

# 基于机器视觉技术的小型无人机飞行轨迹 自动控制方法

周雪会<sup>1</sup>, 张蓉花<sup>2</sup>, 谢彤<sup>1</sup>, 李可成<sup>1</sup>

(1. 广西工业职业技术学院 装备智造学院, 南宁 530001;

2. 湖南工学院 计算机科学与工程学院, 湖南 衡阳 421002)

**摘要:** 小型无人机飞行过程中, 面对复杂环境时的三维激光雷达采集模式容易出现“假回环”问题, 由此生成的轨迹位置误差较大, 导致小型无人机飞行轨迹自动控制质量下降, 为此提出基于机器视觉技术的小型无人机飞行轨迹自动控制方法; 通过无人机搭载相机获取无人机飞行区域环境图像, 运用机器视觉技术完成色彩模型转化、曲率滤波、特征点提取与转化等图像处理工作, 感知飞行环境中的障碍物分布信息, 绘制出三维环境感知地图; 机器视觉技术通过特征点提取和匹配算法, 能够减少因激光雷达数据噪声或环境干扰导致的误匹配问题, 这有助于降低“假回环”的出现概率; 应用改进 A\* 算法在机器视觉环境感知地图中搜索出一条飞行路线, 为后续飞行轨迹控制提供重要的基础; 结合迭代学习算法和 PD 控制算法建立自动控制方案, 该控制方案主要考虑规划飞行路线和无人机实际飞行轨迹之间的误差, 对飞行轨迹进行有效控制, 保证无人机的飞行安全性; 实验结果表明, 依靠该方法完成飞行轨迹自动控制后, 所呈现出的位置误差小于 0.5 m, 能够更好地辅助小型无人机完成飞行任务, 可以在实际中得到广泛应用。

**关键词:** 小型无人机; 机器视觉技术; 环境感知; 轨迹规划; 飞行控制; 强化迭代学习

## Automatic Control Method for Flight Trajectory of Small Drones Based on Machine Vision Technology

ZHOU Xuehui<sup>1</sup>, ZHANG Ronghua<sup>2</sup>, XIE Tong<sup>1</sup>, LI Kecheng<sup>1</sup>

(1. Institute of Equipment Manufacturing and Intelligence, Guangxi Vocational & Technical Institute of Industry, Nanning 530001, China;

2. School of Computer Science and Engineering, Hunan Institute of Technology, Hengyang 421002, China)

**Abstract:** During the flight of small drones, the three-dimensional laser radar acquisition mode in complex environments is prone to the problem of “false loops”, resulting in significant trajectory errors and degraded automatic control quality for the drones' flight trajectories. Therefore, a machine vision based method for automatic control of small drones' flight trajectories is proposed. A camera mounted on a drone is used to capture the images of the drone's flight area environment, and applying a machine vision technology to complete image processing tasks such as color model conversion, curvature filtering, feature point extraction, and transformation, which perceives obstacle distribution information in flight environments and generates a three-dimensional environment perception map. Through feature point extraction and matching algorithms, the machine vision technology can reduce the false matching caused by LiDAR data noises or environmental interference, which helps to reduce the probability of “false loops”. by using the improved A\* algorithm to search for a flight route in the ma-

收稿日期: 2025-02-27; 修回日期: 2025-04-24。

基金项目: 2025 年广西高校中青年教师科研基础能力提升项目 (2025KY1553); 国家级自然科学基金 (017DN004145); 2023 年广西高校中青年教师科研基础能力提升项目 (2023KY1316); 全国航空工业职业教育教指委“基于低空经济产教融合平台探索高质量成果”重点课题; 广西工业职业技术学院 2024 年度校级科研项目 (GYKY2024012B)。

作者简介: 周雪会 (1981-), 女, 硕士, 副教授。

谢彤 (1975-), 男, 硕士, 教授, 高级双师。

通讯作者: 李可成 (1980-), 男, 大学本科, 副教授。

引用格式: 周雪会, 张蓉花, 谢彤, 等. 基于机器视觉技术的小型无人机飞行轨迹自动控制方法[J]. 计算机测量与控制, 2026, 34(3): 111-120, 129.

chine vision environment perception map, providing an important foundation for subsequent flight trajectory control. By combining the iterative learning algorithm and the PD control algorithm, an automatic control scheme is established, which mainly considers the error between the planned flight route and the actual flight trajectory of the drone, effectively controlling the flight trajectory and ensuring the flight safety of the drone. Experimental results show that after applying this method, the position error of the automatic flight trajectory is less than 0.5 m, which can better assist small drones in flight tasks and be widely applied in practice.

**Keywords:** small drones; machine vision technology; environmental perception; trajectory planning; flight control; reinforcement iterative learning

## 0 引言

在工业智能化和数字化发展趋势下,小型无人机作为新兴的空中智能平台,凭借其灵活性强、作业范围广、成本效益高等优势<sup>[1]</sup>,逐步在实际中得到了广泛应用。小型无人机飞行轨迹自动控制的研究,是工业自动化领域中的一个重要课题,轨迹控制不仅关系到任务执行的效率和准确性,更直接关系到生产安全、设备保护和人员安全<sup>[2]</sup>。然而,工业环境中的障碍物种类繁多、形状各异,工业任务具有复杂性和不确定性<sup>[3]</sup>,这都为无人机轨迹自动控制带来了挑战,在该背景下设计一种高效、智能的小型无人机飞行轨迹自动控制方法,是当前工业自动化领域当前研究的重要方向。

当前针对该问题的研究已经出现了诸多优秀的研究成果,例如杨昆等人<sup>[4]</sup>提出基于自适应反步滑模的控制方法。考虑位置环境干扰和自身动力学特点,对设备运动轨迹进行跟踪,并通过对比计算确定当前轨迹与期望轨迹之间的误差。通过反步自适应法和滑膜控制算法构造自动轨迹控制器,将实时轨迹跟踪误差输入其中进行补偿处理,即可完成轨迹实时控制。但是该方法不能捕捉足够的细节信息,导致系统错误地将两个不相邻或不相似的位置或特征点识别为相同或相似,从而形成了错误的回环信息,导致轨迹控制结果出现较大的位置误差。陈丰毅等人<sup>[5]</sup>提出基于自适应神经网络的控制方法。从位置子系统、姿态子系统两方面入手,分别构造基于干扰估计的控制器,并将自适应神经网络引入控制器中。参考期望飞行轨迹,应用自适应控制器对当前无人机运行参数进行补偿,即可得出符合预期目标的无人机轨迹自动控制方案。在 SLAM 系统中,由于数据噪声、环境干扰或算法误差等原因,导致数据质量变差,因此但是自适应神经网络逼近过程中出现误差,这种误差传递到轨迹跟踪控制过程中,会造成较大的位置误差。刘旭光等人提出<sup>[6]</sup>基于强化迭代学习的控制方法。以 PD 控制算法为核心,建立面向无人机飞行轨迹控制的智能控制结构,根据动态环境变化运用迭代学习算法优化控制参数,以便达到最优的轨迹控制效果。但在强化学习中,状态空间离散化操作可能损失部分信息,将两个不

相邻或不相似的位置或特征点识别为相同或相似,从而形成了错误的回环信息,导致学习到的轨迹控制结果表现出的位置误差较为严重。杨洋等人<sup>[7]</sup>提出基于改进滑模观测器的控制方法。依托于滑模观测思想建立快速三阶滑模观测器,估计无人机飞行过程中面临的位置干扰,作为飞行轨迹控制的基础。将非奇异终端滑模理论与超螺旋理论结合起来,构造轨迹控制滑模控制器,将飞行轨迹误差和干扰估计观测值同时输入其中,即可完成无人机飞行轨迹自动化控制。从应用结果来看,该方法的实现和集成相对简单,可以大范围推广应用,但观测器获取状态信息时容易受到外界环境干扰,信息采集结果中存在着错误的回环信息,基于此所获取的飞行轨迹控制结果,存在较大的位置误差。

针对上述提出的挑战,探索新的无人机飞行轨迹自动控制算法时,将人工智能领域的机器视觉技术应用到其中,借助计算机对飞行区域现场图像进行处理和分析,实现对目标的识别、跟踪和定位,以便完成无人机飞行环境的准确感知。在此基础上,运用改进 A\* 算法规划出飞行轨迹,并结合强化迭代学习和 PID 控制思想,完成飞行轨迹自动控制,确保无人机在复杂的环境中能够安全、高效地完成飞行任务。

## 1 小型无人机飞行轨迹自动控制

### 1.1 基于机器视觉技术的飞行环境感知

传统的无人机需要依赖固定的飞行路径或预设的程序进行飞行,而基于机器视觉技术的无人机在飞行过程中,借助其上搭载的图像传感器实时获取飞行区域的图像信息,运用机器视觉技术对这些图像进行高效处理和模式识别,获取地形、障碍物等丰富的环境信息<sup>[8]</sup>,可以为无人机飞行轨迹规划和自动控制提供依据。这种技术融合不仅提高了无人机的自主飞行能力,还拓展了其应用范围,使得无人机能够在更复杂、多变的环境中执行任务,提高了其飞行效率和安全性。

考虑到光照强度会对机器视觉图像产生极大影响,导致 RGB 图像中很多细节信息被掩盖。因此,应用机器视觉技术感知无人机飞行区域环境信息时,先对原始图像的色彩模型进行转化,获取稳定性较强的 HSV 色彩模型图像<sup>[9]</sup>。具体转化公式为:

$$\begin{aligned}
 H(o, v) = & \\
 \begin{cases} \frac{60[G(o, v) - B(o, v)]}{V(o, v) - m(o, v)}, & V(o, v) = G(o, v) \\ 120 + \frac{60[B(o, v) - R(o, v)]}{V(o, v) - m(o, v)}, & V(o, v) = B(o, v) \\ 240 + \frac{60[R(o, v) - G(o, v)]}{V(o, v) - m(o, v)}, & V(o, v) = R(o, v) \end{cases} & (1) \\
 S(o, v) = & \begin{cases} \frac{V(o, v) - m(o, v)}{V(o, v)}, & V(o, v) \neq 0 \\ 0, & V(o, v) = 0 \end{cases} & (2) \\
 V(o, v) = & a(o, v) & (3)
 \end{aligned}$$

式中,  $(o, v)$  表示机器视觉图像像素点,  $R$  表示红色分量,  $G, B$  分别表示绿色分量和蓝色分量,  $H$  表示色相分量,  $S, V$  分别表示饱和度分量和明度分量,  $m$  表示 RGB 通道的色彩分量最小值,  $a$  表示 RGB 通道的色彩分量最大值。

以公式 (1) ~ (3) 给出的色彩分量转换结果为基础, 结合加权运算概念<sup>[10]</sup> 推导出重构的飞行区域机器视觉图像:

$$I(o, v) = \frac{\omega_1 H(o, v) + \omega_2 S(o, v) + \omega_3 V(o, v)}{3} \quad (4)$$

式中,  $I$  表示重构后的 HSV 色彩模型图像,  $\omega_1, \omega_2, \omega_3$  表示取值范围在 0~1 之间的加权系数。在 HSV 色彩模型转化中, 加权系数取值范围限定在 0 到 1 之间, 这一设定源于 HSV 模型的特性、加权运算的需求以及实际应用的考虑。HSV 模型由色调  $H$  ( $0^\circ \sim 360^\circ$  或归一化至 0~1)、饱和度  $S$  (0~1) 和亮度  $V$  (0~1) 组成。加权运算根据各分量重要性进行差异化处理, 而加权系数 (0~1) 反映了这种重要性的评估。此设定简化了计算, 提高了效率, 确保了色彩匹配的准确性, 并避免了数据溢出。因此, 加权系数在 0 到 1 之间的取值范围是综合考虑了 HSV 模型特性、加权运算概念及实际应用需求的结果。

面向色彩转化后的机器视觉环境图像, 应用域分解法对像素点进行划分, 并消除相邻像素点之间的依赖性, 使得同类别像素点无论水平还是垂直都不相邻<sup>[11]</sup>, 不相邻域分解示意图如图 1 所示。

以图 1 所示的图像不相邻域分解结果为基础, 应用曲率滤波算法对像素点进行计算, 滤除机器视觉图像中包含的噪声信息, 即可得到:

$$\begin{cases} \hat{I}(o, v) = c\{I(o, v)\} + b \\ b = \min\{|b'_i|, i = 1, 2, 3, 4\} \end{cases} \quad (5)$$

式中,  $\hat{I}(o, v)$  表示滤波后的飞行环境机器视觉图像,  $c$  表示曲率滤波函数,  $b$  表示最小投影数值,  $b'$  表示目标像素点到曲面的投影长度,  $i$  表示曲面编号。最小投影数值需根据图像噪声水平和边缘特征精细调整, 以平衡平




图1 不相邻域分解示意图

滑效果与边缘保留, 同时考虑计算效率与精度。曲面编号则要求唯一且易于区分, 以简化算法设计并提高可读性, 同时需具备良好的适应性和可扩展性, 以适应图像复杂度和应用场景的变化。因此, 在实际应用中, 这些参数的设定需根据具体情况优化, 以实现最佳滤波效果。

通过公式 (5) 对原始图像完成滤波处理, 解决了因光线变化、机器人振动等因素引起的干扰噪声<sup>[12]</sup>, 使得现场采集图像能够表述更加丰富的机器视觉信息。

为了准确感知的小型无人机飞行环境, 借助机器视觉技术中的图像特征提取思想, 对滤波后的环境图像进一步分析。将环境视觉图像转换为灰度图像, 并调整每帧图像的分辨率使其归一化<sup>[13]</sup>, 这一标准化步骤不仅简化了图像处理流程, 还可以弥补特征提取算法在尺度不变性方面的不足。

引入 ORB 算法 (定向快速与旋转二进制鲁棒独立基本特征算法)<sup>[14]</sup>, 通过 FAST 检测器识别出位于图像中心的全局特征点, 以分散存在的局部特征点。随后比较特征点周围像素的灰度值大小关系, 生成一个能够准确反映图像整体特征的二进制字符串, 这一二进制字符串可以用 BRIEF 描述符表示<sup>[15]</sup>, 以此来刻画图像局部灰度值的相对大小关系。其中, 面向任意特征点定义的 BRIEF 算子, 可以表示为公式 (6):

$$\epsilon(\hat{I}; g_1, g_2) = \begin{cases} 1, & \alpha(g_1) < \alpha(g_2) \\ 0, & \alpha(g_1) \geq \alpha(g_2) \end{cases} \quad (6)$$

式中,  $\epsilon$  表示 BRIEF 算子,  $g_1, g_2$  表示 2 个不同的像素点,  $\alpha$  表示像素点灰度值。

针对无人机飞行区域环境图像中包含的所有特征点, 分别定义对应的 BRIEF 算子, 并通过汇总分析, 得到公式 (7) 所示的二进制字符串:

$$o(\hat{I}) = \prod_{j=1}^n 2^{j+1} \epsilon(\hat{I}; g_{1j}, g_{2j}) \quad (7)$$

式中,  $o$  表示机器视觉图像特征集对应的二进制字符串,

$n$  表示特征点数量,  $j$  表示特征点编号。特征点数量 ( $N$ ) 的选择取决于图像中可用于特征提取的有效信息量。在实际应用中, 通常需要根据图像质量和特征点的分布情况来确定一个合适的阈值, 以确保提取到足够数量的有效特征点。特征点编号需确保唯一性、稳定性及便于管理。编号原则考虑特征点位置、检测顺序等因素, 以保证有序性和可追踪性, 从而准确构建机器视觉特征集对应的二进制字符串, 反映真实场景特征信息。

将公式 (7) 计算出的二进制字符串, 看作无人机飞行区域机器视觉图像包含的所有特征信息。考虑到世界坐标系与摄像机坐标系之间的转换关系, 定义旋转矩阵和平移向量<sup>[16]</sup>。利用旋转矩阵和平移向量, 对每个特征点进行转换, 使其表达的环境信息能够反映无人机飞行区域的真实场景:

$$z = \begin{bmatrix} o'_1 & v'_1 \\ o'_2 & v'_2 \end{bmatrix} = \mathbf{oR} \begin{bmatrix} o_1 & v_1 \\ o_2 & v_2 \end{bmatrix} + \mathbf{T} \quad (8)$$

式中,  $(o_1, v_1)$  表示摄像机坐标系内特征像素点  $g_1$  的坐标,  $(o_2, v_2)$  表示摄像机坐标系内特征像素点  $g_2$  的坐标,  $(o'_1, v'_1)$ 、 $(o'_2, v'_2)$  表示两个特征像素点在世界坐标系内的坐标,  $\mathbf{R}$  表示旋转矩阵,  $\mathbf{T}$  表示平移向量。旋转矩阵和平移向量是实现坐标系转换的关键, 确保特征点坐标在不同坐标系下准确对应。这些参数的计算依赖于相机标定, 通过标定可获得相机的内参 (如焦距、主点坐标、畸变系数) 和外参 (如相机相对于世界坐标系的姿态和位置)。

获取无人机飞行环境视觉图像特征点, 在世界坐标系内的坐标后, 下一步是进行三维空间重构, 将环境感知结果直观呈现出来。从两个或多个视角观察到的同一特征点入手, 通过比较分析推导出特征点在三维空间中的确切位置, 一旦获得了足够数量的三维特征点, 就可以将这些点依次连接起来, 形成一个三维环境感知地图<sup>[17]</sup>, 其计算公式如下:

$$Z(t) = (1-t)^2 z_1 + 2(1-t)t z_2 + \dots + n(1-t)t z_n \quad (9)$$

公式 (9) 用来表达尽可能接近真实环境的障碍分布情况, 指导小型无人机飞行轨迹的变化控制。

上述内容主要介绍了基于机器视觉技术的小型无人机飞行环境感知方法。首先通过图像传感器实时获取飞行区域的图像信息, 并运用机器视觉技术进行图像处理和模式识别, 获取地形、障碍物等环境信息。同时为了应对光照强度对图像的影响, 采用 HSV 色彩模型进行图像转化, 并通过加权运算重构图像, 提升了图像质量。接着, 应用域分解方法和曲率滤波算法对图像进行滤波处理, 以减少图像噪声干扰。最后, 利用 ORB 算法提取图像特征, 构建机器视觉特征集对应的二进制字符串, 并通过旋转矩阵和平移向量实现坐标系转换,

获取特征点在世界坐标系内的坐标, 为三维空间重构提供基础。综上所述, 该过程为无人机飞行轨迹自动控制提供了重要的前提和依据。

## 1.2 无人机飞行轨迹规划

在 1.1 小节利用机器视觉技术实现飞行环境感知后获取三维环境感知地图, 以避免环境中的障碍物为前提, 规划出一条光滑连续的飞行轨迹, 将其作为实现飞行轨迹自动控制的重要前提<sup>[18]</sup>。考虑到小型无人机飞行动力学特性和工作任务要求, 将飞行轨迹规划目标函数表示为公式 (10):

$$J = \int_0^\beta h_0 P(s)^2 + h_1 P'(s)^2 + \dots + h_N P^N(s)^2 = \mathbf{p}^\beta \mathbf{Q}(\beta) \mathbf{p} \quad (10)$$

式中,  $J$  表示小型无人机飞行轨迹规划目标函数,  $\beta$  表示飞行时间,  $\mathbf{p}$  表示由子轨迹段对应的多项式系数构成的向量,  $\mathbf{Q}$  表示微分计算后生成的海森矩阵,  $P$  表示关于时间的轨迹规划多项式,  $N$  表示阶数,  $s$  表示当前时刻,  $h$  表示多项式系数。

根据小型无人机飞行要求, 针对每段飞行规划轨迹端点, 提出位置、速度等方面的约束条件, 并将其表示为:

$$\begin{bmatrix} \mathbf{A}_0 \\ \mathbf{A}_\beta \end{bmatrix}_r \mathbf{p}_r = \begin{bmatrix} d_0 \\ d_\beta \end{bmatrix} \quad (11)$$

式中,  $\mathbf{A}$  表示映射矩阵,  $r$  表示无人机飞行轨迹段编号,  $d$  表示子轨迹端点处的各阶导数值。

将公式 (11) 给出的约束条件代入到公式 (10) 中, 得到约束条件限制下的飞行轨迹规划目标函数。为了更有效地处理这个目标函数, 引入置换矩阵的概念对目标函数中的变量进行重新排序, 将已知的飞行轨迹起点和终点的位置及其各阶导数、子轨迹端点的位置, 视为已经确定或固定的导数, 这些固定导数构成了轨迹规划的基础框架<sup>[19]</sup>。而待优化的子轨迹端点处的位置及其各阶导数, 则被定义为自由导数。自由导数是通过优化过程进行调整的变量, 用来辅助搜索最佳飞行轨迹。将固定导数和自由导数区分开来, 有利于清晰地看到哪些变量是已知的, 哪些是需要通过优化来确定的<sup>[20]</sup>。在这样的背景下, 可以生成公式 (12) 所示的无人机飞行轨迹规划目标函数形式:

$$\mathbf{J}' = \begin{bmatrix} d' \\ d'' \end{bmatrix}^\beta \mathbf{C} \mathbf{D}^{-\beta} \boldsymbol{\chi} \mathbf{D}^{-\beta} \mathbf{C}^\beta \begin{bmatrix} d' \\ d'' \end{bmatrix} \quad (12)$$

式中,  $d'$  表示固定导数,  $d''$  表示自由导数,  $\mathbf{C}$  表示置换矩阵,  $\boldsymbol{\chi}$ 、 $\mathbf{D}$  表示对角矩阵。

面向公式 (12) 给出的飞行轨迹规划目标, 引入改进 A\* 算法在飞行环境感知地图中进行启发式搜索, 最终生成一条符合控制要求的飞行轨迹规划路线。A\* 算法的核心思想是将整个搜索空间进行细致划分, 将其转

化为一个由规则网格节点构成的体系<sup>[21]</sup>。这些网格节点构成了搜索区域的“地图”，它们以二维或三维数组的形式进行组织，从而实现了对整个搜索空间的数字化表示。每一个数组元素都与一个特定的网格节点相对应，而元素的取值则用来描述该节点的可达性<sup>[22]</sup>。传统 A\* 算法在面对复杂飞行环境时，尤其是存在障碍物和多层网格节点的场景中，可能面临搜索效率低下和路径规划不够精确的问题。为了解决这些问题，对传统 A 算法进行改进：首先，在搜索策略上，引入了跳点搜索技术，该技术能够智能地跳过直线路径上的无效节点，减少搜索空间，提高搜索效率。同时，算法会根据当前搜索的状态和目标动态调整搜索范围，特别是在遇到障碍物时，会依据障碍物的位置和大小，智能地剔除部分无效的搜索路径，从而进一步简化搜索过程。无效节点为被障碍物完全包围或路径冗长的节点，其中路径冗长的判断依据为从起点到节点  $n$  的路径长度  $L(n)$  超过预设阈值  $\theta$ ，且该节点的启发式函数值  $f(n)$  不小于其邻接节点的最优路径估计值  $f_{\min}(n')$ ，即：

$$L(n) > \theta \text{ 且 } f(n) \geq f_{\min}(n'), \forall n' \in \text{Neighbor}(n) \quad (13)$$

在搜索过程中，动态计算每个节点的路径长度和启发式函数值，并与预设阈值和邻接节点的最小启发式函数值进行比较，预设阈值根据路径规划的具体需求（如时间、距离、安全性等），确定一个可接受的路径冗长度范围，若满足上述条件，则标记为无效节点，从而跳过。

其次，在对网格节点的处理方式上，提出了节点剔除与保留策略。在面对障碍物时，算法会根据路径长度和节点的重要性来动态剔除或保留网格节点，避免在搜索过程中出现冗余路径，提高路径规划的精确度和效率。重要节点为连接被障碍物隔离区域或提供显著路径优化的节点，其判断依据为从起点经过该节点到目标的路径长度小于其他候选节点的路径长度，即：

$$f_{\text{opt}}(n) + g(n, \text{goal}) < f_{\text{opt}}(n') + g(n', \text{goal}) \quad (14)$$

式中， $f_{\text{opt}}(n)$  表示经过节点  $n$  的最优路径估计值， $g(n, \text{goal})$  表示从节点  $n$  到目标的实际路径长度， $n'$  表示候选节点。

在面对障碍物时，算法会根据上述判断标准动态剔除无效或低效节点，并保留重要节点。包含障碍物的飞行环境节点剔除示意图如图 2 所示。

以图 2 给出的飞行环境感知场景为例，该场景中第一层与第二层的 2 号节点存在障碍物，对路径搜索的逻辑产生了直接影响。改进 A\* 算法尝试从第二层的 4 号节点向 5 号节点探索飞行路径时，面临着一个关键的判断点：是否应继续考虑通过 5 号节点来扩展搜索范围。针对这一问题作出决策时，算法需要比较




图 2 包含障碍物的飞行环境节点剔除示意图

两种路径长度，一是通过 5 号节点到达目标节点的路径，二是不经过 5 号节点直接到达目标节点的路径。在全面考虑第一层全数节点和第二层的部分节点，而忽略第三层节点的情况下，如果通过 5 号节点再前往第二层及第一层的多个节点，这些路径的长度普遍大于不经过 5 号节点的直接飞行路径。依据这一发现可以确定，某些情况下 5 号节点作为中转站的角色是低效的，因此可以从搜索空间中剔除这些经由 5 号节点的路径，从而简化搜索过程。但也存在特殊情况，如果 3 号节点被标记为“不可剔除节点”<sup>[23]</sup>，通过 5 号节点到达第一层与第二层的 3 号节点时，所产生的路径会比直接路径更短，此时 5 号节点作为连接障碍区域与被隔离节点的桥梁，扮演着不可或缺的角色，该条件下路径搜索中 5 号节点必须被保留。

按照上述决策原理，对飞行环境中所有节点进行修剪，保留所有“不可剔除节点”，避免改进 A\* 算法搜索路径出现冗余。“不可剔除节点”是指在无人机飞行轨迹规划中，即使面临障碍物或其他复杂环境因素，也必须保留在搜索路径中的关键网格节点。这些节点对于连接被障碍物隔离的区域、优化路径长度或满足特定飞行要求至关重要。判断“不可剔除节点”的依据包括路径长度优化、连接性、飞行动力学要求以及启发式函数值。在实际飞行环境感知地图中，通过构建三维环境感知地图，初步规划飞行路径，并根据路径长度、启发式函数值等指标评估每个网格节点，可以识别出潜在的“不可剔除节点”。在搜索过程中，根据无人机的实时位置和障碍物信息动态调整这些节点，并利用可视化工具进行验证和优化，以确保路径规划的安全性和有效性。通过这一系列步骤，可以确保在复杂的飞行环境中准确识别并保留“不可剔除节点”，从而提高无人机飞行轨迹规划的精确度和效率。改进 A\* 算法开始从小型无人机飞行起点出发进行搜索，它的搜索过程并不是盲目的，而是受到一个启发函数的引导，根据当前搜索的状态和目标，为算法搜索方向提供重要指导，使其在机器视觉感知环境中移动，从一个网格节点跳到另一个网格节点。这一过程中，算法会根据距离、时间或其他相关

因素，计算出每个可达网格节点的代价值，由此确定具体的无人机飞行移动决策。

本文以欧几里得距离作为启发函数，估计代价  $h(n)$  为当前网格节点  $(x_n, y_n)$  与目标网格节点  $(x_g, y_g)$  的欧几里得距离：

$$h(n) = \sqrt{(x_n - x_g)^2 + (y_n - y_g)^2} \quad (15)$$

由此计算代价函数：

$$f(n) = g(n) + h(n) \quad (16)$$

式中， $f(n)$  表示从起点经过节点  $n$  到达目标节点的代价， $g(n)$  表示从起点到当前节点  $n$  的实际代价。

通过这种方式，改进 A\* 算法能够逐步逼近最优路径，找到一条连接起点与终点、途经所有无人机悬停点，且代价值最小的飞行轨迹规划路线  $J^d$ 。

在获取了精确的三维环境感知地图后，该章节聚焦于如何规划出一条光滑连续的飞行轨迹。首先提出了综合考虑飞行时间、动力学特性和工作任务要求的飞行轨迹规划目标函数，并针对每段飞行规划轨迹的端点提出了位置、速度等方面的约束条件。为了简化目标函数处理过程，引入了置换矩阵对变量进行重新排序，区分了固定导数和自由导数。最终，采用改进 A\* 算法在飞行环境感知地图中进行启发式搜索，生成了符合控制要求的飞行轨迹规划路线。该过程提高了搜索效率和路径规划精确度，还使无人机能够灵活应对复杂的飞行环境，确保飞行轨迹的光滑连续。

### 1.3 飞行轨迹迭代学习控制

依托于 1.2 规划出来的小型无人机飞行轨迹规划路线对无人机飞行轨迹进行控制。在此过程中考虑到自适应要求<sup>[24]</sup>，借鉴了 PD 控制器的设计思想，形成 PD 学习律，将 PD 学习律和迭代学习算法结合起来，建立符合动态飞行要求的轨迹控制方案。

考虑到飞行轨迹自动控制的对象是小型无人机，为了确保控制方案的顺利实施，针对小型无人机的非线性欠驱动系统进行分析，确定控制过程中涉及的输入变量、输出变量和控制变量<sup>[25]</sup>：

$$\begin{cases} \varphi = [h, h', \theta, \theta', \gamma, \gamma'] \\ \eta = [h, \theta, \gamma] \\ U = [u_1, u_2, u_3] \end{cases} \quad (17)$$

式中， $\varphi \in J^d$  表示飞行轨迹自动控制输入变量集合， $\eta$  表示飞行轨迹自动控制输出变量集合， $U$  表示控制变量集合， $u_1, u_2, u_3$  分别表示 X 方向、Y 方向和 Z 方向轨迹控制输入值， $h, h'$  表示实际飞行高度和期望飞行高度， $\theta, \theta'$  表示实际俯仰角和期望俯仰角， $\gamma, \gamma'$  表示实际滚转角和期望滚转角。

在确定轨迹控制相关变量后，建立图 3 所示的自动控制结构。迭代学习 PD 控制结构是一个复杂而精细的控制架构，其巧妙地融合了 3 个迭代学习控制器以及多

个存储器组件，确保控制信号精确传递与处理的同时，保证控制器具备强大的自动学习与优化能力。其中，X 向与 Y 向的控制器与无人机的姿态角紧密相关，还与控制输入  $u_1$  存在耦合关系，在每个迭代周期内，先对 X 向与 Y 向的 PD 控制器同时展开优化计算，确定当前迭代周期中二者所需的控制参数（俯仰角、滚转角），将 X 向与 Y 向 PD 学习律对控制参数更新后的  $u_2(t+1)$ 、 $u_3(t+1)$  输入到被控的无人机系统中得到用于 Z 向迭代学习控制器的 Z 向误差  $e_3(t)$ ，最终 Z 向 PD 控制器根据误差计算值更新控制输入  $u_1$ ，将得到的  $u_1(t+1)$ 、 $u_2(t+1)$ 、 $u_3(t+1)$  输入无人机系统得到下次迭代周期的误差  $E(t+1)$ ，开始下一次迭代。PD 控制算法以其快速响应和稳定性强的特点，在每次迭代中根据无人机的当前状态与目标轨迹之间的误差，实时计算出控制输入，使无人机能够迅速纠正飞行过程中的偏差。同时，PD 控制算法输出的实时误差信息，为迭代学习算法提供了优化控制参数的基础。迭代学习算法则利用这些反馈信息，通过不断迭代来优化 PD 控制器的比例增益和微分增益等控制参数，使无人机的飞行轨迹逐渐逼近目标轨迹。这种结合机制不仅发挥了 PD 控制算法的实时响应能力，还充分利用了迭代学习算法的长期优化能力，使得控制方案既能够快速响应飞行轨迹误差，又能够在多次迭代后逐渐提高控制的精度和鲁棒性。因此，该过程使得无人机的运动轨迹更加接近目标轨迹，从而全面提升无人机自动控制精度。

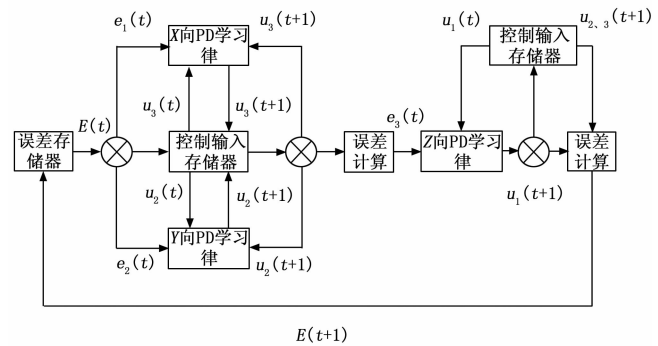


图 3 迭代学习轨迹自动控制框架

图 3 中， $t$  表示迭代学习次数， $E$  表示轨迹误差值， $e_1, e_2, e_3$  分别表示 X 方向、Y 方向和 Z 方向的小型无人机飞行轨迹误差。

图 3 所示的控制框架中，误差参数计算过程可以表示：

$$\begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{bmatrix} = \begin{bmatrix} \gamma'(t) - \gamma(t) \\ \theta'(t) - \theta(t) \\ h'(t) - h(t) \end{bmatrix} \quad (18)$$

将公式 (18) 给出的误差值输入到 3 个控制器中，即可得到迭代学习控制律为：

$$\begin{cases} u_1(t+1) = u_1(t) + [K_1, K_2] \times e_1(t) \\ u_2(t+1) = u_2(t) + [K_1, K_2] \times e_2(t) \\ u_3(t+1) = u_3(t) + [K_1, K_2] \times e_3(t) \end{cases} \quad (19)$$

式中,  $K_1$ 、 $K_2$  表示比例控制参数和微分控制参数。

在迭代学习算法的作用下, 无人机飞行轨迹自动控制框架中的控制参数会不断发生变化, 从而适应动态轨迹控制要求。

PD型迭代学习控制算法的核心是学习律中PD的参数选择, 不合适的参数选择无法保证算法的收敛性, 不同学习参数下算法的收敛速度以及受噪声的影响也大不相同。迭代学习控制算法的学习参数选择多为李雅普诺夫法结合专家经验进行选择。随着迭代次数的增加需要对参数进行更新。因此本文提出一种基于强化学习Q-learning算法的PD学习律参数更新方法。该过程中涉及的主要对象包括: 智能体Agent为无人机控制系统的迭代学习控制器; 环境为无人机系统; 状态空间 $S$ , 其中的每个状态 $s \in S, s = [K_1, K_2]$ ; 动作空间 $A$ , 其中每个动作 $a \in A, a = [\Delta K_1, \Delta K_2]^T$ ;  $R$ 为奖励值。具体过程如下:

选取迭代学习控制器中的两个学习律参数 $K_1$ 、 $K_2$ 作为状态, 在该状态下采取的动作作为 $\Delta K_1$ 、 $\Delta K_2$ , 则对应的状态转移公式为:

$$s' = s + a = [K_1 + \Delta K_1, K_2 + \Delta K_2] \quad (20)$$

动作选择策略 $\pi$ 则采用“ $\epsilon$ -贪心策略”:  $\pi^\epsilon(s) =$

$\begin{cases} \pi(s) \arg \max_a Q(s, a) \\ \text{均匀概率选取 } A \text{ 中任意 } a \end{cases}$ , 对应的动作选择概率为:

$$p_i = \begin{cases} 1 - \epsilon + \epsilon / |A|, a_i = \pi(x) \\ \epsilon / |A|, a_i \neq \pi(x) \end{cases} \quad (21)$$

$\gamma$ 折扣累积奖赏的计算方法如下:

$$\begin{aligned} Q_{k+1}^a(s, a) &= Q_k^a(s, a) + \alpha [R_{s \rightarrow s'}^a + \\ &\quad \gamma Q_k^a(s', a) - Q_k^a(s, a)] \end{aligned} \quad (22)$$

式中,  $\alpha$ 表示学习率, 通常取较小值, 在牺牲收敛速度的情况下保证结果不出现振荡;  $\gamma$ 为折扣因子, 表示下一状态的奖励值对本状态下采取动作 $a$ 的奖励的影响大小;  $R_{s \rightarrow s'}^a$ 表示在状态 $s$ 下采取动作 $a$ 转移到状态 $s'$ 的过程奖励。

在迭代学习控制系统中, 为了优化无人机的轨迹控制性能, 设计了奖励函数来影响模型的学习参数。奖励函数包括精度奖励和稳定时间奖励两部分。精度奖励考虑了不同迭代次数下轨迹误差的收敛情况, 通过权重因子调整奖励值, 以筛选出既能保证迭代收敛又能快速完成的学习参数。稳定时间奖励则根据单次飞行中跟踪误差稳定在0.5 m以内的起始时间变化来给予奖励, 权重因子用于调整奖励值, 如果在当前的学习参数下稳定起始时间能随着迭代逐次降低, 则给予该参数稳定时间奖

励。最终, 将精度奖励和稳定时间奖励相加得到最终的奖励函数 $R_{s \rightarrow s'}^a$ , 用于全面评估和更新优化学习参数, 以满足无人机轨迹控制对精度、收敛性和快速稳定追踪的要求。

上述内容研究了基于迭代学习算法的无人机飞行轨迹控制方法。通过分析小型无人机的非线性欠驱动系统, 确定了控制过程中的输入变量、输出变量和控制变量。在此基础上, 通过引入3个迭代学习控制器和多个存储器组件, 建立了迭代学习PD控制结构, 并详细说明了误差参数计算过程和迭代学习控制律的设计, 确保无人机能够快速响应飞行轨迹误差。为了进一步优化控制性能, 提出了一种基于强化学习Q-learning算法的PD学习律参数更新方法, 使无人机能够自适应调整控制参数。该过程提高了无人机轨迹控制的精度和鲁棒性, 使其能够精准应对动态轨迹控制要求, 从而提升了无人机的飞行性能和安全性。

## 2 实验分析

为了推动小型无人机在工业领域的广泛应用, 针对小型无人机飞行轨迹自动控制问题进行研究, 并设计出基于机器视觉技术的新型控制方法。而在控制方法设计完成后, 需要通过实验分析全面验证该方法的可行性与性能。实验目的主要包括两方面, 其一是验证方法可行性, 通过实际飞行测试, 观察基于机器视觉技术的自动控制方法能否有效引导无人机按照预定轨迹进行飞行。这是实验的基础目标, 也是后续性能评估的前提。其二则是评估控制精度与稳定性, 在无人机飞行过程中, 密切关注控制处理后产生的飞行轨迹与预定轨迹的偏差, 以及飞行过程中的稳定性表现, 由此来评估该方法的控制精度和稳定性。

### 2.1 实验环境搭建

为了保证实验的顺利开展, 选择一处尺寸为2 000 m×2 200 m的广阔区域作为实验场景, 该场景内包含草地、树林和湖面等多种自然元素。草地区域包括不同颜色和密度的草地, 以及可能的地面障碍物(如小土丘、石块等)。这些设计元素旨在模拟无人机在复杂地形中飞行时会遇到的视觉干扰, 从而检验视觉导航算法对地面纹理变化的适应性和鲁棒性。树林区域内的树木形态、大小和分布具有随机性, 用以模拟真实森林中的复杂视觉场景, 这一设计不仅考验了视觉导航算法对树木遮挡的应对能力, 还测试了算法在有限视觉信息下的路径规划和决策能力。而湖面上的波光粼粼和光线反射可能导致图像模糊或特征点难以提取, 从而增加了无人机视觉导航的难度, 将这一区域添加到实验场景中, 有利于评估视觉导航算法在复杂光线条件下的性能表现。

将一台四旋翼无人机作为研究对象, 将其放置到实

验场景中，作为飞行轨迹自动控制的对象，其主要性能参数如表 1 所示。

表 1 小型无人机性能参数

参数名称	取值
无人机质量/kg	1
风阻系数	0.02
X 轴转动惯量/(kg·m <sup>2</sup> )	0.005
Y 轴转动惯量/(kg·m <sup>2</sup> )	0.005
Z 轴转动惯量/(kg·m <sup>2</sup> )	0.011
重力加速度/(m·s <sup>2</sup> )	9.81

在无人机上安装一个相机，以便采集无人机飞行区域图像，为飞行轨迹自动控制提供基础条件。考虑到相机在室外环境中会受到光线等因素的影响出现镜头畸变，在实验准备阶段，需要对相机镜头参数进行标定优化。通过无人机搭载相机，从不同位置对一个标定板进行拍摄，得到图 4 所示的 12 幅图像。




图 4 标定板图片

在 Windows 10 的 64 位系统的计算机上，将标定板图片导入至 MATLAB2016b 软件中，借助标定工具箱捕获图像中角点，如图 5 所示。




图 5 角点提取结果

获取所有标定板图像的角点位置信息后，根据相机参数优化要求对相机内参数进行线性求解，最终确定表 2 所示的参数取值结果。

按照表 2 给出的数值，重新设置双目相机内参数，完成主要实验对象的调整。

将无人机放置于实验场景内的飞行起点上，并在该场景设置 1 个无人机飞行终点和 16 个无人机悬停点。利

表 2 相机参数优化结果

参数名称	优化值
相机横向焦距	10 208.23
相机纵向焦距	10 204.25
镜头光心位置横坐标	644.72
镜头光心位置纵坐标	481.71
畸变系数 1( $k_1$ )	-3.31
畸变系数 2( $k_2$ )	0.21
畸变系数 3( $k_3$ )	-4.51
畸变系数 4( $p_1$ )	0.000 6
畸变系数 5( $p_2$ )	0.063 2

用基于机器视觉技术的新方法、文献 [4] 提出的基于自适应反步滑模的方法、文献 [7] 提出的基于改进滑模观测器的方法，分别在上述环境中对无人机飞行轨迹进行自动控制。通过分析不同方法的控制成果，有助于更好地体现新设计方法的优越控制性能。

### 2.2 建立环境感知地图

研究过程中其创新点主要依托于机器视觉技术对无人机飞行环境进行感知，是应用新方法完成轨迹控制的初始环节。通过无人机上安装的双目相机，在实验区域内采集 9 240 张环境图像，这些图像的大小统一为 320 × 160/pix。通过图像色彩模型转换、滤波处理、特征提取等机器视觉处理环节，最终绘制出图 6 所示的环境感知地图。




图 6 无人机飞行区域环境感知结果

如图 6 所示，通过对飞行区域环境进行感知可以确定，该场景内共存在 9 个可能对小型无人机飞行产生影响的障碍物，包含树木、电力杆塔等。

### 2.3 无人机飞行轨迹规划结果

以环境感知地图为基础，考虑无人机飞行任务要求，应用改进 A\* 算法搜索出一条安全且总体长度较短的路线作为后续无人机飞行轨迹控制的依据，如图 7 所示。

从图 7 可以看出，依靠改进 A\* 算法规划处理的飞行路线实现了起点与终点的连接，同时途径了所有悬停点，满足了小型无人机飞行工作要求。此外，该飞行路




图 7 飞行轨迹规划结果

线完美避开了场景内的各种障碍物, 保证了飞行轨迹的安全性。

### 2.4 飞行轨迹自动控制结果

已知小型无人机飞行轨迹规划路线后, 利用迭代学习 PD 控制框架, 可以对无人机飞行轨迹进行有效控制。其中, 控制量初始值如表 3 所示。

表 3 迭代学习轨迹自动控制框架中控制量初始值

变量	初始值
X 方向控制输入量	1 000
Y 方向控制输入量	0
Z 方向控制输入量	0

将表 3 所示的初始控制参数输入迭代学习 PD 控制框架中, 并输入无人机实时飞行轨迹误差, 借助迭代学习算法的自动学习能力, 动态整定比例控制参数和微分控制参数, 保证不同时刻无人机飞行轨迹控制结果满足规划要求。

在小型无人机飞行轨迹自动控制结束后, 观察无人机飞行位置响应结果, 最终可以绘制出图 8 所示的统计图。

从图 8 给出的位置响应结果可以看出, 基于机器视觉技术的自动控制方法应用后, 保证了无人机飞行轨迹在不同方向上的位置变化与期望轨迹一致, 这证明了这一方法的轨迹控制能力可以满足实际要求。

### 2.5 控制性能对比分析

运用新设计控制方法和两种选定的实验对照组方法, 分别完成小型无人机飞行轨迹自动控制后, 为了对比各方法控制性能, 需要对控制轨迹进一步分析。以 16 个悬停点作为测试点, 观察不同方法控制轨迹在选定点上的位置坐标, 以及实验开始时给定的期望坐标, 将二者代入公式 (23), 即可推算出轨迹控制结果的总体位置误差:

$$\psi = \sqrt{(x' - x'')^2 + (y' - y'')^2 + (z' - z'')^2} \quad (23)$$

式中,  $\psi$  表示总体位置误差,  $(x', y', z')$  表示悬停点期望坐标,  $(x'', y'', z'')$  表示飞行轨迹自动控制后无人机悬停




图 8 无人机飞行轨迹自动控制后位置响应结果

点坐标。

针对 16 个悬停点, 分别完成轨迹控制结果体位置误差计算, 即可绘制出图 9 所示的对比图像。




图 9 不同方法轨迹控制结果位置误差对比

由图 9 给出的对比结果可以看出, 基于机器视觉技术的新方法完成飞行轨迹自动控制后, 所有悬停点上无人机飞行轨迹位置误差都小于 0.5 m, 这表明新方法的应用极大提升了无人机轨迹控制精度。相对来说, 另外两种方法轨迹控制结果所表现出的位置误差, 平均值分别为 1.15 m 和 1.48 m。根据上述实验结果, 对无人机飞行轨迹自动控制的误差来源进行了分析: 误差来源主要包括相机测量误差、算法计算误差以及环境干扰误差, 这些误差对无人机飞行轨迹控制精度产生显著影响。相机测量误差源于图像传感器的分辨率、噪声、镜头畸变及光照条件, 影响地形和障碍物的识别精度, 进而干扰三维环境感知地图的准确性。算法计算误差则与算法精度限制、计算过程中的舍入误差及数据处理近似处理有关, 导致飞行轨迹规划与控制算法准确性下降。

环境干扰误差则主要由风力、气流、电磁干扰等外部因素引起，干扰无人机飞行状态，使实际飞行轨迹偏离规划轨迹。而为应对这些误差，所提方法通过采用 HSV 色彩模型提升图像质量，应用域分解力方法和曲率滤波算法减少噪声，引入置换矩阵简化目标函数处理，采用改进 A\* 算法提高飞行轨迹规划精确度，并在迭代学习控制中引入强化学习 Q-learning 算法优化 PD 学习律参数，从而有效降低了误差对无人机飞行的影响，提高了轨迹控制的精度和鲁棒性。

为了进一步验证基于机器视觉技术的小型无人机飞行轨迹自动控制方法的有效性，采用平均曲率作为评价指标，验证不同方法控制轨迹的平滑度，平均曲率值越小，表明轨迹越平滑，平均曲率公式为：

$$K = \frac{1}{L} \int_0^L k(s) ds \quad (24)$$

式中， $L$  表示轨迹曲线总弧长， $k(s)$  表示弧长位置  $s$  处的曲率。 $k(s)$  的公式为：

$$k(s) = \frac{\|r'(s) \times r''(s)\|}{\|r'(s)\|^3} \quad (25)$$

式中， $r'(s)$  表示一阶导数， $r''(s)$  表示二阶导数， $\times$  表示叉积运算， $\|\cdot\|$  表示向量模长。

共进行 33 次实验，统计不同方法控制下轨迹的平均曲率，结果如图 10 所示。




图 10 不同方法控制下轨迹的平均曲率结果

由图 10 可知，基于机器视觉技术的新方法完成飞行轨迹自动控制后，轨迹的平均曲率更低，而对比方法的轨迹的平均曲率均高于新方法，说明新方法的轨迹平滑度更高，飞行轨迹控制效果好，稳定性更高。

为验证基于机器视觉技术的小型无人机飞行轨迹自动控制方法中改进 A\* 算法的有效性，将其与未改进 A\* 算法在不同环境下的应用效果进行对比实验，并以路径规划耗时、路径规划长度作为评价指标。A\* 算法改进前后的对比结果如表 4 所示。

由表 4 可知，应用改进后的 A\* 算法在不同环境下的路径规划耗时和路径规划长度始终低于未改进 A\* 算法，说明改进 A\* 算法能够更快规划路径，且路径最短，应用效果好。

综合来看，在飞行轨迹自动控制领域引入机器视觉

表 4 A\* 算法改进前后的对比结果

算法	障碍物个数			
	少量		多数	
	路径规划 耗时/s	路径规划 长度/m	路径规划 耗时/s	路径规划 长度/m
改进 A* 算法	3.1	55	10.5	67
未改进 A* 算法	5.5	89	15.4	105

技术，实现了小型无人机飞行品质的有效提升，可以在以工业领域为代表的多个领域能够发挥更大作用。

### 3 结束语

依托于机器视觉技术设计的小型无人机飞行轨迹自动控制方法，通过集成先进的环境感知模块与智能控制算法，实现了无人机在复杂环境中的自动轨迹控制。利用机器视觉技术对无人机飞行区域周围环境进行高精度感知，显著增强了无人机的环境适应能力与障碍物识别精度。在此基础上，引入改进 A\* 算法进行轨迹规划，通过优化搜索策略与启发式函数，有效缩短了路径规划时间，同时确保了飞行轨迹的最优性与安全性。引入强化迭代学习 PID 控制策略，能够不断迭代学习飞行数据，优化控制参数，实现了对无人机的稳定控制，显著提升了飞行品质与任务执行效率。综上所述，通过研究提出的新型自动控制方法，为小型无人机在复杂环境中的安全飞行提供了有效的解决方案，为推动无人机技术的智能化发展作出了积极贡献。

#### 参考文献：

- [1] 刘金华, 王 远, 张智轩, 等. 基于 RBF 网络的四旋翼无人机姿态鲁棒自适应反步滑模控制 [J]. 江苏大学学报 (自然科学版), 2025, 46 (1): 36-42.
- [2] 鲁瀚辰, 郝明瑞, 申庆茂, 等. 固定翼无人飞行器在线避障安全轨迹规划方法 [J]. 战术导弹技术, 2024, (6): 87-93.
- [3] 商 阳, 苏婧婷, 魏 帅, 等. 一种改进的主从式无人机协同导航算法 [J]. 南京航空航天大学学报, 2024, 56 (6): 1097-1103.
- [4] 杨 昆, 朱亚洲, 王振宇, 等. 基于自适应反步滑模的 AUV 轨迹控制 [J]. 舰船科学技术, 2024, 46 (22): 89-93.
- [5] 陈丰毅, 解明扬, 张 民, 等. 基于自适应神经网络的四旋翼无人机轨迹跟踪控制 [J]. 控制工程, 2023, 30 (7): 1267-1275.
- [6] 刘旭光, 杜昌平, 郑 耀. 基于强化迭代学习的四旋翼无人机轨迹控制 [J]. 计算机应用, 2022, 42 (12): 3950-3956.
- [7] 杨 洋, 苏 伟. 基于改进滑模观测器的四旋翼无人机轨迹控制 [J]. 电光与控制, 2024, 31 (7): 20-26.

(下转第 129 页)