

基于预测槽位引导灰狼优化的三无人机受限三维协同围控

杨海涛, 杨 艺

江苏理工学院机械工程学院, 江苏 常州

收稿日期: 2026年8月14日; 录用日期: 2026年9月13日; 发布日期: 2026年9月22日

摘 要

针对机动目标速度突变时三无人机围控队形易偏离、有限迭代灰狼优化难以及时恢复有效候选的问题, 文章提出预测槽位引导的状态触发自适应灰狼优化方法。首先, 利用有限差分加速度预测目标短时位置, 并在预测目标周围构造3个具有高度差的参考槽位; 其次, 将槽位反解为九维加速度引导向量, 在固定迭代位置对部分候选实施等预算恢复。水平突转场景的30次配对结果表明, 相对随机恢复GWO, 本方法的平均恢复时间减少0.0867 s, 半径均方根误差减少0.0128 m, 有效围控比例提高0.0048, 三项95%置信区间均未跨越0。与粒子群优化和改进灰狼优化的比较进一步验证了水平场景下的恢复优势, 但其控制代价和跨场景表现仍具有一定局限性。

关键词

三无人机, 三维协同围控, 灰狼优化, 预测槽位, 滚动优化

Predictive-Slot-Guided Grey Wolf Optimization for Constrained Three-Dimensional Cooperative Encirclement by Three UAVs

Haitao Yang, Yi Yang

School of Mechanical Engineering, Jiangsu University of Technology, Changzhou Jiangsu

Received: August 14, 2026; accepted: September 13, 2026; published: September 22, 2026

Abstract

Aiming at the problems that the three-UAV encirclement formation is prone to deviating when the

speed of a maneuvering target changes abruptly, and that grey wolf optimization under limited iterations struggles to promptly restore effective candidates, this paper proposes a prediction-slot-guided state-triggered adaptive grey wolf optimization method. First, a finite-difference acceleration estimate is used to predict the short-term target position, around which three reference slots with prescribed altitude offsets are constructed. Second, the slots are inverse-mapped into a nine-dimensional acceleration guidance vector, and several candidates are recovered at a fixed internal iteration under an equal per-recovery evaluation budget. Thirty paired runs in the horizontal abrupt-turn scenario show that, compared with random-recovery GWO, ST-A-GWO reduces the mean recovery time by 0.0867 s and the radius root-mean-square error by 0.0128 m, while increasing the eligible encirclement ratio by 0.0048. The corresponding 95% confidence intervals do not cross zero. Comparisons with particle swarm optimization and improved grey wolf optimization support the recovery advantage in the horizontal scenario, although limitations remain in control effort and cross-scenario performance.

Keywords

Three UAVs, Three-Dimensional Cooperative Encirclement, Grey Wolf Optimization, Predictive Slot, Receding-Horizon Optimization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

多无人机协同围控可通过多个飞行平台的空间配合实现对运动目标的持续跟踪和区域监测。与单机跟踪相比,多机系统还需同时维持目标距离、相对方位和机间安全间距,控制变量和约束之间存在较强耦合。Hafez 等利用模型预测控制求解多无人机动态围控问题[1]; Wang 等研究有限目标信息条件下的定位与围控控制[2]; Gao 等通过环形虚拟管约束多无人机在三维空间内的围控运动[3]。

灰狼优化(Grey Wolf Optimization, GWO)具有结构简单和无需梯度信息等特点[4],已被用于多无人机轨迹优化。Yao 等将改进 GWO 与模型预测控制结合,用于城市环境中的多无人机目标跟踪[5]; Wang 等研究了基于混沌 GWO 和事件触发策略的多无人机分布式预测控制[6]; 秦冬燕等将事件触发 GWO 用于四旋翼无人机三维航迹规划[7]; Peng 等采用动态围控点和 GWO 构造多无人机协同围控策略[8]。上述研究说明,目标预测、事件触发和任务相关搜索能够为无人机优化控制提供有效信息,但其任务模型和候选更新方式与本文问题不同。

IGWO 和 PSO 分别作为改进 GWO 与经典群体搜索基线[9]-[11],多智能体协同、滚动预测和机动目标建模为本文提供了方法基础[12]-[17]。动态环境中的多群体 PSO 通过维持搜索多样性应对环境变化[18],记忆或预测策略则利用历史候选或搜索趋势引导新环境搜索。不同于这些策略,ST-A-GWO 根据当前目标状态预测参考槽位,并将其映射为九维加速度方向,以引导候选恢复。

在固定种群规模和内部迭代次数下,目标突然改变运动方向可能使优势候选集中于失效搜索区域。全局随机恢复虽能补充多样性,却未利用围控队形的空间结构;局部随机恢复则可能仍受当前搜索中心限制。为此,本文提出 ST-A-GWO,将预测目标周围的 3 处参考槽位反解为九维加速度方向,并在固定恢复时刻、固定候选数量和相同单次恢复评价预算下,引导候选种群向与队形重构相关的区域恢复。联合状态量和自适应收敛因子作为完整算法的支撑机制。

2. 三无人机受限三维围控问题建模

2.1. 无人机运动模型与九维控制变量

考虑由 3 架无人机组成的三维协同围控系统。设 $i=1,2,3$ 为无人机编号, k 为离散控制时刻。第 i 架无人机的位置、速度和控制加速度分别定义为:

$$\mathbf{p}_i^k = [x_i^k, y_i^k, z_i^k]^T, \quad \mathbf{v}_i^k = [v_{xi}^k, v_{yi}^k, v_{zi}^k]^T, \quad \mathbf{u}_i^k = [u_{xi}^k, u_{yi}^k, u_{zi}^k]^T \quad (1)$$

式中, $\mathbf{p}_i^k$ 、 $\mathbf{v}_i^k$ 和 $\mathbf{u}_i^k$ 的单位分别为 m、m/s 和 m/s²。采用控制周期为 Δt 的离散点质量运动模型, 按照先更新速度、再更新位置的顺序传播状态:

$$\mathbf{v}_i^{k+1} = \Pi_v(\mathbf{v}_i^k + \mathbf{u}_i^k \Delta t) \quad (2)$$

$$\mathbf{p}_i^{k+1} = \Pi_p(\mathbf{p}_i^k + \mathbf{v}_i^{k+1} \Delta t) \quad (3)$$

其中, Π_v 和 Π_p 分别表示速度和飞行区域约束投影。系统约束为:

$$\begin{aligned} -u_{\max} &\leq u_{qi}^k \leq u_{\max}, \quad q \in \{x, y, z\} \\ \sqrt{(v_{xi}^k)^2 + (v_{yi}^k)^2} &\leq v_h^{\max}, \quad |v_{zi}^k| \leq v_z^{\max} \\ \mathbf{p}_i^k &\in [-40, 40] \times [-40, 40] \times [3, 20] \end{aligned} \quad (4)$$

式中, $u_{\max} = 3 \text{ m/s}^2$, $v_h^{\max} = 4 \text{ m/s}$, $v_z^{\max} = 2 \text{ m/s}$ 。每个控制时刻的优化变量由三架无人机的三轴加速度组成:

$$\mathbf{U}^k = [u_{x1}^k, u_{y1}^k, u_{z1}^k, u_{x2}^k, u_{y2}^k, u_{z2}^k, u_{x3}^k, u_{y3}^k, u_{z3}^k]^T \in \mathbb{R}^9 \quad (5)$$

在 $H=3$ 个预测步内, 同一候选加速度保持不变, 预测时间 $\tau = H\Delta t = 0.6 \text{ s}$ 。优化结束后仅执行第一个 0.2 s 控制周期的指令, 下一时刻重新预测和优化。因此, 优化变量为九维恒加速度候选。

2.2. 目标预测与参考槽位

设目标在时刻 k 的位置和速度分别为 $\mathbf{p}_t^k$ 和 $\mathbf{v}_t^k$ 。根据相邻时刻速度差估计目标加速度, 并限制其欧氏范数:

$$\hat{\mathbf{a}}_t^k = \Pi_{\|\mathbf{a}\| \leq a_t^{\max}} \left(\frac{\mathbf{v}_t^k - \mathbf{v}_t^{k-1}}{\Delta t} \right) \quad (6)$$

式中, $a_t^{\max} = 4 \text{ m/s}^2$ 。目标预测位置为:

$$\hat{\mathbf{p}}_t^{k+H} = \Pi_p \left(\mathbf{p}_t^k + \tau \mathbf{v}_t^k + \frac{1}{2} \tau^2 \hat{\mathbf{a}}_t^k \right) \quad (7)$$

在预测目标周围设置 3 处参考槽位:

$$\begin{aligned} \mathbf{s}_i^k &= \Pi_p \left(\hat{\mathbf{p}}_t^{k+H} + [r_{hi} \cos \varphi_i, r_{hi} \sin \varphi_i, h_i]^T \right) \\ r_{hi} &= \sqrt{r_d^2 - h_i^2}, \quad \varphi_i = \frac{2\pi(i-1)}{3} \end{aligned} \quad (8)$$

式中, $r_d = 7 \text{ m}$ 为期望围控半径; 高度偏移 h_i 依次为 0.8 、 0 和 -0.8 m ; 相邻槽位的水平方位间隔为 120° 。三无人机受限三维协同围控模型如图 1 所示。




Figure 1. Constrained three-dimensional cooperative encirclement model for three UAVs: (a) Three reference slots around the predicted target; (b) Three-step prediction and motion constraints; (c) Receding-horizon optimization loop of the nine-dimensional control variable

图 1. 三无人机受限三维协同围控模型: (a) 预测目标周围的三处参考槽位; (b) 三步预测及运动约束; (c) 九维控制量的滚动优化闭环

2.3. 围控约束与综合目标函数

设 $\mathbf{p}_i^{k,H}$ 和 $\mathbf{v}_i^{k,H}$ 为候选控制量经过 H 步传播后的终端状态。预测半径和无人机之间的水平投影夹角定义为:

$$d_i^{k,H} = \|\mathbf{p}_i^{k,H} - \hat{\mathbf{p}}_t^{k+H}\|_2$$

$$\theta_{ij}^{k,H} = \arccos \frac{(\mathbf{r}_{ih}^{k,H})^T \mathbf{r}_{jh}^{k,H}}{\|\mathbf{r}_{ih}^{k,H}\|_2 \|\mathbf{r}_{jh}^{k,H}\|_2} \quad (9)$$

式中, $\mathbf{r}_{ih}^{k,H}$ 为无人机 i 相对预测目标位置的水平分量; $d_i^{k,H}$ 的单位为 m, $\theta_{ij}^{k,H}$ 的单位为 rad。综合目标函数为:

$$J = w_r J_r + w_\theta J_\theta + w_s J_s + w_u J_u + w_h J_h + w_c J_c + w_{\text{slot}} J_{\text{slot}} + w_v J_v \quad (10)$$

各无量纲子项定义为:

$$J_r = \frac{1}{3} \sum_{i=1}^3 \left(\frac{d_i - r_d}{r_d} \right)^2, \quad J_\theta = \frac{1}{3} \sum_{i < j} \left(\frac{\theta_{ij} - 2\pi/3}{\pi} \right)^2$$

$$J_s = \sum_{i < j} \left[\max \left(0, \frac{d_s - d_{ij}}{d_s} \right) \right]^2, \quad J_u = \frac{1}{9} \sum_{i=1}^3 \left\| \frac{\mathbf{u}_i^k - \mathbf{u}_i^{k-1}}{\mathbf{u}_{\max}} \right\|_2^2$$

$$J_h = \frac{1}{3} \sum_{i=1}^3 \left(\frac{p_{iz} - \hat{p}_{t,z} - h_i}{h_{\text{tol}}} \right)^2, \quad J_c = \frac{1}{3} \sum_{i=1}^3 \left[\max \left(0, \frac{d_i - r_m}{r_m} \right) \right]^2$$

$$J_{\text{slot}} = \frac{1}{3r_d^2} \sum_{i=1}^3 \|p_i - s_i^k\|_2^2, \quad J_v = \frac{1}{3(v_h^{\max})^2} \sum_{i=1}^3 \|v_i - v_t^k\|_2^2 \quad (11)$$

目标函数权重依次为 3、2、8、0.2、6、5、0.8 和 2。为统一统计口径, 有效围控状态定义为:

$$E_r^k = \sqrt{\frac{1}{3} \sum_{i=1}^3 (d_i^k - r_d)^2}, \quad E_\theta^k = \sqrt{\frac{1}{3} \sum_{i < j} \left(\theta_{ij}^k - \frac{2\pi}{3} \right)^2}$$

$$E_h^k = \sqrt{\frac{1}{3} \sum_{i=1}^3 (p_{iz}^k - p_{t,z}^k - h_i)^2}$$

$$e^k = \mathbb{I} \{ E_r^k \leq 1.25 \text{ m}, E_\theta^k \leq 20^\circ, E_h^k \leq 0.60 \text{ m}, d_{\min}^k \geq 3.5 \text{ m}, d_i^k \leq 10.5 \text{ m}, 3 \leq p_{iz}^k \leq 20 \} \quad (12)$$

其中, $e^k = 1$ 表示该时刻满足有效围控判据, $d_{\min}^k$ 为无人机之间的最小三维距离。

3. 预测槽位引导的 ST-A-GWO 方法

3.1. 标准算法更新机制

标准 GWO 根据当前种群中的前三个候选 α 、 β 和 δ 引导其他候选更新[4]。设 $\ell = 1, \dots, L$ 为内部迭代次数, 线性收敛因子为:

$$a_\ell = 2 \left(1 - \frac{\ell - 1}{L - 1} \right) \quad (13)$$

对于领导候选 $j \in \{\alpha, \beta, \delta\}$, 系数和中间位置统一表示为:

$$A_j = 2a_\ell r_{1,j} - a_\ell, \quad C_j = 2r_{2,j}, \quad X'_j = X_j - A_j \odot |C_j \odot X_j - X| \quad (14)$$

式中, $r_{1,j}$ 和 $r_{2,j}$ 为 $[0, 1]^9$ 内的随机向量, $\odot$ 表示逐元素乘法, X 为九维候选位置。候选更新为:

$$X^{\ell+1} = \frac{X'_\alpha + X'_\beta + X'_\delta}{3} \quad (15)$$

3.2. 联合状态触发与自适应收敛

联合状态量同时描述目标机动程度和当前围控偏差。目标机动状态量为:

$$m_v = \frac{\|v_t^k - v_t^{k-1}\|_2}{a_{\text{ref}} \Delta t}, \quad m_\psi = \frac{|\text{wrap}(\psi_t^k - \psi_t^{k-1})|}{\psi_{\text{ref}}}, \quad m_z = \frac{|v_{t,z}^k - v_{t,z}^{k-1}|}{a_{\text{ref}} \Delta t}$$

$$M^k = \min \left(1, \frac{m_v + m_\psi + m_z}{3} \right) \quad (16)$$

其中, $a_{\text{ref}} = 2.5 \text{ m/s}^2$, $\psi_{\text{ref}} = 35^\circ$ 。围控状态量为:

$$f_r = \frac{E_r}{1.25 \text{ m}}, \quad f_\theta = \frac{E_\theta}{20^\circ}, \quad f_h = \frac{E_h}{0.60 \text{ m}}$$

$$f_s = \max_{i < j} \left[\max \left(0, \frac{d_s - d_{ij}}{d_s} \right) \right]$$

$$F^k = \min \left(1, \frac{f_r + f_\theta + f_s + f_h}{4} \right) \quad (17)$$

取两类状态量的较大值, 并据此调整收敛因子:

$$\eta^k = \max(M^k, F^k), \quad a_\ell(\eta^k) = 2[(1-s_\ell)(1-\eta^k) + \eta^k], \quad s_\ell = \frac{\ell-1}{L-1} \quad (18)$$

当 $\eta^k = 0$ 时, 式(18)退化为标准线性收敛因子; 当目标机动或队形偏差增大时, 较大的 η^k 使后续迭代保留更大的搜索尺度。候选恢复仅在 $\eta^k \geq 0.45$ 时触发。

3.3. 预测槽位引导方向

在忽略中间速度饱和且加速度在 H 个预测步内保持不变时, 由式(2)递推可得

$$\mathbf{p}_i^{k+H} = \mathbf{p}_i^k + H\Delta t \mathbf{v}_i^k + \frac{H(H+1)}{2} \Delta t^2 \mathbf{u}_i^k \quad (19)$$

令终端位置等于预测槽位 $\mathbf{s}_i^k$, 即可反解得到

$$\mathbf{u}_{i,g}^k = \Pi_{[-u_{\max}, u_{\max}]} \left(\frac{\mathbf{s}_i^k - \mathbf{p}_i^k - H\Delta t \mathbf{v}_i^k}{\Delta t^2 H(H+1)/2} \right) \quad (20)$$

因此, 引导加速度由预测槽位以及无人机的当前位置、当前速度共同决定。将三架无人机的三维引导加速度依次拼接, 得到九维引导候选:

$$\mathbf{X}_g^k = \left[(\mathbf{u}_{1,g}^k)^T, (\mathbf{u}_{2,g}^k)^T, (\mathbf{u}_{3,g}^k)^T \right]^T \in \mathbb{R}^9 \quad (21)$$

式(20)仅用于生成引导方向, 候选评价仍按式(2)~(4)传播, 因此速度和位置约束仍被保留。

3.4. 等预算候选恢复机制

当联合状态量超过恢复阈值时, 在第 30 次内部迭代执行一次候选恢复。根据恢复比例 $\rho = 0.20$, 从 28 个候选中选择 6 个适应度较差的候选。ST-A-GWO 首先限制引导候选相对当前 α 候选的偏移:

$$\mathbf{X}_c = \mathbf{X}_\alpha + \text{clip}(\mathbf{X}_g^k - \mathbf{X}_\alpha, -\sigma, \sigma) \quad (22)$$

随后在引导中心附近生成恢复候选:

$$\tilde{\mathbf{X}}_j = \Pi_{\mathcal{U}}(\mathbf{X}_c + \boldsymbol{\varepsilon}_j), \quad \boldsymbol{\varepsilon}_j \sim \mathcal{N}(\mathbf{0}, \text{diag}(\boldsymbol{\sigma}^2)) \quad (23)$$

式中, $\Pi_{\mathcal{U}}$ 表示九维加速度可行域投影; 各维扰动尺度 $\sigma = 0.18(U_{\max} - U_{\min}) = 1.08 \text{ m/s}^2$ 。恢复候选仅在适应度严格优于对应更新后候选时被接受:


$$\mathbf{X}_j \leftarrow \tilde{\mathbf{X}}_j, \quad \text{if } J(\tilde{\mathbf{X}}_j) < J(\mathbf{X}_j); \quad \text{otherwise } \mathbf{X}_j \text{ remains unchanged} \quad (24)$$

最差候选索引依据恢复前种群排序确定, 比较对象为常规 GWO 更新后的候选。随机恢复 GWO 在相同迭代位置从完整九维可行域均匀采样 6 个候选, 并采用相同严格接受规则。因此, 两种方法在每次恢复中的候选数量和新增目标函数评价次数相同, 主要差别为候选生成方向。

按照当前实现, 每次内部迭代对 28 个候选各评价一次, 45 次常规迭代对应 1260 次目标函数评价。触发恢复时, 对 6 个更新后候选及其 6 个恢复候选分别评价, 额外增加 12 次评价, 因此单次优化的评价次数不超过 1272 次。随机恢复 GWO 与 ST-A-GWO 采用相同的恢复候选数量、接受规则和单次恢复评价预算; 这里的等预算限定于同一次恢复事件, 闭环运行中的触发次数仍由各自状态轨迹决定。

3.5. 滚动优化控制流程

ST-A-GWO 的滚动优化流程如算法 1 所示:



Algorithm 1. Receding-horizon ST-A-GWO procedure
算法 1. ST-A-GWO 滚动优化流程

每个控制周期首先读取无人机和目标状态, 预测目标位置更新参考槽位; 随后计算联合状态量, 利用 ST-A-GWO 搜索九维加速度候选; 当状态量达到阈值时, 在固定内部迭代执行引导恢复; 优化结束后, 仅执行最优候选中的首个三轴加速度指令。状态推进一个控制周期后重复上述过程, 直至仿真结束。

4. 仿真实验设计

4.1. 仿真场景与参数

实验在 MATLAB R2026a 中完成。目标初始位置为(0, 0, 10) m, 三架无人机由初始参考槽位叠加小幅扰动生成, 初始速度均为 0, 且初始状态满足有效围控条件。水平突转为主要实验场景: 目标在 8.6 s 前以(3.2, 0, 0) m/s 运动, 此后变为(0, 3.2, 0) m/s。垂直突变场景用于检查不同运动方向变化下的表现, 其水平速度为(1.8, 0.1, 0) m/s, 垂直速度依次经历 0、2、-2 和 0 m/s。主要参数见表 1。

Table 1. Main simulation and algorithm parameters
表 1. 主要仿真与算法参数

类别	参数设置
仿真与预测	$T = 18\text{ s}$; $\Delta t = 0.2\text{ s}$; $H = 3$; $\tau = 0.6\text{ s}$
飞行约束	区域 $[-40, 40] \times [-40, 40] \times [3, 20]\text{ m}$; $v_h^{\max} = 4\text{ m/s}$; $v_z^{\max} = 2\text{ m/s}$; $u_{\max} = 3\text{ m/s}^2$
围控参数	$r_d = 7\text{ m}$; $d_s = 3.5\text{ m}$; $r_m = 10.5\text{ m}$; $h_i = 0.8, 0, -0.8\text{ m}$
有效围控容差	半径 1.25 m; 角度 20° ; 高度 0.60 m
优化参数	种群规模 28; 内部迭代 45 次
恢复与触发	阈值 0.45; 比例 0.20; 候选 6 个; 第 30 次迭代恢复; 扰动尺度 1.08 m/s^2
目标函数权重	半径 3; 角度 2; 安全 8; 控制变化 0.2; 高度 6; 监测范围 5; 槽位 0.8; 速度 2

参数敏感性实验在水平突转场景下进行。恢复阈值取 0.35、0.45 和 0.55，恢复比例取 0.10、0.20 和 0.30，恢复迭代取 20、30 和 40。每次仅改变一个参数，其余参数保持标称值，每种配置采用 10 个配对随机种子。

4.2. 对比方法

实验包括顺序消融、局部恢复对照和外部优化器对照，方法组成见表 2。IGWO 采用维度学习狩猎策略[9]，PSO 采用粒子群更新及收缩因子策略[10] [11]。

Table 2. Compared methods and experimental roles
表 2. 对比方法及实验作用

方法	主要组成	实验作用
标准 GWO	标准线性收敛因子，不预测、不恢复	基础方法
预测槽位 GWO	标准 GWO 与预测参考槽位	检查目标预测和槽位构造
状态自适应 GWO	预测槽位、联合状态量和自适应因子	顺序消融
随机恢复 GWO	状态自适应 GWO 与全域随机恢复	等预算无引导对照
局部恢复 GWO	状态自适应 GWO 与局部高斯恢复	局部随机搜索对照
ST-A-GWO	状态自适应 GWO 与预测槽位引导恢复	本文方法
粒子群优化	相同预测模型和目标函数下的 PSO	外部优化器对照
改进灰狼优化	采用维度学习狩猎策略的 IGWO	改进 GWO 对照

顺序消融采用随机种子 10301~10330，水平外部比较采用 15301~15330，垂直比较采用 16301~16330。除顺序消融中被有意移除的目标预测、参考槽位、状态自适应和候选恢复组件外，各方法采用相同的仿真场景、控制周期、目标函数、运动约束和种群规模；PSO、IGWO 及完整方法的外部比较采用相同的目标预测模型。各控制周期内，标准 GWO、ST-A-GWO 和 PSO 均采用 28 个个体(粒子)和 45 次迭代，对应 1260 次基础目标函数评价。PSO 采用收缩因子形式，取 $\chi = 0.7298$ 、 $c_1 = c_2 = 2.05$ ，速度上限设为各维搜索范围的 20%。IGWO 采用维度学习狩猎策略；由于每代同时生成经典 GWO 候选与 DLH 候选，为保持相同的 1260 次基础评价预算，设置为 22 代。随机恢复 GWO、局部恢复 GWO 和 ST-A-GWO 采用相同的触发条件、恢复迭代、单次恢复候选数量和接受规则：均在第 30 次迭代时新增 6 个候选。

局部恢复 GWO 用于检验预测槽位引导是否优于与任务无关的局部扰动。触发恢复时，先依据当轮排序选取适应度最差的 6 个个体；对这些个体完成常规 GWO 更新后的当前位置施加逐维高斯扰动，扰动标准差取各维搜索区间宽度的 18%，随后投影至控制变量上下界。仅当扰动候选的目标函数值严格优于其对应当前个体时，才以该候选替换当前个体。该对照不使用预测槽位或其他任务先验信息。

4.3. 评价指标与统计方法

半径均方根误差定义为：

$$RMSE_r = \sqrt{\frac{1}{N_t} \sum_{k=1}^{N_t} (E_r^k)^2} \tag{25}$$

式中， N_t 为仿真采样点数， $RMSE_r$ 的单位为 m。其他主要指标定义为：

$$R_e = \frac{1}{N_t} \sum_{k=1}^{N_t} e^k, \quad T_r = (k_r - k_l) \Delta t$$

$$E_u = \Delta t \sum_{k=1}^{N_t} \sum_{i=1}^3 \|u_i^k\|_2 \quad (26)$$

式中, R_e 为有效围控比例; k_l 为目标突变后首次失去有效围控的时刻; k_r 为此后首次连续 8 个采样点满足有效围控的起始时刻; T_r 为恢复时间; E_u 为控制代价。突变后始终有效时, $T_r = 0$; 失效后至仿真结束未重获连续 8 点有效围控时, T_r 记为缺失, 不计入均值。

正式实验对每种方法运行 30 个配对随机种子, 对同种子差值进行 4000 次配对 Bootstrap 重采样并给出 95% 置信区间。单次代表性轨迹只用于展示动态过程, 不替代配对统计结果。

5. 实验结果与分析

5.1. 代表性围控过程

图 2 给出了 ST-A-GWO 在水平突转场景下的一次代表性围控过程, 随机种子为 10301。目标在 8.6 s 时由沿 x 轴运动突变为沿 y 轴运动, 三架无人机随后调整飞行轨迹并继续维持具有高度差的协同队形。




Figure 2. Representative encirclement process of ST-A-GWO in the horizontal abrupt-turn scenario (seed 10301): (a) Three-dimensional trajectories of the target and three UAVs; (b) Radius root-mean-square error; (c) Joint state variable

图 2. ST-A-GWO 在水平突转场景下的代表性围控过程(随机种子 10301): (a) 目标与三架无人机的三维轨迹; (b) 半径均方根误差; (c) 联合状态量

目标突转时, 联合状态量迅速升至 1 并超过 0.45 的恢复阈值; 半径误差短时超过 1.25 m 容差线, 随后重新进入容差范围。该次运行的恢复时间为 1.0 s, 半径 RMSE 为 0.6707 m, 有效围控比例为 0.9451, 最小无人机间距为 11.5972 m。

5.2. 顺序消融实验

水平突转场景下的顺序消融结果见表 3。

Table 3. Sequential ablation results in the horizontal abrupt-turn scenario
表 3. 水平突转场景下的顺序消融结果

方法	恢复时间/s	半径 RMSE/m	有效围控比例	控制代价
标准 GWO	0.2000* (n = 27)	1.2619	0.2579	23.2381
预测槽位 GWO	1.0667	0.6767	0.9414	30.3508
状态自适应 GWO	1.1000	0.6813	0.9396	30.8001
随机恢复 GWO	1.1867	0.6914	0.9348	29.7007
ST-A-GWO	1.1000	0.6786	0.9396	30.5187

注：*标准 GWO 有 27 次获得可定义恢复时间，0.2000 s 为其均值；其余 3 次失效后至仿真结束未重获连续 8 点有效围控，故不计入均值。

状态自适应 GWO 相对预测槽位 GWO 的恢复时间、半径 RMSE 和有效围控比例差值的 95%置信区间均跨越 0；随机恢复 GWO 相对状态自适应 GWO 的多数指标置信区间同样跨越 0。因此，联合状态量和自适应收敛因子的独立增益未得到当前消融结果的稳定支持。

5.3. 引导恢复机制验证

在相同触发条件、恢复迭代、候选数量、接受规则和单次新增评价预算下，对 ST-A-GWO 与随机恢复 GWO 进行 30 组同种子配对比较，结果见表 4。两种方法仅候选生成方向不同，闭环总评价次数随实际触发次数变化。

Table 4. Paired differences between ST-A-GWO and random-recovery GWO
表 4. ST-A-GWO 相对随机恢复 GWO 的配对差值

指标	平均差值	95%置信区间
恢复时间/s	-0.0867	[-0.1800, -0.0067]
半径 RMSE/m	-0.0128	[-0.0251, -0.0013]
有效围控比例	0.0048	[0.0004, 0.0099]
最小机间距/m	0.0009	[-0.0074, 0.0096]
控制代价	0.8180	[-0.5800, 2.1176]

表 4 给出了 30 组同种子配对的平均差值及 95%置信区间。恢复时间、半径 RMSE 和有效围控比例的置信区间均未跨越 0，表明预测槽位引导恢复在当前水平突转场景下带来了幅度有限但方向稳定的改善；最小机间距和控制代价的置信区间跨越 0，说明两种方法在这两项指标上未呈现稳定差异。

5.4. 与标准 GWO、PSO 和 IGWO 的比较

不同优化器在水平突转场景下的结果见表 5。
图 3(a)~(c)给出了三种优化器在水平突转场景下的运行分布。相对粒子群优化，ST-A-GWO 的恢复时间减少 0.2600 s，半径 RMSE 减少 0.0232 m，有效围控比例提高 0.0143，相应 95%置信区间均未跨越 0。相对改进灰狼优化，恢复时间减少 0.3800 s，半径 RMSE 减少 0.0400 m，有效围控比例提高 0.0209；但控制代价提高 2.4696，其 95%置信区间为[0.9779, 3.8922]。

Table 5. Results of different optimizers in the horizontal abrupt-turn scenario
表 5. 水平突转场景下不同优化方法的结果

方法	恢复时间/s	半径 RMSE/m	有效围控比例	最小间距/m	控制代价
标准 GWO	0.2000* (n = 27)	1.2594	0.2678	12.0668	23.2104
粒子群优化	1.3400	0.7016	0.9264	11.5473	29.9235
改进灰狼优化	1.4600	0.7184	0.9198	11.5038	28.4337
ST-A-GWO	1.0800	0.6784	0.9407	11.5789	30.9034

注: *标准 GWO 有 27 次获得可定义恢复时间, 0.2000 s 为其条件均值; 其余 3 次失效后至仿真结束未重获连续 8 点有效围控, 故不计入均值, 该值不用于标准 GWO 整体恢复性能比较。




Figure 3. Distributions of PSO, IGWO and ST-A-GWO over 30 random seeds: (a)~(c) Horizontal abrupt-turn scenario; (d)~(f) Vertical abrupt-maneuver scenario. Diamonds denote means

图 3. PSO、IGWO 与 ST-A-GWO 在 30 个随机种子下的结果分布: (a)~(c) 水平突转场景; (d)~(f) 垂直突变场景; 菱形表示均值

5.5. 垂直突变与参数敏感性

垂直突变场景下的不同方法比较结果见表 6。

Table 6. Mean results in the vertical abrupt-maneuver scenario
表 6. 垂直突变场景下不同方法的平均结果

方法	恢复时间/s	半径 RMSE/m	高度 RMSE/m	有效围控比例	控制代价
预测槽位 GWO	2.2000	0.1972	0.5332	0.8791	46.1564
局部恢复 GWO	2.2000	0.1910	0.5332	0.8791	45.9171

续表

粒子群优化	2.2067	0.1898	0.5360	0.8788	47.5818
改进灰狼优化	2.2000	0.2159	0.5335	0.8791	47.1998
ST-A-GWO	2.2000	0.1943	0.5332	0.8791	45.9535

为考察恢复阈值、恢复比例和恢复迭代对结果的影响, 在水平突转场景下进行了单因素参数敏感性实验, 结果如图 4 所示。




Figure 4. Paired differences of single-factor parameter settings relative to the nominal parameters [points denote mean differences and horizontal lines denote 95% bootstrap confidence intervals ($n = 10$)]: (a) Recovery time; (b) Radius RMSE; (c) Eligible encirclement fraction

图 4. 单因素参数配置相对标称参数的配对差值[点表示平均差值, 横线表示 95% Bootstrap 置信区间($n = 10$)]: (a) 恢复时间; (b) 半径 RMSE; (c) 有效围控比例

图 4 表明, 除恢复阈值取 0.35 时半径 RMSE 差值的 95% 置信区间未跨越 0 外, 其余核心指标的置信区间大多跨越或包含边界 0。由于每种配置仅包含 10 个配对随机种子, 且一次只改变一个参数, 上述结果用于描述局部参数稳健性, 不能据此证明标称参数最优。

6. 讨论

等预算比较表明, ST-A-GWO 的改善主要体现在队形恢复指标。该方法将目标短时运动和期望队形几何映射到九维加速度空间, 使恢复候选更可能落入与队形重构相关的区域。其贡献在于围控任务信息向候选恢复方向的映射, 而非对通用动态优化记忆或预测机制的改进。

但顺序消融未稳定支持联合状态量和自适应收敛因子的独立增益。现有结果表明, 预测槽位引导在水平突转场景下相对全域随机恢复具有优势; 但尚不足以证明任务模型引导稳定优于一般局部搜索。

评价次数相当并不等同于实际求解时间, 本文尚未在统一计算环境下报告耗时。仿真未考虑测量噪声、通信延迟和状态估计误差, 且模型仅验证三架无人机的九维控制, 因此结论不能直接推广至任意规模集群。

此外, 本文针对 3 架无人机构造 3 处参考槽位, 优化维数固定为 9。若扩展到更多无人机, 控制维数

将随数量增加, 槽位分配、相邻方位约束和候选恢复比例也需重新设计。因此, 本文结论限定于三无人机受限三维协同围控, 不能直接外推为任意规模无人机集群的性能结论。

7. 结论

针对目标运动方向突变时三无人机围控队形重构困难的问题, 本文提出预测槽位引导的 ST-A-GWO 方法。该方法根据目标短时预测位置构造三维参考槽位, 将槽位反解为九维加速度引导方向, 并在联合状态量超过阈值时, 对固定数量候选实施等预算引导恢复。

水平突转场景的 30 次配对实验表明, 相对随机恢复 GWO, ST-A-GWO 的平均恢复时间减少 0.0867 s, 半径 RMSE 减少 0.0128 m, 有效围控比例提高 0.0048, 三项差值的 95%置信区间均未跨越 0。与 PSO 和 IGWO 相比, ST-A-GWO 在水平场景的队形恢复指标上具有优势, 但控制代价和跨场景表现仍存在局限。后续可进一步考察连续机动、目标状态估计误差及不同槽位几何参数对引导恢复性能的影响。

参考文献

- [1] Hafez, A.T., Marasco, A.J., Givigi, S.N., Iskandarani, M., Yousefi, S. and Rabbath, C.A. (2015) Solving Multi-UAV Dynamic Encirclement via Model Predictive Control. *IEEE Transactions on Control Systems Technology*, **23**, 2251-2265. <https://doi.org/10.1109/tcst.2015.2411632>
- [2] Wang, W., Chen, X., Jia, J. and Fu, Z. (2022) Target Localization and Encirclement Control for Multi-UAVs with Limited Information. *IET Control Theory & Applications*, **16**, 1396-1404. <https://doi.org/10.1049/cth2.12314>
- [3] Gao, Y., Bai, C., Zhang, L. and Quan, Q. (2022) Multi-UAV Cooperative Target Encirclement within an Annular Virtual Tube. *Aerospace Science and Technology*, **128**, Article ID: 107800. <https://doi.org/10.1016/j.ast.2022.107800>
- [4] Mirjalili, S., Mirjalili, S.M. and Lewis, A. (2014) Grey Wolf Optimizer. *Advances in Engineering Software*, **69**, 46-61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- [5] Yao, P., Wang, H. and Ji, H. (2016) Multi-UAVs Tracking Target in Urban Environment by Model Predictive Control and Improved Grey Wolf Optimizer. *Aerospace Science and Technology*, **55**, 131-143. <https://doi.org/10.1016/j.ast.2016.05.016>
- [6] Wang, Y., Zhang, T., Cai, Z., Zhao, J. and Wu, K. (2020) Multi-UAV Coordination Control by Chaotic Grey Wolf Optimization Based Distributed MPC with Event-Triggered Strategy. *Chinese Journal of Aeronautics*, **33**, 2877-2897. <https://doi.org/10.1016/j.cja.2020.04.028>
- [7] 秦冬燕, 闫晓辉, 邵桂伟, 等. 基于事件触发灰狼优化算法的四旋翼无人机三维航迹规划[J]. 智能系统学报, 2025, 20(3): 699-706.
- [8] Peng, J., Tian, X. and Wang, N. (2025) Railway Multi UAV Collaborative Encirclement Strategy Based on Grey Wolf Optimization Dynamic Encirclement Points. *Aviation*, **29**, 231-241. <https://doi.org/10.3846/aviation.2025.25360>
- [9] Nadimi-Shahraki, M.H., Taghian, S. and Mirjalili, S. (2021) An Improved Grey Wolf Optimizer for Solving Engineering Problems. *Expert Systems with Applications*, **166**, Article ID: 113917. <https://doi.org/10.1016/j.eswa.2020.113917>
- [10] Kennedy, J. and Eberhart, R. (1995) Particle Swarm Optimization. *Proceedings of ICNN'95—International Conference on Neural Networks*, Perth, 27 November-1 December 1995, 1942-1948. <https://doi.org/10.1109/icnn.1995.488968>
- [11] Clerc, M. and Kennedy, J. (2002) The Particle Swarm—Explosion, Stability, and Convergence in a Multidimensional Complex Space. *IEEE Transactions on Evolutionary Computation*, **6**, 58-73. <https://doi.org/10.1109/4235.985692>
- [12] Olfati-Saber, R. (2006) Flocking for Multi-Agent Dynamic Systems: Algorithms and Theory. *IEEE Transactions on Automatic Control*, **51**, 401-420. <https://doi.org/10.1109/tac.2005.864190>
- [13] Cao, Y., Yu, W., Ren, W. and Chen, G. (2013) An Overview of Recent Progress in the Study of Distributed Multi-Agent Coordination. *IEEE Transactions on Industrial Informatics*, **9**, 427-438. <https://doi.org/10.1109/tii.2012.2219061>
- [14] Chung, S., Paranjape, A.A., Dames, P., Shen, S. and Kumar, V. (2018) A Survey on Aerial Swarm Robotics. *IEEE Transactions on Robotics*, **34**, 837-855. <https://doi.org/10.1109/tro.2018.2857475>
- [15] Qin, S.J. and Badgwell, T.A. (2003) A Survey of Industrial Model Predictive Control Technology. *Control Engineering Practice*, **11**, 733-764. [https://doi.org/10.1016/s0967-0661\(02\)00186-7](https://doi.org/10.1016/s0967-0661(02)00186-7)
- [16] Rong Li, X. and Jilkov, V.P. (2003) Survey of Maneuvering Targettracking. Part I: Dynamic Models. *IEEE Transactions*

-
- on *Aerospace and Electronic Systems*, **39**, 1333-1364. <https://doi.org/10.1109/taes.2003.1261132>
- [17] Faris, H., Aljarah, I., Al-Betar, M.A. and Mirjalili, S. (2018) Grey Wolf Optimizer: A Review of Recent Variants and Applications. *Neural Computing and Applications*, **30**, 413-435. <https://doi.org/10.1007/s00521-017-3272-5>
- [18] Blackwell, T. and Branke, J. (2006) Multiswarms, Exclusion, and Anti-Convergence in Dynamic Environments. *IEEE Transactions on Evolutionary Computation*, **10**, 459-472. <https://doi.org/10.1109/tevc.2005.857074>