控制与决策
Control and Decision

基于事件触发的时变风场下无人机实时路径重规划策略

宋璐璐, 邓超, 范莎

引用本文:
宋璐璐, 邓超, 范莎. 基于事件触发的时变风场下无人机实时路径重规划策略[J]. 控制与决策, 2026, 41(3): 835-844.

在线阅读 View online: https://doi.org/10.13195/j.kzyjc.2024.1341

您可能感兴趣的其他文章

Articles you may be interested in

面向多目标侦察任务的无人机航线规划

UAV trajectory planning for multi-target reconnaissance missions

控制与决策. 2021, 36(5): 1191-1198 https://doi.org/10.13195/j.kzyjc.2019.1284

输入受限的多旋翼无人机轨迹跟踪鲁棒正定不变集设计

Design of robust positively invariant set for trajectory tracking of multirotor UAV with input saturation

控制与决策. 2021, 36(4): 857-866 https://doi.org/10.13195/j.kzyjc.2019.0880

四旋翼无人机抗干扰轨迹跟踪控制

Anti-interference trajectory tracking control of quadrotor UAV

控制与决策. 2021, 36(2): 379-386 https://doi.org/10.13195/j.kzyjc.2019.0875

基于领航-跟随的有人/无人机编队队形保持控制

Formation keeping control for manned/unmanned aerial vehicle formation based on leader-follower strategy

控制与决策. 2021, 36(10): 2435-2441 https://doi.org/10.13195/j.kzyjc.2020.0453

基于仿生算法改进粒子滤波的SLAM算法精度预测

Accuracy predition of SLAM algorithm based on bionic algorithm to improve particle filter

控制与决策. 2021, 36(1): 166-172 https://doi.org/10.13195/j.kzyjc.2019.0555

基于事件触发的时变风场下无人机实时路径重规划策略

宋璐璐[1]，邓 超[2]，范 莎[1†]

(1. 南京邮电大学 自动化学院，南京 210042；2. 南京邮电大学 碳中和先进技术研究院，南京 210042)

摘 要: 针对无人机在飞行过程中受时变风场影响导致的能耗和飞行状态变化问题, 提出一种基于事件触发机制的实时路径重规划策略. 首先, 采用改进的粒子群优化 (IPSO) 算法进行路径规划, 并通过评估不同风场下规划路径的相似度量化风场变化对规划路径的影响. 进一步, 应用卡尔曼滤波 (KF) 算法预测无人机飞行状态, 并根据实际飞行状态与预测状态之间的误差, 评估风场变化对预测准确度的影响. 在此基础上, 设计一种基于事件触发机制 (ETM) 的路径重规划策略, 使无人机仅在风场变化超过设定阈值时执行路径更新. 仿真实验结果表明, 该策略可显著降低无人机飞行过程中的能耗和计算负担, 同时增强无人机在复杂风场条件下的适应能力.

关键词: 无人机；路径规划；改进的粒子群优化算法；卡尔曼滤波算法；事件触发机制；时变风场

中图分类号: V279；TP242.6 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2024.1341

引用格式: 宋璐璐, 邓超, 范莎. 基于事件触发的时变风场下无人机实时路径重规划策略 [J]. 控制与决策, 2026, 41(3): 835-844.

Real-time path replanning strategy for UAVs in time-varying wind fields based on event-triggered mechanism

SONG Lu-lu[1]，*DENG Chao*[2]，*FAN Sha*[1†]

(1. College of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210042, China；2. Institute of Advanced Technology, Nanjing University of Posts and Telecommunications, Nanjing 210042, China)

Abstract: This study addresses the challenges of managing energy consumption and flight state variation in unmanned aerial vehicles (UAVs) operating in time-varying wind fields by proposing a real-time path replanning strategy based on an event-triggered mechanism (ETM). The approach first employs an improved particle swarm optimization (IPSO) algorithm for path planning, which assesses the similarity between paths under varying wind conditions to quantify the impact of wind field changes on the current path. Additionally, a Kalman filter (KF) is applied to predict the flight state of a UAV, evaluating the effect of wind variations on state prediction accuracy by comparing actual and predicted states. Based on these insights, an ETM is established to update the path only when wind field changes exceed a specified threshold. Simulation results demonstrate that the proposed strategy significantly reduces energy consumption and computational load, while enhancing the adaptability in complex wind environments.

Keywords: UAV；path planning；improved particle swarm optimization algorithm；Kalman filter algorithm；event-triggered mechanism；time-varying wind fields

0 引 言

无人机广泛应用于军事侦察、环境监测、物流运输等领域, 其自主飞行能力是提高任务执行效率和保障飞行安全的关键技术[1]. 路径规划作为无人机自主飞行的核心技术, 直接影响其飞行效率、任务执行准确度以及整体安全性[2]. 在复杂环境中, 风场作为主要的外部干扰因素之一, 会显著影响无人机的飞行轨迹、能耗和稳定性, 与此同时, 风场的动态变化增加了路径规划的复杂性. 因此, 深入研究时变风场对无人机路径规划的影响, 开发适应风场变化的实时路径规划方法, 已成为当前无人机自主飞行技术研究的热点[3]. 通过动态调整路径以适应实时风场变化, 可以提高无人机对顺风场的利用率及对逆风场的适应性, 从而在降低飞行能耗的同时提升自主飞行的安全性. 然而, 频繁的路径更新可能导致额外的控制成本和误差, 包括转向曲率的增加及路径更新

收稿日期: 2024-11-18；**录用日期:** 2025-09-08.
责任编委: 张海涛.
†通信作者. E-mail: shafan90@163.com.

过程中的偏差[4-5]. 因此, 根据实时风场的变化有效地调整飞行路径, 以提升无人机在复杂环境中的自主飞行能力和任务执行效率, 具有重要的理论和实践意义.

目前, 针对风场影响下的无人机路径规划问题, 研究人员提出了如 A*算法等一系列解决方案. Sun 等[4] 提出了一种结合风场数据和三维地形信息的改进 A*算法, 通过引入风场成本与距离成本, 优化无人机的飞行路径; Xu 等[5] 提出了一种改进的 P-RRT*算法, 通过人工势场引导路径扩展, 并剪除冗余节点, 提高路径规划效率. 上述算法能够高效生成规划路径, 但依赖于预加载的环境信息, 且对实时风场变化的响应能力较弱. Theile 等[6] 提出了一种基于双深度Q网络算法的自主无人机路径规划方法, 通过全局与局部地图信息, 使无人机能够在复杂风环境中动态调整飞行路径; Zhang 等[7] 提出了一种基于长短期记忆网络的实时路径规划算法, 结合分层奖惩机制提升了固定翼无人机在复杂环境中的适应性. 然而, 这些深度学习方法虽表现优异, 但需要大量训练数据, 且实时计算需求较高, 在资源受限的设备上实现具有一定的挑战性.

智能优化算法具备良好的环境适应性和强大的全局优化能力, 已逐渐应用于风场动态变化环境下的无人机路径规划问题中[8]. 遗传算法 (GA)[9-10] 通过模拟自然选择和变异机制搜索最优解, 能够随风场变化调整路径, 具有较强的鲁棒性, 但收敛速度相对较慢 ; 蚁群优化 (ACO) 算法[11-12] 通过模拟蚂蚁觅食行为适应风场变化, 适用于多障碍物场景, 但在大规模问题上计算复杂度较高; 粒子群优化 (PSO) 算法[13-15] 以群体智能模拟优化路径, 具有计算量低、收敛速度快的优点, 能够有效寻找较优路径解. 然而, 在复杂环境中, 传统的 PSO算法容易陷入局部最优. 同时, 在频繁变化的风场下, 其信息交互量较大, 影响实时性. 针对传统 PSO 在复杂环境中的局部最优及响应时间问题, 文献 [13]结合 PSO 和深度策略梯度优化山区路径规划, 显著减少了能耗; 文献 [14] 结合 PSO 和遗传算法并引入动态惯性权重, 适应能耗密集的动态环境, 降低了风场下无人机的能耗; 文献 [15] 通过混沌初始化、自适应加速度系数等方法改进 PSO, 增强了三维路径规划能力.

前文综述了风场环境下的无人机路径规划方法, 然而, 在时变风场中, 无人机是否更新规划路径, 还取决于其飞行状态, 因此需要对无人机的状态进行预测. 卡尔曼滤波(KF)算法因其在无人机飞行状态预测与控制中的优异性能, 被广泛应用[16-17]. 文献 [16] 提出的分布式卡尔曼模型预测控制算法提高了多无人机编队的稳定性; 文献 [17] 提出的无迹卡尔曼滤波器结合李雅普诺夫矢量场引导, 解决了固定翼无人机在未知风场中的远程跟踪问题; 文献 [18] 提出的多速率卡尔曼滤波器算法, 通过自适应模型与干扰抑制提高了姿态估计精度. 因此, 本研究采用 KF 算法预测无人机执行上一时刻路径的飞行状态.

另一方面, 事件触发机制 (ETM) 是一种在动态系统中通过检测事件触发条件来激活控制更新的策略, 相较于传统的时间触发控制, ETM 通过在必要时刻触发控制, 显著减少了资源消耗. 文献 [2] 提出了一种基于事件触发的无人机轨迹调整与恢复策略, 使无人机仅在必要时执行动态避障操作, 有效降低了不必要的控制更新频率; 文献 [19] 设计了一种基于事件触发的模型预测控制算法, 在保证车辆对参考轨迹跟随精度的前提下, 减少了在线求解优化问题的计算量, 从而降低了实时优化的计算负担. 鉴于 ETM 的优势, 为了实现无人机规划路径根据风场变化的适应性调整, 本文将 ETM 应用于风场变化事件的监测与路径重规划响应中.

综上所述, 本文旨在研究无人机在飞行过程中受时变风场影响导致的能耗与飞行状态变化问题. 在复杂的风场环境中, 实时更新规划路径虽然能够提升无人机的适应性, 但频繁的路径重规划可能导致额外的控制成本和误差. 如何在风场变化时优化路径更新频率, 确保路径的合理性, 成为本文的研究难点. 为此, 本文提出一种基于事件触发机制的无人机实时路径重规划策略, 将路径相似度与状态预测准确度相结合, 作为判断是否更新路径的依据, 以优化风场扰动下的系统稳健性和响应速度, 主要贡献包括:

1) 提出改进的粒子群优化 (IPSO) 算法对无人机飞行路径进行规划, 进一步计算不同风场条件下规划路径的相似度, 以评估风场变化对规划路径的影响.

2) 利用 KF 算法预测时变风场下不同规划路径中无人机的飞行状态, 通过计算真实状态与预测状态的误差来衡量风场变化对飞行状态预测准确度的影响.

3) 提出一种基于事件触发机制 (ETM) 的实时路径重规划策略, 根据上述风场变化对规划路径和无人机状态预测准确度影响准则, 设定风场变化的阈值. 当风场变化超出该阈值时, 系统自动更新规划路径, 确保无人机能够迅速响应环境变化并调整飞行路径, 降低飞行能耗和计算负担.

1　问题描述

考虑如下场景: 一架无人机由起点出发, 穿过时变风场, 到达目标点. 时变风场由多个恒定风场和随机风场共同构成, 恒定风场是指气象学中可评估和预测的风的长期行为, 随机风场是指不可预测的风场波动和脉动.

1.1　建立线性无人机模型

本文考虑如下无人机的离散线性模型:

$$x(k+1)=Ax(k)+Bu(k). \tag{1}$$

其中: A和B是常数矩阵; $x(k)=[p^{\mathrm{T}}(k),v^{\mathrm{T}}(k)]^{\mathrm{T}}$ 是无人机在k时刻的状态; $p^{\mathrm{T}}(k)\in\mathbb{R}^3$ 和 $v^{\mathrm{T}}(k)\in\mathbb{R}^3$分别是无人机在$k$时刻的位置和速度; $u(k)\in\mathbb{R}^3$是对系统施加的控制量.

注 1　本文侧重于研究无人机的轨迹重规划问题, 旨在生成安全、节能的飞行规划轨迹. 为了简化计算过程, 将无人机视为质点模型, 这种处理方式在轨迹规划问题中已被广泛应用[2,9].

1.2　风场对无人机速度的影响

为了优化无人机路径规划, 有必要充分考虑环境条件, 其中风场 (包括风速和风向) 是最为重要的因素之一, 因为风场的作用会改变无人机的地面速度, 从而对其飞行路径产生影响[3]. 下面给出风场对无人机空速的影响公式:

$$\vec{V}_{\mathrm{wind}}=[v_{\mathrm{wind}};\theta_{\mathrm{wind}}], \tag{2}$$

$$\vec{V}_{\mathrm{air}}=[v_{\mathrm{air}};\theta_{\mathrm{air}}], \tag{3}$$

$$\vec{V}_{\mathrm{ground}}=[v_{\mathrm{ground}};\theta_{\mathrm{ground}}]. \tag{4}$$

其中: 风向量$\vec{V}_{\mathrm{wind}}$中, v_{wind}是风相对于地面在单位时间内行进的距离, 而θ_{wind}是风的方向, 风速和风向数据来自气象网站的最新气象发布和实时检测数据; 空速向量 $\vec{V}_{\mathrm{air}}$是无人机在空中的速度, 这里v_{air}是空速大小, θ_{air}是空速方向角, 根据当前天气条件和无人机特性, 空速有一定的下限和上限; 地面速度向量$\vec{V}_{\mathrm{ground}}$是在飞行时无人机在地面上的投影速度, 通常会受到风的影响, v_{ground}是地面速度, θ_{ground}是航线角度. 三者之间的关系可以通过相应的矢量关系描述为

$$\vec{V}_{\mathrm{ground}}=\vec{V}_{\mathrm{air}}+\vec{V}_{\mathrm{wind}}\ . \tag{5}$$

1.3　本文的研究问题

本文的研究问题聚焦于无人机在时变风场环境中实现高效、安全的路径规划. 具体而言, 在风场变化影响无人机飞行的情况下, 如何确保路径规划的合理性, 减少系统计算负担, 并提高无人机的响应速度是主要难点. 因此, 本文的核心研究问题可以概括为:

1) 在时变风场的影响下, 如何设计路径规划算法, 使无人机能够在动态环境中生成合理的飞行路径, 从而保证飞行安全性和路径的有效性;

2) 如何基于风场变化判断是否更新路径, 从而减少因频繁路径重规划带来的计算负担和潜在响应延迟问题;

3) 如何结合路径相似度与状态预测准确度确定基于事件触发机制的路径更新策略, 确保无人机能够根据风场变化动态调整路径, 以提升系统在复杂环境下的稳健性和响应速度.

针对上述问题, 本文提出一种基于事件触发机制的路径重规划策略, 通过结合路径相似度评估和飞行状态预测, 在风场变化超出阈值时触发路径更新, 以确保无人机在复杂风场条件下实现高效且安全的飞行.

注 2　风场数据的获取手段多种多样, 包括气象站数据、遥感监测、激光雷达观测、机载传感器反馈以及数值天气预报模型等方法[20]. 限于篇幅, 本文并未详细探讨确定实时风场的具体方法, 而是侧重于风场数据在路径规划算法中的应用和优化策略的设计.

注 3　在变化复杂的风场条件下引入事件触发机制, 根据风场变化自动调整路径规划, 是本文的主要创新点之一. 这一机制有效增强了无人机对动态环境的响应能力, 提高了路径规划的适应性.

2　IPSO 路径规划及路径近似性

本节首先提出针对风场影响的 IPSO 路径规划算法, 随后, 借助 B 样条曲线[21] 拟合光滑路径, 并采用 Hausdorff 距离[22] 量化不同风场下规划路径相似度.

2.1　算法概述

在本节研究中, PSO 算法被用于无人机的路径规划, 通过模拟群体中 “粒子” 在搜索空间中寻找最优解的过程实现规划路径优化. 每个 “粒子” 代表一个可能的规划路径解, 其通过自身速度和位置的不断调整实现路径寻优. 每个 “粒子” 的更新公式[13-15]表示为

$$v_i^{t+1}=wv_i^t+c_1r_1(p_i^{\mathrm{best}}-x_i^t)+c_2r_2(g^{\mathrm{best}}-x_i^t), \tag{6}$$

$$x_i^{t+1}=x_i^t+v_i^{t+1}. \tag{7}$$

其中: v_i^t是第i个 “粒子” 在第t次迭代的速度; x_i^t是位置; w是惯性权重, 决定 “粒子” 之前速度对新速度的影响; c_1和c_2是学习因子, 控制 “粒子” 对自身最佳位置 p_i^{best}和全局最佳位置 g^{best}的趋势; r_1和r_2是 [0,

1] 之间的随机数.

本节针对风场影响下的路径规划问题, 从学习因子和惯性权重两个方面改进传统 PSO 算法. 为满足路径规划的实时性要求, 引入自适应学习因子 $c_1(t)$和$c_2(t)$动态调整式 (6) 中的c_1和c_2, 使粒子在不同阶段具备差异化的探索和开发能力. 在初期阶段, 通过增大个体学习因子$c_1(t)$, 以增强粒子的全局探索能力; 而在后期阶段, 逐步增大群体学习因子$c_2(t)$, 加快算法收敛速度, 从而更快地找到最优解[23], $c_1(t)$ 和 $c_2(t)$ 的具体计算公式如下:

$$c_1(t) = c_1^{\max} - \left(\frac{c_1^{\max} - c_1^{\min}}{T_{\max}}\right) \cdot t, \tag{8}$$

$$c_2(t) = c_2^{\min} + \left(\frac{c_2^{\max} - c_2^{\min}}{T_{\max}}\right) \cdot t. \tag{9}$$

其中: $c_1^{\max}$和$c_1^{\min}$分别是个体学习因子$c_1(t)$的最大值和最小值, $c_2^{\max}$和$c_2^{\min}$分别是群体学习因子$c_2(t)$的最大值和最小值, t是当前迭代次数, $T_{\max}$是最大迭代次数.

此外, 为提升路径规划中的全局优化能力, 本文引入混沌惯性权重策略$w(t)$[24], 通过混沌序列生成动态惯性权重, 以动态调整式 (6) 中的w, 增加搜索过程的多样性和有效性, 即

$$w(t) = w_{\min} + (w_{\max} - w_{\min}) \times \text{chaos}(t). \tag{10}$$

其中: $w_{\max}$ 和 $w_{\min}$ 分别是惯性权重 w 的最大和最小值; $\text{chaos}(t)$用于生成混沌序列的混沌映射函数, 本节选择Logistic映射, 其定义为

$$\text{chaos}(t) = r \times \text{chaos}(t-1) \times (1 - \text{chaos}(t-1)). \tag{11}$$

这里: r是控制参数, $\text{chaos}(t-1)$是前一迭代值, 初始值通常在区间 (0, 1) 内.

2.2 约束条件

在无人机路径规划问题中, 需要考虑以下约束条件, 以确保路径规划的有效性和安全性.

约束 1 在有强风或恶劣天气的区域, 无人机应调整路径或完全避开这些区域, 因此, 无人机规划路径风速应不大于无人机能够安全飞行的最大风速, 即

$$v_{\text{wind}} \leqslant v_{\text{wind-max}}. \tag{12}$$

其中: v_{wind}是实时风速, $v_{\text{wind-max}}$是无人机能够安全飞行的最大风速.

约束 2 障碍物 (如山峰) 需要视为不可访问区域, 设定障碍物约束为

$$\forall (x_i, y_i, z_i) \in L,\ (x_i, y_i, z_i) \notin O. \tag{13}$$

其中: L是无人机的规划路径, O是障碍物的空间位置集.

约束 3 为保证无人机能够保持足够的升力和稳定性, 约束无人机最小空速; 受限于结构、动力和安全, 约束无人机最大空速. 因此, 无人机空速v_{air} 应满足

$$v_{\text{air-min}} \leqslant v_{\text{air}} \leqslant v_{\text{air-max}}. \tag{14}$$

其中: $v_{\text{air-min}}$是无人机的最小空速, $v_{\text{air-max}}$是无人机的最大空速.

约束 4 为避免无人机因转弯半径过小而导致轨迹偏离或飞行失控问题, 规划路径上任意点的曲率半径 $R(s)$ 应满足以下约束:

$$R(s) \geqslant R_{\min},\ \forall s \in [0, L], \tag{15}$$

其中$R_{\min}$是无人机的最小允许转弯半径.

2.3 适应度函数

在 PSO 算法中, 适应度函数用于衡量每个“粒子”的质量, 即评估当前路径的优劣. 本研究适应度函数的设计如下:

$$\text{fit} = \alpha L_{\text{total}} + \beta K_{\text{avg}} + \gamma T_{\text{total}}. \tag{16}$$

其中: L_{total}是三维路径的总长度, K_{avg}是路径的平均曲率, T_{total}是总飞行时间; α, β, γ是相应指标的权重系数, 决定不同指标在路径规划中的影响权重. 通过最小化 fit, IPSO 算法可以在考虑路径长度、平滑性和飞行时间的基础上找到最优解.

2.4 拟合光滑路径曲线

为实现无人机规划路径的平滑性, 引入基于控制点的光滑曲线拟合技术. 具体而言, 首先通过 IPSO 算法在起点与终点之间确定 n 个控制点 $\{P_1, P_2, \ldots, P_n\}$, 其中相邻控制点间距 $\Delta d_i = \|P_{i+1} - P_i\|$ 满足

$$\Delta d_{\min} \leqslant \Delta d_i \leqslant \Delta d_{\max},\ \forall i \in 1, 2, \ldots, n-1. \tag{17}$$

其中: 控制点间距下界$\Delta d_{\min} = R_{\min}$确保路径分段可飞性, 同时抑制冗余振荡并降低计算复杂度; 上界$\Delta d_{\max} = 2R_{\min}$保障拟合曲线的曲率连续性, 避免因插值点稀疏导致的轨迹误差累积. 接着采用 B 样条曲线[20] 对路径进行拟合, 从而生成三维空间中的平滑曲线. B 样条曲线的表示为

$$C(q) = \sum_{i=1}^{n} N_{i,p}(q) P_i,\ 0 \leqslant q \leqslant 1. \tag{18}$$

其中: P_i是第i个控制点, $N_{i,p}(q)$是第i个控制点在阶数为p的 B 样条基函数下的权重. 通过本文方法生成的路径能够在起点与终点之间平滑连接各个控制点, 减少路径的曲率, 提升无人机的飞行稳定性和安全性.

2.5 路径相似度

在风场动态变化的环境中, 通过计算不同风场条件下路径的相似度, 可以有效地评估风场对路径规划的影响. 采用 Hausdorff 距离[23] $H(L_{\tau-1}, L_\tau)$量化两条路径$L_{\tau-1}$与L_τ之间的相似度. 其中: $L_{\tau-1}$是$\tau-1$时刻无人机采取的路径, L_τ是τ时刻拟采取的规划路径. $H(L_{\tau-1}, L_\tau)$ 定义如下:

$$\max\{\sup_{a\in L_{\tau-1}}\inf_{b\in L_\tau} d(a,b), \sup_{b\in L_\tau}\inf_{a\in L_{\tau-1}} d(a,b)\}, \tag{19}$$

其中$d(a,b)$是点a与点b之间的欧几里得距离. 当两条路径相似度较高$(d_H(L_{\tau-1}, L_\tau) < \varepsilon)$时, 表明风场变化对路径影响较小; 相似度较低$(d_H(L_{\tau-1}, L_\tau) \geqslant \varepsilon)$时, 表示风场变化对路径规划影响显著. 通过引入路径差异阈值ε, 在提高风场利用效率的同时, 避免因频繁更换路径而导致的不稳定性.

3 不同风场下 KF 算法预测无人机状态

在时变风场作用下, 利用 IPSO 算法实时规划无人机路径后, 需要依据无人机状态进一步判断是否切换飞行路径. 本节通过调整 KF 算法中控制输入风场数据, 计算无人机飞行状态的真实值与预测值之间的误差, 评估采用不同风场数据下的规划路径, 对无人机状态预测准确度的影响.

3.1 无人机飞行状态

在时变风场作用下, 无人机飞行状态方程可描述为

$$x_{k+1} = Ax_k + Bu_k + w_k. \tag{20}$$

其中: x_k是第k时刻的状态向量, 包括位置和速度向量; A是状态转移矩阵, 描述了无人机状态在没有控制输入和外部扰动时的自然演变; B是控制输入矩阵, 描述了控制输入对无人机的状态影响; u_k是第k时刻的控制输入; w_k是过程噪声, 服从均值为 0, 协方差为Q的正态分布.

无人机的状态观测方程为

$$z_{k+1} = Hx_{k+1} + v_k. \tag{21}$$

其中: z_{k+1}是在第$k+1$时刻的观测向量; H是观测矩阵, 用于将状态向量映射到观测空间; v_k是观测噪声, 服从均值为 0, 协方差为R的正态分布.

3.2 KF 算法预测和更新步骤

KF 算法分为两个主要步骤: 预测和更新. 首先, KF 算法根据上一时刻的状态进行预测, 预测的状态向量和误差协方差矩阵分别为

$$\hat{x}_{k+1|k} = A\hat{x}_{k|k} + Bu_k, \tag{22}$$

$$P_{k+1|k} = AP_{k|k}A^{\mathrm{T}} + Q. \tag{23}$$

其中: $\hat{x}_{k+1|k}$是基于k时刻的测量值和估计得到的对$k+1$时刻的预测状态, $\hat{x}_{k|k}$是在第k时刻给定所有可用测量值时的状态估计, $P_{k+1|k}$是预测误差协方差矩阵. 卡尔曼增益K_k计算如下:

$$K_k = P_{k|k-1}H^{\mathrm{T}}(HP_{k|k-1}H^{\mathrm{T}} + R)^{-1}. \tag{24}$$

利用卡尔曼增益对状态和误差进行更新, 即

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(z_k - H\hat{x}_{k|k-1}), \tag{25}$$

$$P_{k|k} = (I - K_kH)P_{k|k-1}. \tag{26}$$

通过上述更新步骤, KF 算法能够实时调整状态估计.

3.3 状态预测值与真实值误差计算

为了评估 KF 算法在不同风场输入条件下对无人机状态预测的准确度, 将时刻k的估计误差定义如下:

$$e_k = x_k - \hat{x}_{k|k}. \tag{27}$$

在此基础上, 本节使用均方根误差E衡量所有时间步误差的累积, 其表达式为

$$E = \sqrt{\frac{1}{T}\sum_{k=1}^{T} e_k^2}, \tag{28}$$

其中T是总的时间步数.

3.4 时变风场下采用不同规划路径的状态预测

本研究中, 在时变风场$\vec{V}_{\mathrm{vary}}$的影响下, 通过改变风场作为控制输入$\vec{V}_{\mathrm{input}}$的方式, 分析风场对无人机状态估计的影响. 具体而言, 将一部分风场$\vec{V}_{\mathrm{input}}$ 作为控制输入应用于无人机的状态转移模型, 剩余的风场$\Delta\vec{V}$部分以及其他环境因素则作为扰动进入过程噪声模型, 即

$$\Delta\vec{V} = \vec{V}_{\mathrm{vary}} - \vec{V}_{\mathrm{input}}. \tag{29}$$

在此基础上, 定义u_f为将$\vec{V}_{\mathrm{input}}$作为控制输入对状态输入的作用, 更新后的无人机状态方程为

$$x_{k+1} = Ax_k + B(u_k + u_f) + w_k. \tag{30}$$

此外, 过程噪声协方差矩阵根据风场输入的变化进行调整, 以便反映风场对系统的不确定性影响

$$Q_{\mathrm{wind}} = Q_0 + \mathrm{diag}([0,0,0,\Delta u_x^2, \Delta u_y^2, \Delta u_z^2])\cdot T^2. \tag{31}$$

该过程噪声模型反映了时变风场与控制输入之间的不匹配程度. 当输入风场v_{input}接近真实风场v_{vary}时, 扰动不确定性减小, 过程噪声降低, KF 算法可以更加准确地估计系统状态; 当两者偏差较大时, 过程噪声增强, 导致状态估计的误差增加.

如果 KF 算法的观测误差均方根满足条件$E \geqslant \delta$, 其中 δ 是系统的预测误差容忍度, 则系统会认为当前的路径规划已经失效, 需要进行重新规划.

注 4 在本研究中, 时变风场由恒定风场与随机风场组成. 恒定风场主要用于路径规划阶段, 以提供相对稳定的外部条件, 确保 IPSO 算法生成的路径具备较高的可行性; 完成路径规划后, 在利用 KF 算法对无人机状态进行预测的过程中, 需将恒定风场和随机风场的综合影响纳入考量, 从而实现对飞行状态的有效预测.

4 事件触发机制设计

本节首先设计一种基于风场变化的事件触发机制, 用于判断是否进行路径重规划; 在此基础上, 给出基于事件触发的时变风场下无人机实时路径重规划策略算法.

4.1 基于事件触发机制的路径重规划

为适应动态环境变化下的无人机飞行需求, 并降低规划路径的计算负担, 实现复杂环境中的高效、安全飞行, 本节设计事件触发机制如下: 当实时检测到的风场与规划路径使用的风场之间的差异超过设定的阈值时, 系统将自动触发路径重规划, 并激活异构计算架构实现硬件加速, 以提升路径规划的实时性. 事件触发机制以数学形式表示为

$$f((\vec{V}_{\text{wind-det}}-\vec{V}_{\text{wind-plan}})>\xi)\Rightarrow \text{Trigger Replaning}. \tag{32}$$

其中: ξ是设定的风场变化阈值, $\vec{V}_{\text{wind-det}}$是实时检测的风场值, $\vec{V}_{\text{wind-plan}}$是规划路径采取的风场值. 当检测到的风场变化超过阈值ξ时, 系统将触发路径重规划决策. 这里的风场变化阈值ξ由下述两项条件共同决定: 路径的 Hausdorff 距离满足$d_H(L_\tau, L_{\tau+1})\geqslant\varepsilon$和均方根误差满足$E\geqslant\delta$.

针对风场突变问题, 本文引入梯度触发规则以增强对风速突变的响应能力. 具体而言, 通过构建实时风速变化率微分检测模块, 当检测到风速的瞬时变化率超过预设阈值γ时, 立即触发预警机制

$$\frac{\partial \vec{V}_{\text{wind-det}}}{\partial t}>\gamma. \tag{33}$$

另外, 为了降低检测能耗, 本文采用事件触发驱动的自适应连续检测: 当$\vec{V}_{\text{wind-det}}\leqslant 0.7\xi$时, 系统处于低功耗模式, 以 5 Hz 频率监测$\vec{V}_{\text{wind-det}}$; 当$\vec{V}_{\text{wind-det}}>0.7\xi$时, 系统切换至高功耗模式, 并提高检测频率至 20 Hz, 以增强检测精度.

4.2 实时路径重规划策略流程

在上一节设计的事件触发机制的基础上, 提出一种基于事件触发的时变风场下无人机实时路径重规划策略. 在τ时刻, 系统采集风场和地形数据, 通过 IPSO 算法生成路径. 若路径相似度或预测误差超过阈值, 则触发路径重规划, 否则沿用原路径.

算法1 无人机实时路径重规划策略.

输入: $\tau-1$, τ, $\vec{V}_{\text{wind-plan}}$, $L_{\tau-1}$, $\vec{V}_{\text{wind-det}}$

1. 初始化: 差异阈值ε, 预测误差容忍度δ;
2. IPSO规划路径: 生成在风场$\vec{V}_{\text{wind-det}}$下的规划路径$L_\tau$;
3. 计算相似度: $d_H(L_{\tau-1}, L_\tau)$;
4. 如果$d_H(L_{\tau-1}, L_\tau)\geqslant\varepsilon$则
5. $\Rightarrow$ Trigger Replanning
6. τ时刻规划路径更新为L_τ;
7. 否则
8. 如果 $E\geqslant\delta$则
9. $\Rightarrow$ Trigger Replanning
10. τ时刻规划路径更新为L_τ;
11. 否则
12. $\nRightarrow$ Trigger Replanning
13. τ时刻规划路径沿用$L_{\tau-1}$;
14. 更新$\vec{V}_{\text{wind-det}}$, L_τ;
15. 进入$\tau+1$时刻.

注 5 在当前研究中, 通过在线评估路径差异阈值ε和预测误差容忍度δ判断是否进行路径切换, 并基于这一机制逐步积累飞行数据. 未来研究将结合无人机的飞行历史数据, 采用机器学习、深度学习等人工智能方法, 分析并建模ε、δ、ξ、γ与飞行数据(包括飞行距离、速度、状态等)之间的关系, 实现阈值的自适应优化.

5 仿真研究与分析

本节首先在二维场景下分析风场变化对路径规划的影响, 对比不同智能算法在风场条件下的路径规划性能; 随后在三维场景中验证路径重规划策略的可行性.

5.1 风场条件下路径切换的必要性

在二维空间中构建$1\,000\times 1\,000$仿真场景, 无人机从起点$(0,0)$出发, 飞行至终点$(1\,000, 1\,000)$, 最大空速设为10 m/s. 区域内风场符合正态分布, 划分为以下 5 个区域:

$$\vec{V}_{\text{wind-det}}=\begin{cases}(0.5,0.2),\ x\in[0,200];\\(1.0,1.5),\ x\in(200,400];\\(-0.4,0.2),\ x\in(400,600];\\(-1.0,-0.5),\ x\in(600,800];\\(0.6,0.7),\ x\in(800,1\,000].\end{cases} \tag{34}$$

图 1 展示了考虑风场影响后的路径规划, 随着重规划次数从 0 次 (P0) 增至 5 次 (P5), 不同策略下的飞行轨迹在空间形态上呈现显著差异, 验证了动

态调整机制的必要性. 具体而言: 无重规划 (P0): 全程保持初始路径, 不考虑风场影响, 不触发重规划; 1 次重规划 (P1): 在起点触发重规划, 风场为 $(0.5, 0.2)$; 2 次重规划 (P2): 在起点和 $x = 200$ 触发重规划, 风场分别为 $(0.5, 0.2)$ 和 $(1.0, 1.5)$; 3 次重规划 (P3): 在起点、$x = 200$ 和 $x = 400$ 触发重规划, 风场分别为 $(0.5, 0.2)$、$(1.0, 1.5)$ 和 $(-0.4, 0.2)$; 4 次重规划 (P4): 在起点、$x = 200$、$x = 400$ 和 $x = 600$ 触发重规划, 风场分别为 $(0.5, 0.2)$、$(1.0, 1.5)$、$(-0.4, 0.2)$ 和 $(-1.0, 0.5)$; 5 次重规划 (P5): 在起点、$x = 200$、$x = 400$、$x = 600$ 和 $x = 800$ 触发重规划, 风场分别为 $(0.5, 0.2)$、$(1.0, 1.5)$、$(-0.4, 0.2)$、$(-1.0, 0.5)$ 和 $(0.6, 0.7)$.

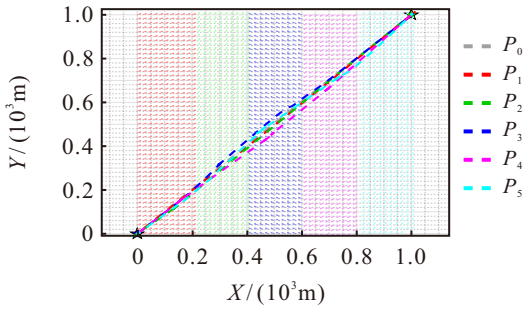

图1　多阶段路径规划

表 1 定量对比了不同路径规划策略的性能指标, 实验数据表明, 路径重规划频率的变化对路径长度、曲率、飞行时间和能耗均产生显著影响. 随着路径调整频率的增加, 路径长度由 P0 的 1 475.2 m 增至 P5 的 1 709.8 m, 增幅达 15.9%, 表明频繁调整路径会导致绕行距离增加; 同时, 平均曲率由 P0 的 0.002 3 激增至 P5 的 0.634 2, 曲率增加 2.8 倍, 这表明, 在风场环境下, 频繁触发路径重规划可能导致航迹曲率剧烈变化, 增大路径复杂度; 在飞行时间和能耗方面, P3 的飞行时间最短为 122.2 s, 而 P6 的能耗最低为 13.24 kJ, 表明飞行时间与能耗之间存在一定的权衡关系, 路径优化方案的选择需要综合考虑任务需求和环境因素, 以实现全局最优的路径规划. 为减少路径重规划的频繁触发对航迹平滑性和计算负担的影响, 本文采用 Hausdorff 距离评估按照风场变化触发路径的变化, 以$d_H(L_\tau, L_{\tau+1}) \geqslant \varepsilon$作为路径重规划的触发条件, 仅在路径变化超出设定范围时才进行重规划, 以避免因过度路径调整导致的航迹曲率急剧变化, 同时降低因频繁切换路径导致的计算资源消耗. 然而, 若路径重规划触发频率过低, 则可能导致无人机能耗增加以及飞行状态难以预测, 尤其在风场变化较大的情况下, 若长期沿用原有路径, 则可能因风速变化导致飞行阻力增大, 从而影响任务执行效率. 因此, 本文采用 KF 评估无人机的状态可预测性, 并设置均方根误差满足$E \geqslant \delta$时触发路径调整, 以确保路径切换频率不低于一定水平, 从而优化能耗, 并提高无人机在复杂风场环境下的路径适应性.

表1　多阶段路径规划性能对比

规划策略	路径长度 / m	平均曲率	总飞行时间 / s	总飞行能耗 / kJ
P0	1 475.2	0.002 3	141.4	13.69
P1	1 554.9	0.004 2	134.8	13.68
P2	1 506.0	0.139 6	122.2	13.67
P3	1 501.4	0.225 4	134.5	13.48
P4	1 709.8	0.262 6	139.9	13.38
P5	1 626.5	0.634 2	132.4	13.24

5.2　风场条件下多种算法路径规划性能对比

在二维场景中的$[0, 200]$区域, 风场向量为$(0.5, 0.2)$, 无人机从起点$(0, 0)$出发, 飞行至终点 $(200, 200)$, 进行路径规划. 为验证 IPSO 方法在风场环境中的路径优化能力, 本文对比分析了 GA[9-10]、ACO[11-12] 和传统 PSO 算法在风场条件下的路径规划性能. 在相同的环境参数条件下, 进行 50 次独立实验, 结果如表 2 所示. 实验结果表明, IPSO 算法在各项指标上均优于其他算法. 具体而言, 相较于 GA、ACO 以及传统 PSO 算法, IPSO 算法的适应度平均值分别减少了 2.31%、5.44% 和 2.35%, 表明 IPSO能够有效找到更优的路径规划方案; 同时, IPSO 的平均规划时间较 GA、ACO 和传统 PSO 算法分别减少了 38.65%、36.15% 和 19.86%, 展示了其在实时性上的显著优势; 在适应度方差方面, IPSO 的优化效果最为显著, 相较于其他 3 种算法分别减少了 55.84%、68.08% 和 58.45%, 表明 IPSO 在多次实验中的稳定性较强, 结果波动较小.

表2　不同智能算法路径规划性能对比

算法	适应度平均值	适应度方差	平均规划时间 / s
GA	156.46	53.42	0.076
ACO	161.65	73.86	0.072
PSO	156.52	56.67	0.058
IPSO	152.85	23.56	0.046

5.3　路径重规划策略可行性

在三维空间中, 设计如下仿真场景: 场地尺寸为 1 000, 飞行起点为 $(10, 10, 10)$, 终点为 $(900, 900, 900)$, 无人机最大飞行空速为 10.下面分别对风场方向相同但强度不同的同向异速风场和方向不同且强度变化的异向异速风场条件下的无人机飞行路径进行仿真, 以分析不同风场特性对无人机路径规划的影响.

首先考虑同向异速风场, 分别设定风场向量为 $(0,0,0)$、$(1,1,1)$、$(2,2,2)$ 和 $(3,3,3)$, 对应的规划路径分别命名为 Path 1、Path 2、Path 3 和 Path 4, 规划路径如图 2 所示.

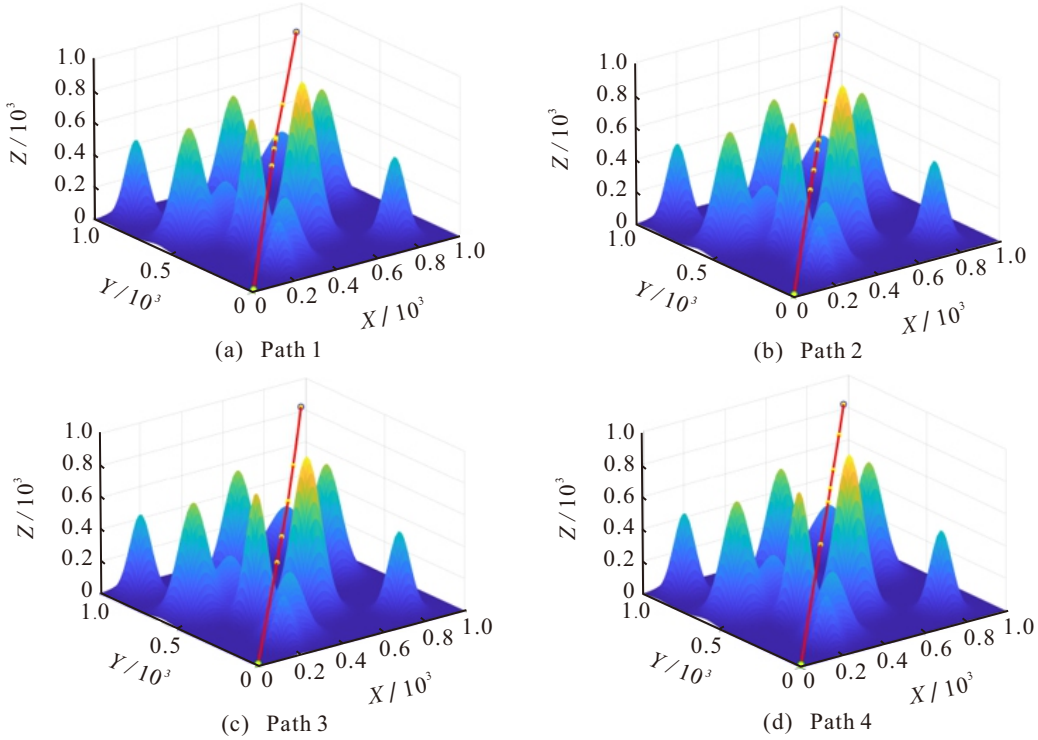

图2 同向异速风场下规划路径

为评估同向异速风场对规划路径的影响, 采用 Hausdorff 距离对不同路径进行两两比较, 计算结果如表 3 所示. 结果表明, 在风场方向一致的情况下, 尽管风场强度增加, Hausdorff 距离相对于整体路径长度依然较小, 路径相似度较高. 因此, 在同向异速风场条件下, 无需触发路径更新.

表3 同向异速风场下规划路径相似度

Hausdorff 距离	Path 1	Path 2	Path 3	Path 4
Path 1	0	4.63	5.73	7.81
Path 2	4.63	0	1.14	3.45
Path 3	5.73	1.14	0	2.73
Path 4	7.81	3.45	2.73	0

此外, 考虑异速异向风场, 设定风场向量为 $(1,1,1)$、$(2,1,1)$、$(3,1,1)$、$(4,1,1)$、$(5,1,1)$ 和 $(6,1,1)$, 对应的规划路径分别命名为 Curve 1、Curve 2、Curve 3、Curve 4、Curve 5 和 Curve 6, 如图 3 所示.

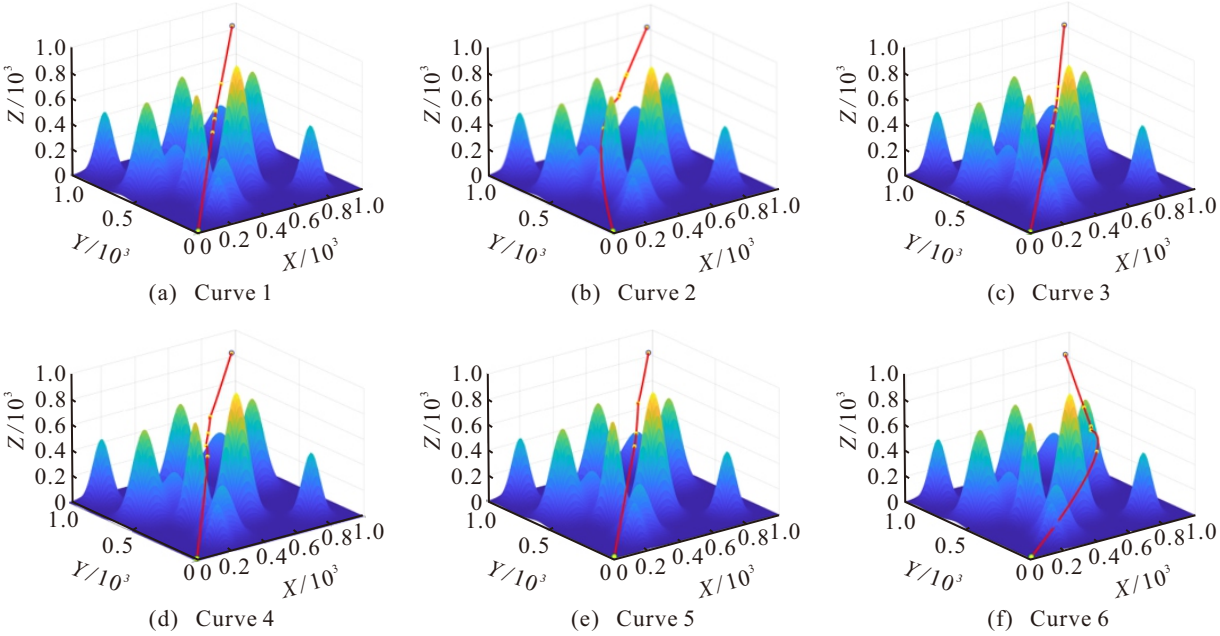

图3 异向异速风场下规划路径

在图 3 中, Curve 2 和 Curve 6 由于避障需求出现了规划路径突变.

利用 Hausdorff 距离量化不同路径的相似度, 如表 4 所示. 结果表明, 风场方向的变化对路径规划影响较为显著, 在风场差异较大的情况下, 无人机飞行轨迹出现明显偏移. 其中: Curve 2 与 Curve 6 因差异较大直接触发路径重规划; 而 Curve 1、Curve 3、Curve 4 与 Curve 5 之间的差异是否触发路径重规划, 则需进一步评估无人机飞行状态.

表4　异向异速风场下路径相似度

Hausdorff 距离	Curve 1	Curve 2	Curve 3	Curve 4	Curve 5	Curve 6
Curve 1	0	195.16	133.90	177.36	179.73	240.88
Curve 2	195.16	0	102.49	151.14	127.73	111.36
Curve 3	133.90	102.49	0	122.10	104.76	124.26
Curve 4	177.36	151.14	122.10	0	171.99	187.63
Curve 5	179.73	127.73	104.76	171.99	0	66.60
Curve 6	240.88	111.36	124.26	187.63	66.60	0

最后, 为研究时变风场下, 采用不同风场规划路径飞行对无人机的状态预测准确度的影响, 引入 KF 算法对无人机的飞行状态进行预测. 当时变风场设定为 $(4,1,1)$ 时, 规划路径的风场向量从 $(0,1,1)$ 开始, 以步长 $(0.05,0,0)$ 逐渐增加至 $(8,1,1)$. 图 4 显示了仿真结果, 表明当规划路径风场与真实风场向量 $(4,1,1)$ 完全一致时, KF 算法对无人机状态的预测准确度最高, 然而当规划路径风场偏离真实风场向量 $(4,1,1)$ 时, 无人机状态预测准确度下降, 并呈现以真实风场向量为中心的对称性分布. 因此, 可以在一定预测误差容忍度内避免路径更新, 降低因重新规划路径导致的计算负担.

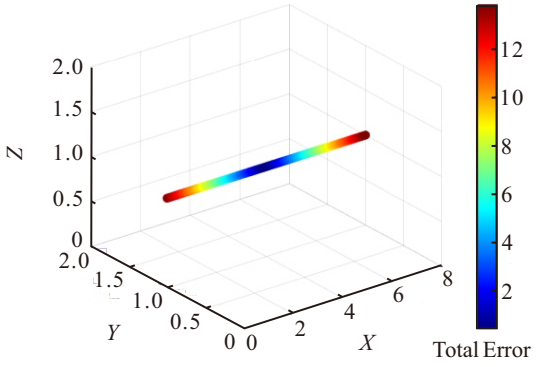

图4　不同规划路径下无人机状态预测准确度

6　结　论

本文提出了一种基于事件触发机制的无人机实时路径重规划策略, 以应对时变风场对飞行过程中的能耗和状态变化的影响. 该策略首先通过改进的粒子群优化 (IPSO) 算法进行路径规划, 利用 B 样条曲线拟合生成光滑路径, 并计算不同风场条件下规划路径之间的 Hausdorff 距离, 以量化风场变化对路径的影响; 接着, 应用卡尔曼滤波 (KF) 算法预测无人机的飞行状态, 通过分析实际飞行状态与预测状态之间的误差, 进一步评估风场变化对状态预测准确度的影响; 基于上述研究, 设定风场变化阈值, 当风场变化超过该阈值时, 启动事件触发机制 (ETM), 更新规划路径, 从而增强无人机对环境变化的响应能力, 同时降低复杂风场条件下的能耗和计算负担. 仿真实验结果验证了该策略在变化风场中的有效性和可行性. 未来的研究可以进一步优化事件触发机制的触发条件, 以适应更复杂的动态风场环境, 进一步提升无人机的自主飞行性能和效率.

参考文献 (References)

[1] 于彦鹏, 余墨多, 汤奇荣, 等. 面向城市应急物资配送的多无人机协同路径规划算法[J]. 控制与决策, 2025, 40(4): 1098-1106.
(Yu Y P, Yu M D, Tang Q R, et al. Multi-UAV cooperative path planning algorithm for urban emergency material distribution[J]. Control and Decision, 2025, 40(4): 1098-1106.)

[2] 鲜斌, 宋宁. 基于模型预测控制与改进人工势场法的多无人机路径规划[J]. 控制与决策, 2024, 39(7): 2133-2141.
(Xian B, Song N. A multiple UAVs path planning method based on model predictive control and improved artificial potential field[J]. Control and Decision, 2024, 39(7): 2133-2141.)

[3] İncekara H, Selek M, Basciftci F. Optimization of quadrotor route planning with time and energy priority in windy environments[J]. The International Arab Journal of Information Technology, 2023, 20(5): 782-795.

[4] Sun G H, Fang X F, Zhu L C, et al. Path planning of plant protection UAV based on improved A* algorithm under wind conditions[J]. International Journal of Precision Agricultural Aviation, 2018, 1(1): 31-38.

[5] Xu X, Zhang F F, Zhao Y. Unmanned aerial vehicle path-planning method based on improved P-RRT* algorithm[J]. Electronics, 2023, 12(22): 4576.

[6] Theile M, Bayerlein H, Nai R, et al. UAV path planning using global and local map information with deep reinforcement learning[C]. 2021 20th International Conference on Advanced Robotics. Ljubljana, 2022: 539-546.

[7] Zhang J D, Guo Y K, Zheng L H, et al. Real-time UAV path planning based on LSTM network[J]. Journal of Systems Engineering and Electronics, 2024, 35(2): 374-385.

[8] 罗越群, 丁达理, 谭目来, 等. 无人作战飞机自主机动决策方法综述[J]. 航空学报, 2025, 46(7): 30-59.
(Luo Y Q, Ding D L, Tan M L, et al. A review of

autonomous maneuver decision methods for unmanned combat aerial vehicle[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(7): 30-59.)

[9] Shivgan R, Dong Z. Energy-efficient drone coverage path planning using genetic algorithm[C]. 2020 IEEE 21st International Conference on High Performance Switching and Routing (HPSR). Newark, 2020: 1-6

[10] 黄书召, 田军委, 乔路, 等. 基于改进遗传算法的无人机路径规划[J]. 计算机应用, 2021, 41(2): 390-397.
(Huang S Z, Tian J W, Qiao L, et al. Unmanned aerial vehicle path planning based on improved genetic algorithm[J]. Journal of Computer Applications, 2021, 41(2): 390-397.)

[11] Al Baroomi B, Myo T, Ahmed M R, et al. Ant colony optimization-based path planning for UAV navigation in dynamic environments[C]. 2023 7th International Conference on Automation, Control and Robots. Kuala Lumpur, 2023: 168-173.

[12] 宋阿妮, 包贤哲. 精英扩散蚁群优化算法求解运输无人机三维路径规划[J]. 计算机工程与科学, 2021, 43(10): 1891-1900.
(Song A N, Bao X Z. An elite diffusion ant colony optimization algorithm for solving 3D path planning of transportation UAV[J]. Computer Engineering & Science, 2021, 43(10): 1891-1900.)

[13] Na Y W, Li Y L, Chen D Q, et al. Optimal energy consumption path planning for unmanned aerial vehicles based on improved particle swarm optimization[J]. Sustainability, 2023, 15(16): 12101.

[14] Deng L X, Chen H Y, Zhang X, et al. Three-dimensional path planning of UAV based on improved particle swarm optimization[J]. Mathematics, 2023, 11(9): 1987.

[15] 徐建新, 孙纬, 马超. 基于改进粒子群算法的无人机三维路径规划[J]. 电光与控制, 2023, 30(6): 15-21.
(Xu J X, Sun W, Ma C. UAV 3D path planning based on improved particle swarm optimization[J]. Electronics Optics & Control, 2023, 30(6): 15-21.)

[16] Sun H L, Sun L Y, Qi J T, et al. Formation keeping method based on NMPC for fixed-wing UAV with kinematic constraints[C]. 2023 42nd Chinese Control Conference. Tianjin, 2023: 5854-5860.

[17] Sun S, Dong K, Guo C, et al. A wind estimation based on unscented Kalman filter for standoff target tracking using a fixed-wing UAV[J]. International Journal of Aeronautical and Space Sciences, 2021, 22(2): 366-375.

[18] Feng W B, Wang C Q, Wu S Q, et al. Multi-rate Kalman filter for UAV attitude estimation based on adaptive disturbance model[C]. 2024 43rd Chinese Control Conference. Kunming, 2024: 3590-3596.

[19] 张皓, 张洪铭, 王祝萍. 基于事件触发的无人驾驶汽车路径跟随预测控制[J]. 控制与决策, 2019, 34(11): 2421-2427.
(Zhang H, Zhang H M, Wang Z P. Event-triggered predictive path following control for unmanned autonomous vehicle[J]. Control and Decision, 2019, 34(11): 2421-2427.)

[20] Bhandari S, Biral F. Wind field estimation and airspeed calibration for small UAVs using low-cost sensors[J]. Aerospace Science and Technology, 2019, 92: 121-133.

[21] 陈钢, 叶佩昌, 贾庆轩, 等. 基于速度修正项的机械臂避障路径规划[J]. 控制与决策, 2015, 30(1): 156-160.
(Chen G, Ye P C, Jia Q X, et al. Obstacle avoidance path planning of manipulator based on speed correction term[J]. Control and Decision, 2015, 30(1): 156-160.)

[22] 王培, 江南, 万幼, 等. 应用 Hausdorff 距离的时空轨迹相似性度量方法[J]. 计算机辅助设计与图形学学报, 2019, 31(4): 647-658.
(Wang P, Jiang N, Wan Y, et al. Measuring similarity of spatio-temporal trajectory using Hausdorff distance[J]. Journal of Computer-Aided Design & Computer Graphics, 2019, 31(4): 647-658.)

[23] 吴永红, 曾志高, 邓彬. 基于惯性权重和学习因子动态调整的粒子群算法[J]. 湖南工业大学学报, 2021, 35(1): 91-96.
(Wu Y H, Zeng Z G, Deng B. Particle swarm optimization algorithm based on dynamic adjustment of inertial weight and learning factors[J]. Journal of Hunan University of Technology, 2021, 35(1): 91-96.)

[24] 褚宏悦, 易军凯. 无人机安全路径规划的混沌粒子群优化研究[J]. 控制工程, 2024, 31(6): 1027-1034.
(Chu H Y, Yi J K. Research on chaos particle swarm optimization for UAV safe path planning[J]. Control Engineering of China, 2024, 31(6): 1027-1034.)

作者简介

宋璐璐 (1994−), 女, 博士生, 主要研究方向为机器人自主导航、路径规划及环境感知, E-mail: songll0827@126.com;

邓超 (1988−), 男, 教授, 博士生导师, 主要研究方向为智能控制与自主系统, E-mail: dengchao_neu@126.com;

范莎 (1989−), 女, 讲师, 博士, 主要研究方向为智能优化算法与复杂系统控制, E-mail: shafan90@163.com.