记为 0。表达式如下:

$$h(x,y)=\begin{cases}0, & f(u,v) < E \\ 1, & f(u,v) \geq E\end{cases}\quad (8)$$

(5) 构造 Hash 值: 将对比出的结果串联成 64 个一维向量, 组合得到 64 位 Hash 值则为目标的编码值。

(6) 对比指纹: 将相邻帧的 Hash 编码进行“指纹”匹配, 当前帧的编码值为 $h \in \{0,1\}^l$, 上一帧的编码值为 $h' \in \{0,1\}^l$ 。匹配函数如下:

$$\begin{aligned}dis &= HamDistance(h,h') \\ sim &= \begin{cases}(1 - dis/10) \times 100\%, & dis \leq 10 \\ 0, & dis > 10\end{cases}\end{aligned}\quad (9)$$

其中, $HamDistance$ 为汉明距离计算函数, dis 为相邻帧的汉明距离, sim 为相邻帧的相似度。

如图 4 所示, 当相邻两帧之间目标变化较小时, 汉明距离 dis 数值较低; 而目标外观变化较大时, dis 数值偏大 (图片序列及标注点对应帧数)。当 $dis > 10$ 时, 此时哈希相似度 sim 偏小, 相邻帧目标外观变化较大, 表明此时算法跟踪可能存在较大偏移, 跟踪结果并不可靠, 因此本文将阈值设定为 10。




图 4 哈希值变化曲线

Fig. 4 Hash value change curves

2) 峰值比例

在跟踪过程中, 仅使用感知哈希去判别跟踪器可靠性存在一定的局限, 为了提高跟踪置信度的评估精度, 进一步降低检测器的误触发率。本文引入峰值比例计算方

法 (ratio between the second and first major mode, RSFM), 通过计算当前帧响应最大峰值与次峰值的比例, 评估跟踪可靠性, 函数表达式如下:

$$\gamma = 1 - \min\left(\frac{G_{ps}}{G_{pf}}, R_0\right) \quad (10)$$

其中, G_{pf} 为当前响应最大峰值, G_{ps} 为当前响应次峰值, 为了防止计算比值后有多组相似的模态表示, 故将比值限制为 R_0 , R_0 一般取值为 0.5。 γ 越接近 1, 表示当前跟踪可靠性越高。

本文根据感知哈希算法与 RSFM 方法综合评估跟踪可靠性。公式表示如下:

$$\text{Result} = \begin{cases} 1, & \text{dis} < 10 \text{ and } \gamma > R_0 \\ 0, & \text{其他} \end{cases} \quad (11)$$

当汉明距离 dis 小于预设阈值且峰值比例 γ 大于 R_0 时, 表示当前跟踪置信度高; 反之则启用重检测器重定位目标所在位置。

2.3 旋转跟踪框

在跟踪场景下, 目标会存在不同程度的旋转运动, ECO_HC 算法无法在目标发生旋转运动时准确进行跟踪。因此, 本文将傅里叶-梅林变换^[25]与跟踪算法相结合以此提高本文算法的旋转适应性。

傅里叶-梅林变换具体过程如下: 1) 将输入图像进行傅里叶变换得到对数极坐标图像; 2) 对数极坐标图像进行高斯滤波; 3) 通过对数坐标变换得到仅有平移因子和尺度因子的对应关系。经过以上变换, 目标的旋转运动转换为平移运动, 通过计算可以获得目标旋转角度, 进而得到新的跟踪框。

当前第 i 帧特征滤波器得到的目标区域图像块 $f_i(x, y)$ 是第 $i-1$ 帧图像块 $f_{i-1}(x, y)$ 经过一系列变换所得。变换中心为原点 $(0, 0)$, 旋转变换为 $\Delta\theta$, 尺度变换为 ∂ , 位移向量为 $(\Delta x, \Delta y)$ 。第 i 帧图像块 $f_i(x, y)$ 可以表示为:

$$f_i(x, y) = f_{i-1}(\partial(x\cos\Delta\theta + y\sin\Delta\theta) - \Delta x, \partial(-x\sin\Delta\theta + y\cos\Delta\theta) - \Delta y) \quad (12)$$

对式(12)进行傅里叶变换, 忽略平移因子, 得到傅里叶谱 $|F_i(u, v)|$ 和 $|F_{i-1}(u, v)|$, 两者关系表达式如式(13)所示。

$$|F_i(u, v)| = F_{i-1}\left(\frac{u\cos\Delta\theta + v\sin\Delta\theta}{\partial}, \frac{-u\sin\Delta\theta + v\cos\Delta\theta}{\partial}\right) \quad (13)$$

由式(13)可知两者仅存在尺度和旋转变换的关系。在笛卡尔坐标系下, 进行尺度和旋转计算复杂度偏高, 故通常使用坐标变换将其转换到对数坐标系下。转换公式如下:

$$\rho = \log(\sqrt{(x - x_0)^2 + (y - y_0)^2}) \quad (14)$$

$$\theta = \arctan\left(\frac{y - y_0}{x - x_0}\right) \quad (15)$$

其中, (x_0, y_0) 为转换过程中的极点, 将式(13)取对数, 并把式(14)和(15)代入其中得:

$$Q_{F_i}(\log(\rho_{F_i}), \theta_{F_i}) = Q_{F_{i-1}}(\log(\rho_{F_i}) - \log(\partial), \theta_{F_i} - \Delta\theta) \quad (16)$$

其中, Q_{F_i} 和 $Q_{F_{i-1}}$ 为 $\log(|F_i(u, v)|)$ 和 $\log(|F_{i-1}(u, v)|)$ 的对数极坐标图像, $\rho_{F_i} = \sqrt{u^2 + v^2}$, $\theta_{F_i} = \arctan(v/u)$ 。用 (ω, φ) 表示 $(\log(\rho_{F_i}), \theta_{F_i})$, 式(16)可以表示为:

$$Q_{F_i}(\omega, \varphi) = Q_{F_{i-1}}(\omega - \Delta\omega, \varphi - \Delta\varphi) \quad (17)$$

经过计算, 目标图像的旋转变化转换为对数坐标轴的平移运动, 得到目标的旋转角度 $\Delta\theta$ 。根据跟踪器预测的目标中心位置 (pos_x, pos_y) , 最终完成对原始跟踪框的旋转变换, 旋转矩阵 ϕ 如下:

$$\phi = \begin{bmatrix} \cos(\Delta\theta) & -\sin(\Delta\theta) & 0 \\ \sin(\Delta\theta) & \cos(\Delta\theta) & 1 \\ 0 & 0 & 1 \end{bmatrix} \quad (18)$$

3 实验结果与分析

3.1 实验环境

实验在 Windows10 系统环境下, 选用 Visual Studio 2017 作为算法平台, 算法语言为 C++; 计算机硬件配置为 Intel Core i7-4700MQ CPU, 内存大小 8 GB。对比算法实验参数均采用论文中原始参数设置, 保证实验客观公正。

3.2 旋转跟踪评估

本节主要验证本文算法对目标旋转运动的适应性, 选择 OTB_100^[26] 中目标存在明显旋转变化且其他干扰因素较少的 Vase 序列和 Jump 序列进行对比实验分析。

如图 5 所示, 引入傅里叶-梅林变换后的长期跟踪框架在目标发生旋转时, 本文算法跟踪框能进行不同角度的旋转变化, 提高了目标发生旋转变化时算法的鲁棒性。

3.3 评估指标

实验采取 OTB-100^[26] 数据集作为测试数据集。选择 OTB-100 中目标遮挡、运动模糊、离开视野、尺度大幅度变化等挑战场景, 共 16 组序列作为对比实验测试序列。挑战属性包含遮挡 (occlusion, OCC)、运动模糊 (motion blur, MB)、离开视野 (out-of-view, OV)、尺度变化 (scale variation, SV) 等, 测试序列如表 1 所示。

实验方法采用一次验证评估法 (one-pass evaluation, OPE), 并采用精确度和成功率作为跟踪性能评价标准。精确度为跟踪序列中目标中心定位误差 (CLE) 小于设定阈值的帧数占比。

$$S_r = \frac{|area(r_c) \cap area(r_0)|}{|area(r_c) \cup area(r_0)|} \quad (19)$$




图 5 旋转目标跟踪验证结果

Fig. 5 Rotating target tracking verification results

表 1 具有代表性的序列名称和属性

Table 1 Representative sequence names and attributes

序列名称	属性	序列名称	属性
Biker	OCC, MB, OV, SV	Ironman	OCC, MB, OV
Bird1	OV	Kitesurf	OCC, IV
Blurow1	SV, FM, MB	Matrix	OCC, SV
Box	OCC, OV, MB	MotorRolling	MB, SV
DragonBaby	OCC, MB, OV, SV	Panda	OCC, SV
Dudek	OCC, OV, SV	Skiing	SV
Girl2	OCC, SV, MB	Trans	SV
Human3	OCC, SV	Vase	SV

其中, r_c 为跟踪预测的目标框, r_0 为人工标注的真实框, $area(r_c)$ 是预测框的面积, $area(r_0)$ 表示真实框的面积。

3.4 定量分析

为验证本文算法在跟踪过程中的性能,将本文算法 (M-LTDT) 与 LADCF (learning adaptive discriminative correlation filters)^[27]、ECO^[7]、ECO_HC^[7]、STRCF^[8]、BACF (background-aware correlation filters)^[5]、Staple (sum of template and pixel-wise learners)^[28]、KCF (kernelized correlation filters)^[4] 8 种主流算法进行比较。如图 6 所示,本文算法精确度为 83.9%,成功率为 76.7%,整体性能优于其他算法,跟踪性能有显著提升。




图 6 8 种算法的精度图和成功率图

Fig. 6 Precision plot and success plot of the eight algorithms

如表 2 所示,由于 ECO 使用 CNN 特征,计算复杂度高,算法耗时长;本文算法跟踪速率为 20.62 fps,由于重检测器启动及再初始化跟踪器耗时较长,跟踪速度有一定程度影响。

表 2 不同算法跟踪速率

Table 2 Tracking speed of different algorithms

算法	M-LTDT	ECO	ECO_HC
跟踪速率/fps	20.62	2.19	49.36

3.5 定性分析

如图 7 所示为 8 种算法在不同复杂场景序列下的实验分析,采用 4 种线型与两种线宽组合来表示不同算法跟踪结果。

1) 离开视野(OV):图 7(a) Bird1 跟踪结果所示,飞鸟在较长一段时间被云层遮蔽,导致在后续多数跟踪器模型错误更新,无法准确定位目标位置,多数跟踪器发生丢失跟踪目标;本文算法通过置信度策略判断当前跟踪结果并不可靠后,触发检测器检测目标位置并初始化跟踪器,消除了跟踪器累计的错误信息,重新定位目标,因此在后续能准确跟踪目标。

2) 尺度变化(SV):图 7(b)和(c)跟踪结果所示,目标外观在较短时间内发生明显变化,此时相邻帧之间目标哈希值变化较大,峰值比例变化剧烈。本文算法在匹配到目标尺度发生变化时,能再次准确跟踪目标对象。对比算法在目标姿态、位置发生显著变化时均无法定位跟踪对象,跟踪框发生大范围偏移。

3) 遮挡(OCC):图 7(d)和(e)跟踪结果所示,目标所处背景变化剧烈,且目标外观变化显著。由闪光、烟雾和雨水造成的遮挡和目标形变令跟踪难度加大。在图 7(d) 100 帧左右仅有本文算法和 ECO 算法能精确定位目标;但在 145 帧左右由于检测器未识别到目标导致丢失目标;在图 7(e),当目标背景过明或过暗时,多数跟踪器无法在背景显著变化下准确识别目标位置,本文算法通过重检测能在 44 帧和 93 帧目标难以识别的情况下准确定位目标。

4) 运动模糊(MB):图 7(f)跟踪结果所示,由于摩托手手的快速翻转和移动引起的运动模糊导致多数跟踪器在跟踪初期就丢失目标;本文算法在整个过程中基本能稳定跟踪目标,虽然期间会出现模型漂移情况,但经过重检测器重新定位目标后,后续依然能很好的完成跟踪任务。

3.6 海上船舶跟踪实验

为了验证本文算法在海上对船舶跟踪的精确度和鲁棒性,搭建无人机平台进行船舶跟踪实验。对完全遮挡和离开视野的两种干扰因素分别进行两组实际场景定



图7 The proposed, ECO^[7], ECO-HC^[7], LADCF^[27], STRCF^[8], BACF^[5], Staple^[28], KCF^[4] 算法跟踪结果

Fig. 7 Track results of the proposed, ECO^[7], ECO-HC^[7], LADCF^[27], STRCF^[8], BACF^[5], Staple^[28], and KCF^[4] algorithms

性和定量实验分析,给出目标即将丢失和再次跟踪时跟踪效果。

1) 平台搭建如图8所示,跟踪实验平台由地面站和空中平台两部分组成。无人机型号为大疆经纬 M100,搭配三轴旋转云台,摄像头选用 DJI 禅思 Z3,使用 LightBridge2 无线图传,并在遥控端通过 HDMI 转 AV 视频转换器接收信息,然后使用 AV 转 USB 设备连接计算机接收实时图像信息。

2) 实验分析

如图9所示,本文算法与 ECO_HC 算法在海上实际跟踪场景跟踪结果曲线。本文算法在两种干扰因素下的

精确度和成功率分别为 80.9%, 60.4% 和 90.2%, 48.3%, 远高于基准算法,算法性能得到显著提升。

(1) 遮挡

如图10(a)所示,在79帧船舶发生快速转向后激起的浪花遮挡船身,本文算法能在完全遮挡后重新定位目标位置;而 ECO_HC 算法由于错误信息的累计导致丢失目标。如图10(b)所示,在207帧海面强反光遮挡视野,在238帧本文算法能重新定位目标,而 ECO_HC 在后续帧发生严重漂移,无法准确跟踪目标。

(2) 离开视野

如图10(c)所示,目标在55帧离开检测视野,在



Fig. 8 Track experiment platform architecture

78 帧再次出现时,由于重检测器的加入,本文算法能再次定位目标位置。如图 10(d) 所示,在 255 帧云台发生大幅度转动,ECO_HC 算法模型发生严重漂移;本文算法经过置信度评估当前可靠性较低,并启用检测器重新检测目标位置,迅速找回并持续跟踪目标。




Fig. 9 Comparison chart of maritime tracking performance in different scenarios



图 10 不同场景海上跟踪实验定性分析
Fig. 10 Qualitative analysis of maritime tracking experiments in different scenarios

4 结 论

为实现无人机对海上运动船舶的长期稳定跟踪的目的,本文提出一种基于核相关滤波的长期跟踪(M-LTDT)算法,使用感知哈希方法和RSFM方法综合评估跟踪器可靠性,目标丢失后利用重检测器重新定位目标;并将傅里叶-梅林变换与跟踪框架结合以解决传统跟踪框角度固定的问题,以此适应目标的旋转变换。在公共数据集和实际海上实验分析得证本文所提算法的有效性和鲁棒性。但在实际跟踪应用,场景复杂多变,未来的研究中还需考虑对目标重检测进行更深入的探索。

参考文献

- [1] LI W, GE Y, GUAN Z, et al. Synchronized motion-based UAV-USV cooperative autonomous landing [J]. Journal of Marine Science and Engineering, 2022, 10(9): 1214.
- [2] WANG Y, LIU W, LIU J, et al. Cooperative USV-UAV marine search and rescue with visual navigation and reinforcement learning-based control [J]. ISA Transactions, 2023.
- [3] 韩瑞泽, 冯伟, 郭青, 等. 视频单目标跟踪研究进展综述[J]. 计算机学报, 2022, 45(9): 1877-1907.
HAN R Z, FENG W, GUO Q, et al. Single object tracking research: A survey [J]. Chinese Journal of Computer, 2022, 45(9): 1877-1907.
- [4] HENRIQUES J F, CASEIRO R, MARTINS P, et al. High-speed tracking with kernelized correlation filters [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(3): 583-596.
- [5] KIANI GALOOGAHI H, FAGG A, LUCEY S. Learning background-aware correlation filters for visual tracking [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 1135-1143.
- [6] FU C, LI B, DING F, et al. Correlation filters for unmanned aerial vehicle-based aerial tracking: A review and experimental evaluation [J]. IEEE Geoscience and Remote Sensing Magazine, 2021, 10(1): 125-160.
- [7] DANELLJAN M, BHAT G, SHAHBAZ KHAN F, et al. Eco: Efficient convolution operators for tracking [C]. IEEE International Conference on Computer Vision and Pattern Recognition, 2017: 6638-6646.
- [8] LI F, TIAN C, ZUO W, et al. Learning spatial-temporal regularized correlation filters for visual tracking [C]. IEEE International Conference on Computer Vision and Pattern Recognition, 2018: 4904-4913.
- [9] FU C, LIN F, LI Y, et al. Correlation filter-based visual tracking for UAV with online multi-feature learning [J]. Remote Sensing, 2019, 11(5): 549.
- [10] LI Y, FU C, DING F, et al. AutoTrack: Towards high-performance visual tracking for UAV with automatic spatio-temporal regularization [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2020: 11923-11932.
- [11] YUAN D, CHANG X, LI Z, et al. Learning adaptive spatial-temporal context-aware correlation filters for UAV tracking [J]. ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM), 2022, 18(3): 1-18.
- [12] ZHANG J, FENG W, YUAN T, et al. SCSTCF: Spatial-channel selection and temporal regularized correlation filters for visual tracking [J]. Applied Soft Computing, 2022, 118: 108485.
- [13] 白中浩, 朱磊, 李智强. 基于多模型融合和重新检测的高精度鲁棒目标跟踪[J]. 仪器仪表学报, 2019, 40(9): 132-141.
BAI ZH H, ZHU L, LI ZH Q. High-accuracy and robust object tracking based on multi-model fusion and re-detection [J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 132-141.
- [14] YANG J, TANG W, DING Z. Long-term target tracking of UAVs based on kernelized correlation filter [J]. Mathematics, 2021, 9(23): 3006.
- [15] 吴涛, 袁亮. 多特征融合且抗遮挡的长时目标跟踪算法[J]. 计算机工程与设计, 2021, 42(1): 226-231.
WU T, YUAN L. Multifeature fusion and antiocclusion long-term object tracking algorithm [J]. Computer Engineering and Design, 2021, 42(1): 226-231.
- [16] 陈仁祥, 何家乐, 杨黎霞, 等. 基于加权在线样本更新的目标长时跟踪方法[J]. 仪器仪表学报, 2023, 44(6): 66-73.
CHEN R X, HE J L, YANG L X, et al. Target long-term tracking method on weighted online sample update [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 66-73.
- [17] ZHOU Z, CHEN J, PEI W, et al. Global tracking via ensemble of local trackers [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2022: 8761-8770.
- [18] CHEN X, YAN B, ZHU J, et al. Transformer tracking [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2021: 8126-8135.
- [19] WANG X, TANG J, LUO B, et al. Tracking by joint local and global search: A target-aware attention-based approach [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33(11): 6931-6945.
- [20] ZHAO H, YAN B, WANG D, et al. Effective local and global search for fast long-term tracking [J]. IEEE

- Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(1): 460-474.
- [21] FAN Y, FEI F, WANG G, et al. PSR-based feature adaptation with anomaly re-prediction for maritime target tracking[C]. Chinese Control Conference (CCC). IEEE, 2022: 6672-6677.
- [22] 范云生, 孙涛, 王国峰, 等. 基于海空双视觉协同的无人艇载无人机自主降落与验证[J]. 大连海事大学学报: 自然科学版, 2022(2): 48.
FAN Y SH, SUN T, WANG G F, et al. Autonomous landing and verification of unmanned boat-borne UAVs based on dual vision collaboration between sea and air[J]. Journal of Dalian Maritime University: Natural Science Edition, 2022(2): 48.
- [23] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [24] FEI M, JU Z, ZHEN X, et al. Real-time visual tracking based on improved perceptual hashing[J]. Multimedia Tools and Applications, 2017, 76: 4617-4634.
- [25] 熊丹, 卢惠民, 肖军浩, 等. 具有尺度和旋转适应性的长时间目标跟踪[J]. 自动化学报. 2019, 45(2): 289-304.
XIONG D, LU H M, XIAO J H, et al. Robust long-term object tracking with adaptive scale and rotation estimation[J]. Acta Automatica Sinica, 2019, 45(2): 289-304.
- [26] WU Y, LIM J, YANG M H, et al. Object tracking benchmark[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015. 37(9): 1834-1848.
- [27] XU T, FENG Z H, WU X J, et al. Learning adaptive discriminative correlation filters via temporal consistency preserving spatial feature selection for robust visual object tracking[J]. IEEE Transactions on Image Processing, 2019, 28(11): 5596-5609.
- [28] BERTINETT L, VALMADRE J, GOLODETZ S, et al. Staple: Complementary learners for real-time tracking[C]. IEEE International Conference on Computer vision and Pattern Recognition, 2016: 1401-1409.

作者简介



范云生(通信作者), 分别于 2004 年、2007 年和 2012 年获得大连海事学士学位、硕士学位和博士学位, 现为大连海事大学船舶电气工程学院教授, 主要研究方向为无人系统智能控制、智能感知与自主控制、集群智能与测试评估。

E-mail: yunsheng@dlmu.edu.cn


Fan Yunsheng (Corresponding author) received B. Sc., M. Sc. and Ph. D. degrees all from Dalian Maritime University in 2004, 2007, and 2012, respectively. He is currently a professor with the College of Marine Electrical Engineering at Dalian Maritime University. His main research interests include automation and autonomy, with a special interest in the exploration of technologies for intelligent control of unmanned systems, intelligent perception and autonomous control, swarm intelligence and test evaluation.



张凯, 2019 年于青岛理工大学获得学士学位, 现为大连海事大学硕士研究生, 主要研究方向为图像处理、目标跟踪。

E-mail: 17805420323@163.com

Zhang Kai received his B. Sc. degree from Qingdao University of Technology in 2019. He is currently a master student at Dalian Maritime University. His main research interests include image processing and target tracking.



牛龙辉, 2016 年和 2020 年分别获得洛阳理工学院和西安工程大学的学士、硕士学位, 现为大连海事大学博士研究生, 研究方向为无人水面艇的视觉感知。

E-mail: niu2021@dlmu.edu.cn

Niu Longhui received B. Sc. and M. Sc. degrees both from Luoyang Institute of Science and Technology and Xi'an Polytechnic University in 2016 and 2020. He is currently a Ph. D. candidate at Dalian Maritime University. His research interest is visual perception of unmanned surface vehicles.



刘婷, 2016 年获得哈尔滨工业大学控制科学与工程博士学位, 现任大连海事大学讲师, 主要研究方向为视觉感知和深度学习。

E-mail: liuting0910@dlmu.edu.cn

Liu Ting received her Ph. D. degree in Control Science and Engineering from Harbin Institute of Technology in 2016. She is currently a lecturer at Dalian Maritime University. Her research interests include visual perception and deep learning.



费凡, 2019 年于绥化学院获得学士学位, 2023 年于大连海事大学获得硕士学位, 主要研究方向为图像处理、目标跟踪。

E-mail: qq15245780999@163.com

Fei Fan received his B. Sc. degree from Suihua University in 2019 and M. Sc. degree from Dalian Maritime University in 2023. His main research interests include image processing and target tracking.