

DOI: 10.19650/j.cnki.cjsi.J2514676

基于边角区域引导的无人平台分层主动路径规划方法*

陶贤露^{1,2}, 刘佳璇^{1,2}, 王焯轩^{1,2}, 潘树国^{1,2}, 徐锦乐^{1,2}

(1. 东南大学仪器科学与工程学院 南京 210096; 2. 东南大学综合时空网络与装备技术全国重点实验室 南京 2110096)

摘要: 高效的 路径规划与决策能力是无人平台在未知环境中实现自主探索的关键。但受感知误差与计算资源限制, 现有探索方法在复杂结构场景中易出现覆盖不完整和探索效率低下, 尤其在边角或遮挡区域, 常引发路径冗余与感知盲区。其原因在于多数规划器仅关注局部信息增益或最短路径, 未充分利用环境结构特征, 导致高代价回溯与重复探索。故提出一种基于边角区域引导的无人平台分层主动路径规划方法。通过构建“前端路径生成—后端轨迹优化”的分层架构, 以实现高效、连续的全局探索。前端引入快速环境信息预处理机制, 并结合视点自适应推离与小扰动优化策略, 实现边角区域的均衡覆盖与视点分布优化; 后端基于融合边角约束的多因素代价模型, 结合路径序列优化、B 样条平滑与末端修正机制, 生成连续且安全的可执行轨迹。实验表明, 所提方法在典型边角复杂环境中相较于两种先进算法, 在平均探索时间上分别减少 14.7%~18.2%, 路径长度缩短 17.4%~39.7%。同时, 所提方法在保证平均覆盖率超过 96.6% 的前提下, 实现了对探索时间与路径质量的有效平衡, 显著提升了整体探索效率与路径规划质量。与学习算法对比, 验证了其在复杂结构场景下的稳定性与适应能力。此外, 通过真实室内场景的实车实验, 进一步验证了算法的可行性与适应性。

关键词: 无人平台; 自主探索; 序列优化; 路径规划; 轨迹优化

中图分类号: TH242 TP18 文献标识码: A 国家标准学科分类代码: 510.80

Hierarchical active path-planning based on the edge-and-corner region guidance for the unmanned platform

Tao Xianlu^{1,2}, Liu Jiaxuan^{1,2}, Wang Zhuoxuan^{1,2}, Pan Shuguo^{1,2}, Xu Jinle^{1,2}

(1. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China;

2. State Key Laboratory of Comprehensive PNT Network and Equipment Technology, Southeast University, Nanjing 210096, China)

Abstract: Efficient path planning and decision-making are essential for the unmanned platforms to achieve the autonomous exploration in unknown environments. However, due to the limitations in perception accuracy and computational resources, the current exploration methods often suffer from the low efficiency and incomplete coverage in the structurally complex scenarios. In particular, the redundant paths and sensing blind zones frequently occur in cornered or occluded regions. This is mainly because most planners focus only on the local information gain or the shortest path, which fail to fully exploit environmental structural features and results in the high-cost backtracking and repeated exploration. To address these challenges, this study proposes a hierarchical active path-planning method based on the edge-and-corner regions for unmanned platforms. The proposed framework adopts a two-layer structure consisting of front-end path generation and back-end trajectory optimization to achieve the efficient and continuous global exploration. In the front-end stage, a fast environmental information preprocessing mechanism is introduced by combining with an adaptive viewpoint push-away and small disturbance optimization strategy to ensure the balanced coverage and uniform viewpoint distribution in corner regions. In the back-end stage, a multi-factor cost model with corner constraints integrated with path sequence optimization, B-spline smoothing, and terminal correction is designed to generate the continuous, safe, and executable trajectories. Experimental results demonstrate that, the proposed method reduces the average exploration time by 14.7%~18.2% and shortens the path length by 17.4%~39.7% compared with the two advanced algorithms in the typical corner-rich environments. Meanwhile, it maintains an average coverage rate over 96.6% by effectively

收稿日期: 2025-11-14 Received Date: 2025-11-14

* 基金项目: 江苏省基础研究计划 (BK20251745)、国家自然科学基金 (42404023) 项目资助

balancing the exploration efficiency and path optimization performance, thereby significantly improving the overall exploration quality and planning effectiveness. The comparison with the learning-based method further verifies its stability and adaptability in the structurally complex scenarios. Furthermore, the real-world indoor experiments validate the feasibility and adaptability of proposed algorithm, confirming its potential for the practical deployment in the complex exploration tasks.

Keywords: unmanned platform; autonomous exploration; sequence optimization; path planning; trajectory optimization

0 引言

近些年来,随着传感器、大数据及人工智能等技术的不断发展,无人平台在灾害搜救^[1]、环境监测^[2]、安防巡检^[3]、智能仓储^[4]等领域展现出广阔的应用前景。其中,轮式移动机器人、多旋翼无人机等作为无人平台的常见形式,依靠多种高效、灵活的自适应路径规划算法,在复杂或高风险等极端环境中体现出了巨大的应用价值^[5-8]。

自主探索未知场景作为无人平台达成智能化的核心之一。在过去几十年,许多学者提出了各式探索策略和算法,持续推动相关研究的发展。但鉴于未知环境的特殊性,如何实现完整且高效的探索仍是亟待解决的问题。首先,现有探索方法往往需要在全局范围反复识别前沿区域、采样候选视点并进行路径规划,随着环境规模的增大,计算开销剧增,导致规划模块响应时间显著上升,难以满足实时性要求,影响整体探索效率。其次,在未知环境探索中,边角区域通常由墙体或障碍物边界的转折、内凹及狭窄连通结构所形成,典型位置包括房间入口、走廊尽头及障碍物凹角等。该类区域通常伴随遮挡与局部自由空间受限的特性,对应候选视点稀疏且单视点增益低。而多数规划器在目标选择与路径生成过程中主要依赖贪婪策略,以局部信息增益最大化或最短路径为导向,往往容易造成该部分区域的覆盖遗漏,进而产生高代价的往返运动与重复探索,显著降低探索的整体效率。

受此启发,本文提出了一种基于边角区域引导的无人平台分层主动路径规划方法,在视点生成与全局路径规划中显式引入边角区域引导机制,以提升对该类区域的探索优先级并改善探索效率。系统整体采用“前端路径生成—后端轨迹优化”的分层结构。在前端阶段,引入快速环境信息预处理机制,实现前沿、候选视点及信息增益的高效提取;并通过自适应推离与扰动优化策略,使视点在边角区域分布更加均衡,以引导无人平台在路径规划阶段优先覆盖探索盲区,从而提升感知覆盖能力。结合稀疏路线图与动态切换机制,有效提升路径搜索效率。在后端阶段,本文进一步提出融合边角约束的小区域代价模型,引导无人平台在路径优化过程中优先探索边角区域,减少因遗漏导致的高代价回溯;并结合多因素路径序列优化,实现访问顺序的全局优化。同时,为了确保路径的连续性与可行性,对粗略路径进行B样条的轨迹平

滑与局部修正。本文的主要贡献包括:1)提出了一种基于边角引导的视点距离自适应调整机制,对视点位置进行动态调整,以引导无人平台在路径规划阶段优先覆盖边角等可视性受限的探索盲区;2)提出了一种融合边角约束的多因素代价函数设计,通过提升位于边角等盲区对视点的探索优先级,以提升路径序列的全局合理性与规划效率;3)通过开展丰富的仿真与真实世界下的实验,并与先进方法进行系统对比,验证了所提方法在理论及实际层面的有效性和可行性。

1 相关工作

无人平台在未知环境中进行路径探索与建图一直是自主导航研究的重要课题之一。经过多年的发展,研究者提出了多种自主探索策略以提升机器人在复杂环境中的感知与规划能力。目前,主流的探索方法主要可分为两类:基于前沿检测^[9-11](Frontier-based)与基于采样^[12-16](Sampling-based)的主动探索策略。近年来,随着深度与强化学习的发展,基于学习的探索方法也逐渐成为研究热点,为自主探索问题提供了新的解决思路^[17-21]。

基于前沿的探索方法最早由Yamauchi^[9]提出,其核心思想是识别已知与未知空间的边界作为前沿,并贪婪地将最近的前沿作为下一目标进行导航。该方法实现简洁、计算开销较低,能够在中小规模场景中获得良好的探索性能。然而,由于缺乏对环境结构特征的识别,该类方法容易陷入局部最优,致使路径重复且效率降低。基于此,后续研究对边界点筛选策略做了优化。例如,Zhou等^[10]提出了一种基于无人机的快速自主探索方法,通过构建增量式边界信息结构并引入分层规划框架,实现了无人机探索性能的显著提升。该方法能够动态更新并聚类前沿点,避免频繁的重计算,从而降低计算负担;同时在全局层面确定目标区域,并在局部路径规划中选择最优视点组合,有效提升了覆盖效率。尽管Frontier-based方法历经了多次改进,在路径效率以及计算开销上均取得了一定进展,但其依旧主要依赖前沿几何分布进行目标选取,缺乏对环境结构和空间拓扑特性的综合考虑^[22-24]。这种以局部信息为导向的贪婪策略易导致探索短视和路径反复,难以兼顾全局规划效率。尤其在结构复杂的场景中,该类方法往往难以有效覆盖边界等可视性受限的区域,导致出现探索盲区与回溯,从而限制了系

统在大规模未知环境中的探索效率与覆盖完整性。此外,在大规模场景下,频繁提取前沿与计算信息增益会显著增加计算开销,降低规划的实时性。

基于采样的探索方法则是通过在自由空间中随机或启发式地采样潜在视点,并综合考虑信息增益、可达性与路径代价等因素,以选取最优目标点。典型代表为 Next-Best-View 方法^[13],其基于快速随机探索树结构(rapidly-exploring random tree, RRT)扩展搜索空间,通过在树的分支上选择信息收益最大的节点,引导机器人实现连续探索。该方法具有较好的全局搜索能力与灵活性,但由于需要频繁计算大量采样视点的增益和路径代价,计算负担较重;同时,缺乏对环境结构的建模与全局拓扑感知,容易陷入局部最优,造成探索滞后与路径冗余。许多方法基于此做出了改进。例如, Qiao 等^[14]通过调整树结构扩展规则与节点存储机制,并引入地图分块策略,有效减少冗余节点、降低内存占用;在此基础上,进一步提出采样驱动的多树融合边界检测算法,提高了边界检测的效率与稳定性^[15]。Dang 等^[16]提出了一种结合全局与局部规划的图优化探索框架,局部阶段利用快速随机图生成次优路径,全局规划则保证机器人能高效返回未探索区域,在隧道等狭窄环境中展现出较高路径效率,但频繁的全局重定位可能增加总体探索时间。然而,由于 RRT 算法的随机性,采样不均时,易在狭窄通道或者地形复杂区域遗漏关键空间信息,从而对整体覆盖效果产生影响。随着探索空间的扩大,采样节点数量增加,大量节点信息增益的评估进一步加重了计算负担,对系统的实时响应能力构成挑战。

基于学习的探索方法通常以局部地图及传感器观测为输入,通过学习得到的表征模型或策略网络完成目标点选择与动作决策,从而从大规模数据中提取环境结构与决策规律,在一定程度上缓解传统方法的探索短视问题。现有学习方法通常采用生成式模型^[18]、模仿学习^[21]或图神经网络^[25]等技术实现探索决策。其中,深度强化学习因其能够显式优化长期收益而被广泛采用。例如, Cao 等^[19]提出了一种基于强化学习的探索方法(a reinforcement learning approach using attention-based deep networks for exploration, ARiADNE)将注意力机制与拓扑图表示结合,在图结构上进行目标选择,从而在一定程度上缓解局部贪婪造成的重复往返,并在室内探索中展现出良好的决策能力。虽然学习方法通常不需要人工设计增益函数,有着一定的自适应性,但依赖高成本的训练以及大量的数据,且对不同场景结构敏感,泛化能力受限。

针对上述问题,本文提出一种基于边角区域引导的分层主动路径规划方法,系统框架如图 1 所示。

该方法采用“前端路径生成—后端轨迹优化”的分层结构:前端模块基于激光 SLAM (simultaneous

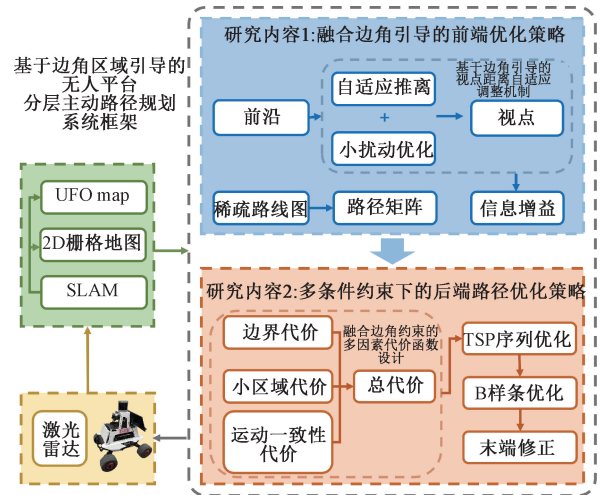


图 1 所提系统框架

Fig. 1 Proposed system framework overview

localization and mapping) 构建三维栅格地图,并通过通行性分析生成二维地形图。在此基础上,系统结合前沿检测与边角识别机制提取潜在高信息增益的候选视点,并依据信息增益评估进行优先级筛选,保留代表性目标用于后续规划。随后,系统运用增量方式构建稀疏路线图,并结合局部路径搜索方法,生成高效的路径连接矩阵。后端模块通过 TSP (travelling salesman problem) 优化算法确定最优访问顺序,生成可行路径,并结合 B 样条曲线平滑与末端修正机制生成连续、平滑且覆盖完整的最终轨迹。

2 基于边角区域引导的分层高效探索方法

2.1 融合边角引导的前端优化策略

针对传统方法在边角覆盖不足的问题,本文提出一种基于边角引导的视点提取与自适应调整机制,以提高对边角区域的感知覆盖能力。同时,为应对大规模场景下计算开销大的挑战,引入快速预处理与增量更新机制,实现环境信息的高频获取,从而在保证探索精度的同时提高系统效率。

1) 基于边角引导的视点距离自适应调整机制

在室内探索任务中,由前文所述的边角区域特性可知,其对应可行观测视点稀疏且信息增益较低。若直接采用最近前沿点作为视点,容易导致对边角后方未知空间的观测不足,进而产生高代回溯路径。针对上述问题,本文在视点生成阶段提出一种结合边角引导与距离自适应的视点优化机制,对基于前沿检测获得的初始视点进行动态调整与筛选,引导无人平台在路径规划阶段更倾向于优先覆盖探索盲区,尤其是在边角区域中实现更均

匀的视点分布。具体地,系统首先依据当前机器人位置 v_0 与前沿中心点 $p_{a,k}$ 间的欧式距离 $d_{a,k}$ 大小,将其划分为 3 种策略区间,即:

$$f(d_{a,k}) = \begin{cases} \pi_1, & d_{a,k} < d_{thr}; d_{a,k} > d_{far} \\ \pi_2, & d_{thr} \leq d_{a,k} \leq d_{far} \end{cases} \quad (1)$$

式中: π_1 为最近点策略, π_2 为视点自适应推离与小扰动优化分布策略; d_{thr} 为中等距离区间的范围下限,而其对应上界记为 d_{far} 。二者之间关系可表示为 $d_{far} = d_{thr} + \gamma$,其中差值 γ 可根据平台任务需求进行灵活调整。

对距离过近或过远的 $p_{a,k}$,即 $d_{a,k} < d_{thr}$ 或 $d_{a,k} > d_{thr} + \gamma$ 时,系统仍采用传统最近点策略,以保证路径的可行性,并尽可能减少探索路径的行进成本。而对处于中等距离区间 $[d_{thr}, d_{thr} + \gamma]$ 的 $p_{a,k}$,若直接采用最近点作为视点,易导致无人平台在探索过程中反复往返,降低路径规划的全局最优性。为此,本文引入自适应推离与小扰动优化策略,通过动态调整视点的空间位置与朝向,强化其对盲区区域的可视覆盖能力,如图 2 所示。




图 2 视点自适应推离与小扰动优化分布

Fig. 2 Viewpoint-adaptive push-away and small disturbance optimization distribution

其中虚线表示 $p_{a,k}$ 指向 v_0 的方向向量;箭头表示角度扰动方向;实线表示视点与其可见前沿之间的连接; $d_{a,k}$ 表示 $p_{a,k}$ 与 v_0 间的欧式距离。系统首先计算前沿中心点 $p_{a,k}$ 相对无人平台当前位置 v_0 的单位方向向量 d_k ,并在该方向上适当推离视点,使其处于更优的探索范围内。推离后的视点位置 v_{mid}^{pos} 计算为:

$$v_{mid}^{pos} = v_0^{pos} + \eta \cdot d_{a,k} \cdot d_k \quad (2)$$

式中: v_0^{pos} 为无人平台当前位置坐标; η 为自适应推离因子,根据 $d_{a,k}$ 的值自适应调节推离幅度。

此外,为进一步提升其对边角或遮挡区域的可视能力与空间分布均衡性,系统引入了小角度偏移扰动策略:首先计算 d_k 对应的单位垂直法向量,并在其两侧进行通行性检测,确保扰动后仍具备路径可达性。当两侧均可通行时,系统随机选择一侧进行小幅扰动,使视点朝向略有偏移,以扩大感知范围,防止因目标聚集导致视野重叠或路径冗余。该策略在提升视点空间多样性的同时,增强了系统对边角区域的适应能力,为后续路径生成提供更加稳定、可靠的输入。

2) 基于高效搜索的环境信息预处理

为提升规划模块的实时性,本文引入了高效的环境信息预处理策略,具体策略为:

(1) 基于前沿单元的信息增益评估方法

传统的信息增益计算方法通常依赖于统计视点可见范围内未知体素的体积,并结合位置相关的体素数量指标来衡量视点的信息增益。然而,基于体素体积的信息增益计算会占据路径规划器运行时间的 95%^[26],从而在大规模场景中显著限制自主探索任务的实时性与系统响应效率。为此,受一种面向大规模环境的快速自主探索算法 (fast autonomous exploration for large-scale, FAEL)^[27] 优化思路的启发,本文设计了一种更加轻量化的信息增益评估策略。该策略以可见范围内的前沿单元数作为衡量标准,在保证评估精度的同时显著提升了计算效率。具体计算公式为:

$$G(v) = \sum_{i \in F(v)} S(i) \quad (3)$$

式中: $G(v)$ 为视点 v 的信息增益值; $F(v)$ 为表示视点 v 可见范围内的前沿单元集合; $S(i)$ 为前沿单元 i 的信息贡献量。

(2) 基于高效路径搜索的稀疏路线图构建方法

在后端的序列优化阶段,系统需频繁评估无人平台与各候选视点之间及视点相互之间的路径距离。针对大规模环境中图搜索与采样计算开销大的问题,本文构建了一种稀疏路线图结构,如图 3 所示。

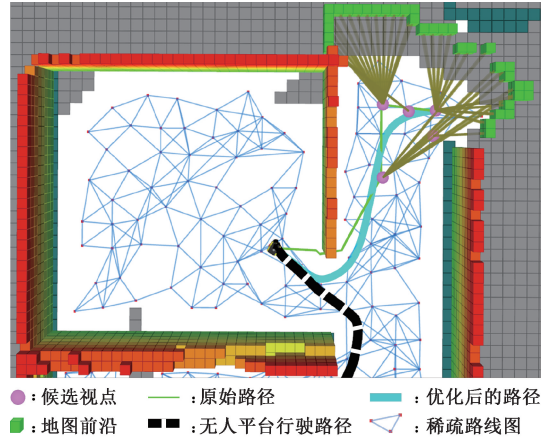


图 3 基于高效路径搜索的稀疏路线图构建

Fig. 3 The sparse roadmap with efficient path search

其中,离散圆点表示视点,与其相邻方块单元表示前沿;分段线性曲线表示原始路径;光滑粗实线表示优化后的路径;虚线表示无人平台行驶路径;拓扑网状结构表示稀疏路线图。将环境空间抽象为具备拓扑关系的无向图,使得原始大规模搜索问题转化为在稀疏图上开展的快速查询问题,从而显著降低路径计算与序列排序的时间开销。

具体流程为:系统首先在已知环境空间范围内,以无人平台当前位置为中心,在局部滑动窗口内均匀采样生成候选节点集,并剔除与已有节点距离小于阈值 ξ 的样本,以保证节点分布的代表性和稀疏性。随后,利用KD树(K-dimensional tree)结构进行快速邻域检索,在半径 r 内依据连通条件和障碍检测结果,筛选距离较近的最多 n 个节点建立双向边,形成拓扑关系清晰的稀疏路线图。其随环境地图的增量更新与探索视点的变化而动更新图结构并建立局部连边,以确保路径规划始终基于最新状态高效运行。

(3) 基于目标距离的前端路径矩阵生成方法:在完成稀疏路线图构建后,系统进一步计算无人平台与各视点之间及视点两两之间的可行路径距离,生成路径矩阵,为目标序列优化提供输入。为兼顾大规模场景下的实时性与路径精度,系统采用局部搜索与全局规划相结合的动态路径生成机制:在局部范围内利用滑动窗口地图执行 A^* 搜索以快速获得精确路径;而在视点分布稀疏或跨越区域较大的情形下,切换至基于稀疏路线图的全局路径搜索,在图结构中执行 A^* 算法以粗略求解最短路径,显著降低计算开销。

2.2 多条件约束下的后端路径优化策略

为在保证路径可行性的同时提升任务覆盖效率,本文设计了多条件约束下的后端路径优化框架。该框架以融合边角约束的多因素代价函数为核心,通过TSP启发式优化生成最优路径序列,并结合B样条平滑与末端修正机制进一步优化路径,实现路径在全局覆盖性与局部可行性间的协同平衡。

1) 融合边角约束的多因素代价函数设计

为进一步改善边角小区域的探索遗漏问题,本文在全局路径规划阶段引入一种面向边角区域的小区域优先代价设计方法,将前沿的空间特征纳入代价建模,并结合运动一致性约束,以提升边角区域对应视点的探索优先级。构建多因素综合代价函数为:

$$C(v_0, v_k) = w_l \cdot L(v_0, v_k) \cdot C_c(v_k) + w_b \cdot C_b(v_k) - w_s \cdot C_s(v_k) \quad (4)$$

式中: $L(v_0, v_k)$ 是 v_0 到 v_k 的累计运动距离; $C_c(v_k)$ 为运动一致性成本,衡量从 v_0 到 v_k 运动方向变化的代价;而 $C_b(v_k)$ 、 $C_s(v_k)$ 为边角小区域优先探索代价; w_l 、 w_b 、 w_s 为对应的权重系数。

(1) 基于边角小区域优先的代价函数设计

受FAEP(fast autonomous exploration planner)^[28]算法启发,本文在探索顺序优化过程中提出一种面向边角区域的小区域优先代价设计方法,通过提高位于边角或狭窄区域附近前沿点对应视点优先级,降低边角区域的遗漏与重复折返风险,从而优化路径结构,提升任务执行的连贯性与整体探索效率。

边界代价函数 $C_b(v_k)$ 旨在引导无人平台在未知场景中优先覆盖环境边缘区域。考虑到实际探索过程中边界形态复杂且动态变化,本文引入滑动窗口机制对边界代价进行动态调整,如图4所示。

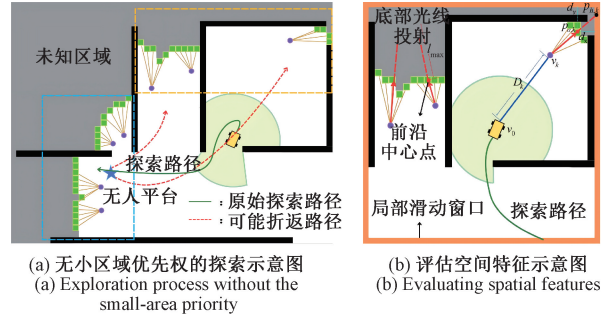


图4 小区域优先代价函数设计示意图

Fig. 4 Design of small-region priority cost function

如图4(a)所示,下方虚线方框表示当前规划的下一个探索前沿区域,上方虚线方框则表示了可能导致来回折返的边角区域。滑动窗口以无人平台当前位置为中心,并随平台运动实时更新,使系统能够根据局部边界信息自适应地调整路径选择。代价函数计算为:

$$d_{\min}(v_k) = \min(d_x(v_k), d_y(v_k)) \quad (5)$$

$$C_b(v_k) = d_{\min}(v_k) - \lambda_k \cdot (R - d_{\max}) \quad (6)$$

式中: $d_x(v_k)$ 、 $d_y(v_k)$ 分别为目标视点 v_k 对应的前沿中心点 $p_{a,k}$ 到当前滑动窗口 W 的 x 、 y 轴的边界之间的最小距离; λ_k 为距离调节系数; R 为窗口半径。当视点靠近窗口边界时,代价逐渐降低以提升该区域的探索优先级。该方法可有效减少边界视点遗漏,提高无人平台在边角区域的覆盖效率。

小区域代价函数 $C_s(v_k)$ 基于底部光线投射(如图4(b)中的虚线)对环境进行局部分析,通过评估视点与前沿区域之间的空间范围与障碍分布,动态评估其探索优先级:系统首先在局部范围内筛选与无人平台当前位置 v_0 距离小于距离阈值 D_{thr} 的候选视点 v_k ,并计算其指向对应前沿中心点的 $p_{a,k}$ 的单位方向向量 \mathbf{d}_k 。随后以 $p_{a,k}$ 为起始点沿 \mathbf{d}_k 向未知区域进行光线投射,逐步检测投影路径上各采样点的占据状态,获得到最近障碍物或边界的首次碰撞距离 l_k 。若 l_k 较短,则表明该区域受限为狭小区域,系统将提升对应视点的探索优先级;反之,则降低其权重以避免冗余搜索。通过上述评估,系统可自适应调整小区域代价 $C_s(v_k)$,在保证无人平台及时覆盖易遗漏区域的同时,减少后续重复探索,从而提高整体探索效率与路径规划的均衡性。

(2) 运动一致性成本 C_c

为约束相邻路段之间的方向变化并保持路径连续性,在代价模型中引入运动一致性成本项 C_c ,其定义为:

$$L(v_0, v_k) = D(v_0, v_1) + D(v_1, v_2) + \dots + D(v_{k-1}, v_k) \quad (7)$$

$$C_c(v_k) = (1 - \alpha) \cdot \log_2\left(\frac{\theta}{\pi} + 1\right) + \alpha, \quad \alpha \in (0, 1] \quad (8)$$

$$\theta = \arccos \frac{(\mathbf{v}_k^{pos} - \mathbf{v}_0^{pos}) \cdot \mathbf{v}_0}{\|(\mathbf{v}_k^{pos} - \mathbf{v}_0^{pos})\| \cdot \|\mathbf{v}_0\|} \quad (9)$$

式中: \mathbf{v}_0^{pos} 为无人平台当前位置; \mathbf{v}_k^{pos} 为第 k 个目标视点; \mathbf{v}_0 为当前无人平台的前进速度。方向偏差越大, 代价越高, 从而引导系统选择与当前运动趋势一致的路径, 减少频繁折返与方向突变, 提升路径规划的整体平滑性与执行稳定性。

2) 基于 B 样条参数路径优化

在完成路径序列优化后, 为消除离散节点连接带来的曲率突变与运动不连续问题, 本文采用基于 B 样条的多目标路径平滑优化方法, 通过引入避障、平滑与航向约束, 实现无人平台运动轨迹的连续化与可执行性优化。

将前端路径节点挑选出来作为 B 样条的控制点, 其表示为 $\mathbf{P}_{c,i}(x_i, y_i, z_i)$ 。构建综合代价函数为:

$$\min J = \lambda_c \cdot J_c + \lambda_s \cdot J_s + \lambda_y \cdot J_y \quad (10)$$

式中: J_c 、 J_s 、 J_y 分别表示碰撞、轨迹平滑和航向角平滑代价函数; λ_c 、 λ_s 、 λ_y 分别为各惩罚项对应的权重系数。

避障代价用于约束路径远离障碍物, 即:

$$J_c = \sum_{i=1}^N \lambda_c \cdot (d_{safe} - d_i)^2 \quad (11)$$

式中: d_i 表示 $\mathbf{P}_{c,i}$ 到障碍物边界的最小距离; d_{safe} 为设定的安全距离阈值。当控制点 $\mathbf{P}_{c,i}$ 与障碍物间距离 d_i 小于安全阈值 d_{safe} 时, 系统通过惩罚项增加代价以实现避障调整。

曲率平滑代价采用基于控制点的二阶差分形式进行构建, 保证平滑性的同时避免因过度灵敏而引发的抖动现象, 即:

$$J_s = \sum_{i=1}^{N-1} \|\mathbf{a}_i\|^2 \quad (12)$$

其中, \mathbf{a}_i 为第 i 个控制点的二阶差分向量, 即:

$$\mathbf{a}_i = \frac{\mathbf{P}_{c,i+1} - 2\mathbf{P}_{c,i} + \mathbf{P}_{c,i-1}}{\Delta s^2} \quad (13)$$

式中: Δs 表示控制点之间的平均距离。

航向连续性代价用于抑制速度方向突变, 保证路径方向一致性, 即:

$$J_y = \sum_{i=1}^{N-1} \|\Delta \mathbf{v}_{c,i}\|^2 = \|\mathbf{v}_{c,i} - \mathbf{v}_{c,i-1}\|^2 \quad (14)$$

式中: $\Delta \mathbf{v}_{c,i}$ 为相邻速度方向之间的差值向量; $\mathbf{v}_{c,i}$ 为第 i 个控制点处的速度方向向量。

综合优化后, 控制点在梯度方向上进行迭代更新, 逐

步获得平滑、连续且满足约束条件的最终路径, 在保证路径可行性的同时, 有效提升无人平台的运动稳定性与效率。

3) 末端路径修正机制

尽管经 B 样条优化后的路径具备良好的平滑性及避障能力, 但在复杂环境中仍可能在路径末端局部区域出现轻微碰撞或贴近障碍边界的情况。为提高路径的安全性与可行性, 设计了一种自适应推离的局部修正策略, 针对优化结果展开二次碰撞检测及动态调整。

如图 5 所示, 系统对平滑路径进行离散采样, 并逐段检测是否存在与障碍物的交叉, 在检测到碰撞或过近时, 沿路径法向方向执行推离调整。




图 5 碰撞检测推离示意图

Fig. 5 Collision detection-driven repulsive motion

推离强度根据距离自适应调节, 其计算公式为:

$$F_{push} = F_{min} + (F_{max} - F_{min}) \cdot (1 - e^{-\beta \cdot d}) \quad (15)$$

式中: F_{min} 、 F_{max} 分别为最小与最大推离强度; β 为指数调节系数; d 为采样点至障碍物的最短距离。该方法能在保持路径连续性的前提下, 实现局部避障的动态修正。

修正完成后, 系统基于 B 样条对调整段进行局部重构, 确保路径平滑过渡并维持整体轨迹的稳定性。如图 6 所示, 分段线性折线表示原始路径, 连续且光滑曲线表示平滑优化后的路径。修正后轨迹与障碍物保持更大安全间距, 运动更加平滑稳定。

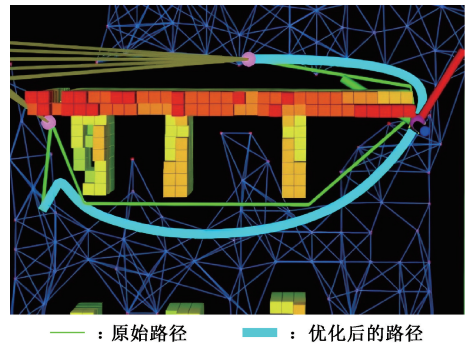


图 6 路径平滑优化结果截图

Fig. 6 Screenshot of path smoothing optimization results

3 实验验证

为评估所提方法的性能,本文分别在仿真环境与实车平台中开展了验证实验。仿真实验在一台 AMD Ryzen 7 8745H @ 3.80 GHz CPU 与 16 GB RAM 计算机上完成,运行系统为 Ubuntu 20.04。系统基于 Fast-LIO2 算法




图7 3种仿真地图

Fig. 7 The three simulation environments

其中,场景1为结构规则、障碍较少的开放式环境,主要用于评估算法在标准空间下的基础性能;场景2与场景3则由一系列走廊和房间构成,包含大量易出现回溯路径的探索死角,用以检测各方法对小区域和边角区域的探索效果。同时,通过在探索时间和轨迹长度指标上,本文将所提方法与两种先进探索算法进行对比分析:

对比算法1为FAEL^[27],该算法为面向大规模环境的高效前沿探索方法,具备快速路径更新能力,能够适应高频率任务执行的应用需求;

实现高精度激光SLAM建图与定位,整体系统构建于ROS(robot operating system)框架之上。

3.1 仿真验证与性能对比

为系统评估所提系统在探索任务中的整体效率,特别是在狭小空间、边角等复杂区域中的适应性 with 探索效果,本文在3种仿真环境下开展了仿真实验,如图7所示。

对比算法2为TARE^[29],该算法为最先进的探索方法之一,采用分层式环境建模与局部—全局联合优化策略的先进探索算法,可在复杂结构中实现高效的全局路径规划与连续运动控制。

无人平台的最大速度设定为2 m/s,激光雷达的最大探测范围设置为 $d_{\max} = 12$ m,其余仿真参数设置如表1所示。所有方法均在相同的起始位置和初始设置情况下进行了10次重复实验,并统计了探索时间、轨迹长度和覆盖率作为对比指标于表2。

表1 所提方法在各仿真实验中的参数设置

Table 1 Parameter settings of the proposed method in all simulation experiment

栅格地图	稀疏路线图更新			路径序列优化			B样条路径优化			
分辨率	R	r	n	ξ	α	w_b	λ_c	λ_s	λ_y	d_{safe}
0.385	7.0 m	3.0 m	3	1.0 m	0.9	0.5	7	0.2	0.2	0.725 m

1) 多场景性能评估

图8展示了3种算法在各仿真场景中的探索轨迹结果。仅从路径分布的角度来看,本文方法在整个探索过程中展现出了最少的路径冗余,其能够有效引导无人平台深入房间及边界区域,实现对边角与狭窄空间的充分覆盖,显著减少了回溯运动与冗余路径,高效且连续地完成了对整个未知环境的覆盖。相较而言,FAEL在探索初期及执行过程中对边角区域的关注不足,常出现部分区域探索遗漏的情况,进而在后期产生高代价回返操作,尤其在场景2和场景3等结构复杂环境中更为明显。而TARE方法虽然在路径规划的连续性方面表现较好,但对边角区域遗漏严重,在不同环境中都出现了不同程度的多次回溯的情况,造成整体探

索效率下降。

图9展示了各方法在不同场景中的探索进度曲线。从曲线可以直观看出,本文方法能够在最短的时间和距离内完成探索任务,且曲线整体呈现近似线性增长,充分说明其在探索效率方面相较其他两种方法具有显著优势。

通过多组实验发现,TARE方法在探索早期阶段表现出较快的覆盖速度,主要是由于其路径生成策略倾向于沿直线通道优先推进。然而,该方法忽略了走廊两侧小型房间的及时探索,在中后期阶段出现多次回溯以补充未覆盖区域,探索效率低。同时,FAEL在执行过程中通常能够较早进入房间开展探索,但其目标点选取机制仅依据方向与距离构建代价函数,缺乏对边界区域的

表 2 所有方法在 3 种仿真环境中的探索数据对比

Table 2 The exploration result comparisons of all methods in three simulation environments

场景	方法	探索时间/s		轨迹长度/m		覆盖率 平均值/%
		平均值	标准差	平均值	标准差	
场景 1	TARE	575.92	66.00	1045.76	109.05	87.31
	FAEL	416.35	51.81	575.85	103.74	97.09
	本文方法	354.40	40.40	480.87	64.08	96.97
场景 2	TARE	502.65	33.14	891.99	63.00	87.27
	FAEL	481.85	20.26	673.79	30.88	96.56
	本文方法	409.3	53.77	537.84	77.41	96.60
场景 3	TARE	538.74	84.14	905.51	53.95	88.17
	FAEL	510.37	35.40	724.74	55.15	97.97
	本文方法	448.98	31.50	598.45	37.38	97.91

引导。当房间入口与边界距离较远时,若通道方向信息增益更大,该方法易提前离开房间,导致边缘区域覆盖不全,并在后期产生高代价的补偿性回返。相比之下,本文方法在路径规划阶段综合考虑了信息增益、运动连续性与边角优先性等多因素,使得生成的探索路径在经过各视点时更加合理与高效。尽管在探索初期,其进度增长趋势与 FAEL 方法接近,但随着任务推进,本文方法在中后期阶段逐渐展现出更高的覆盖速度与效率,最终以最短的时间与路径长度提前完成了探索。尤其是在结构复杂、空间密集的环境中,本方法能够有效避免冗余回溯,显著提升整体探索效率。

从表 2 可以看出,本文所提出的探索方法在相同环境条件下,展现出更优的时间效率和路径控制能力。结果显示,与 FAEL 相比,所提方法的平均探索时间降低 12.03% ~ 14.81%, 平均路径总长度降低 16.49% ~ 20.15%; 与 TARE 相比,平均探索时间与平均路径总长

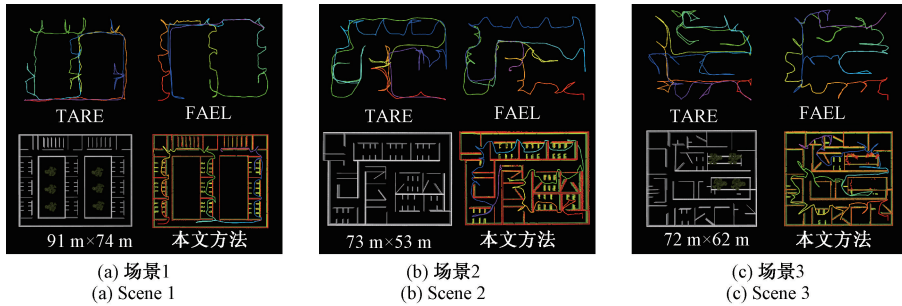


图 8 所有方法在 3 种仿真地图中的探索轨迹结果图

Fig. 8 Exploration trajectory results of all methods in the three simulation maps

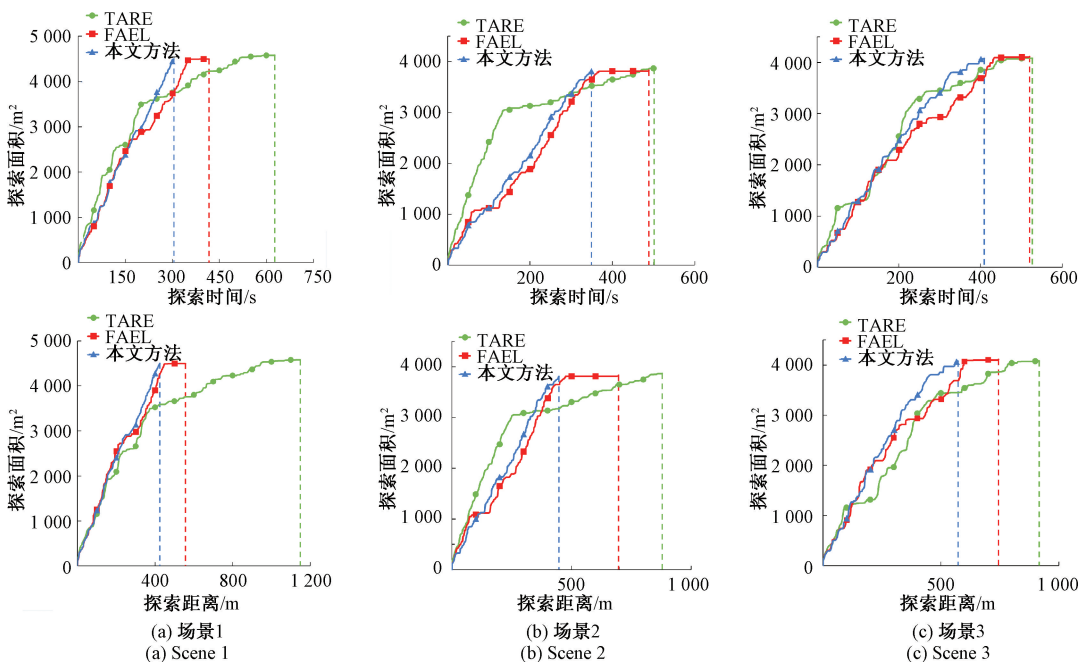


图 9 所有方法在 3 种仿真环境中的探索进展

Fig. 9 The exploration progress of all methods in the three simulation environments

度则分别降低 16.66%~38.41% 和 33.91%~54.02%。此外,所提算法在平均覆盖率方面明显优于 TARE 算法,提升约 9.7%~9.8%。与 FAEL 算法相比,本文所提算法在保持相同高覆盖率的同时,进一步兼顾了时间效率与路径规划性能,体现出较强的综合探索能力。

2) 进一步性能评估

为进一步评估所提方法在边角区域中的探索能力,并补充与基于学习的探索方法的对比验证,本节引入先进学习探索算法 ARiADNE^[19]的公开室内探索模型进行对比验证。为尽量减小训练分布差异对对比结果带来的影响,并在更接近其公开室内场景的条件下进行评估,如图 10 所示,本文参考其公开的室内场景结构额外设计了场景 4,并在局部引入若干边角小区域结构,用于检验算法对小尺度未知区域的覆盖能力与整体探索效率。场景中主要包括 3 类代表边角结构:结构 1 包含带遮挡的角落结构,观测视点受限,易被延后处理;结构 2 为转角处的狭窄房间入口,其周边开阔区域往往具有更大的即时增益,导致入口内部的小区域易被忽略;结构 3 为包含较大凹角的房间结构,若缺乏针对性引导,房间边界处易出现覆盖遗漏的情况。

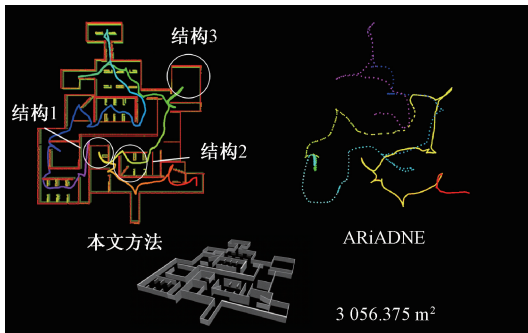


图 10 所提方法与 ARiADNE 在场景 4 探索轨迹结果图
Fig. 10 Exploration trajectory result comparisons between the proposed method and ARiADNE in scene 4

在此基础上,本文首先分析 ARiADNE 在不同场景条件下的探索稳定性表现。经过重复实验验证,在图 7 所示的 3 个未包含于训练集中的复杂场景中,ARiADNE 均因陷入局部死角而无法有效脱困,最终导致探索任务失败;在场景 4 的部分实验中,亦可观察到类似情况。其原因在于当前学习方法对场景分布变化仍较为敏感,当测试环境与训练场景存在差异时,其策略难以保持稳定性,泛化能力存在一定局限。

相比之下,从探索轨迹结果可以看出,所提方法在探索过程中表现出更少的路径回溯与重复访问,且更早进入并完成对局部小区域的覆盖。其原因在于:对于结构 1,本文通过小区域优先代价项提高了该类低增益区

域的排序优先级,从而降低遗漏;对于结构 2 与结构 3,基于边角引导的视点距离自适应调整机制使得视点更贴近关键区域,同时通过小区域优先代价进一步促使无人平台优先进行该结构区域的探索。虽然所提方法在这些区域的探索牺牲了一定的局部效率,但极大的减少了往返路径,提高了整体的探索效率。

从表 3 的定量结果可以看出,所提方法在保持较高覆盖率的同时,其平均探索时间与平均轨迹长度均优于基准方法。进一步地,在 ARiADNE 能够顺利完成探索的案例中,相较于该学习方法,所提方法的平均探索时间减少约 6.87%,轨迹长度缩短约 23.75%,展现出了更强的探索稳定性。

表 3 所有方法在场景 4 中的探索数据对比

Table 3 Exploration results of all methods in scene 4

方法	探索时间/s		轨迹长度/m		覆盖率 平均值%
	平均值	标准差	平均值	标准差	
ARiADNE	375.61	38.54	598.89	40.54	96.26
TARE	372.47	28.97	665.54	50.96	92.23
FAEL	377.36	19.36	500.92	32.18	99.69
本文方法	349.80	24.63	456.66	29.89	99.34

3.2 实车探索实验验证

为进一步评估该策略在现实环境中的可行性与有效性,本节在真实场景中基于四轮差速移动机器人平台开展了自主探索实验,所使用的无人平台如图 11 所示。该平台采用 Scout Mini 底盘,并搭载 RS-Helios-1615 激光雷达、MTI-30 惯性测量单元以及 Intel NUC 13 VYKI5 机载计算设备。实验选取一处典型的室内走廊作为测试环境,其布局如图 12 所示。考虑到实验场地较为狭窄,将地图分辨率设为 0.2 m,雷达最大有效探测范围 d_{max} 为 4 m,同时将机器人最大速度为 1.5 m/s 以确保安全,其他参数设置与表 1 保持一致。

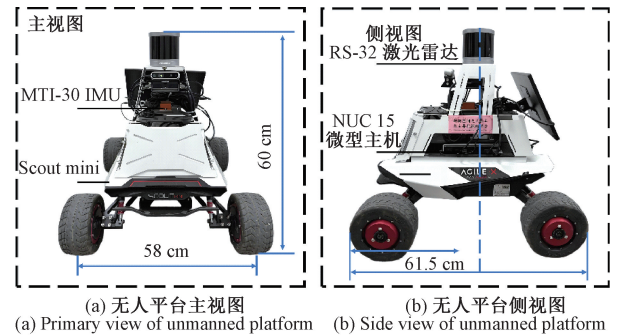


图 11 无人平台实物图

Fig. 11 The real unmanned platform




图12 室内走廊环境地图

Fig. 12 The environment map of indoor corridor

图13显示了基于所提算法重建地图结果,其中白色实线为探索轨迹,圆点为探索起始位置。在该场景中,机器人共用时833.95s完成了对走廊区域的自主探索,轨迹总长度为196.485m,对应探索面积为464m²。实验结果充分验证了所提探索方法在真实场景中应用的可行性和有效性。




图13 真实环境探索实验结果

Fig. 13 The results of real-world experiment

4 结 论

针对无人平台在大规模未知环境中探索效率低、边角区域覆盖不足及路径连续性差等问题,本文提出了一种基于边角区域引导的无人平台分层主动路径规划方法。在系统前端,设计了基于边界信息的探索目标生成机制,同时引入基于动态切换策略的路径矩阵构建方式,以此提高探索点筛选的代表性以及路径生成的响应效率。在系统后端,结合多因素代价评估、B样条优化以及碰撞修正策略,确保了路径在执行过程中的空间覆盖性、平滑性与安全性。仿真结果表明,所提方法能够高效地完成复杂环境下的全局探索任务,并在维持平均覆盖率96.6%以上的同时,探索时间和路径长度有显著的降低,显著提升了整体探索效率与路径规划质量。同时,在室内真实场景中的实车实验进一步验证了所提方法在真实场景中的可行性与适用性。

本文方法目前只考虑了静态障碍物的情景,而实际环境中移动目标普遍存在且不可忽视。未来工作将从动态障碍物运动预测建模、动态环境下的路径重规划算法

设计,以及基于时间一致性的实验验证等方面展开,以进一步提升算法在复杂动态场景中的适应性与鲁棒性。

参考文献

- [1] FUKUI R, KATO Y, TAKAHASHI R, et al. Automated construction system of robot locomotion and operation platform for hazardous environments basic system design and feasibility study of module transferring and connecting motions[J]. *Journal of Field Robotics*, 2016, 33(6): 751-764.
- [2] CHEN S W, NARDARI G V, LEE E S, et al. SLOAM: Semantic LiDAR odometry and mapping for forest inventory[J]. *IEEE Robotics and Automation Letters*, 2020, 5(2): 612-619.
- [3] 刘博. 基于激光雷达的室内外巡检移动机器人原型设计与实现[D]. 成都: 西南交通大学, 2015.
LIU B. Prototype design and implementation of an indoor-outdoor inspection mobile robot based on LiDAR[D]. Chengdu: Southwest Jiaotong University, 2015.
- [4] 邹楚, 陈佳. 仓储机器人创新技术近五年研究进展[J]. *机电工程技术*, 2024, 53(8): 17-22, 70.
ZOU CH, CHEN J. Research progress on innovative technologies of warehousing robots in the past five years[J]. *Mechanical & Electrical Engineering Technology*, 2024, 53(8): 17-22, 70.
- [5] 孙明晓, 张允曦, 栾添添, 等. 基于局部地图复杂度动态势场引导的无人船路径规划算法[J]. *仪器仪表学报*, 2025, 46(8): 321-329.
SUN M X, ZHANG Y X, LUAN T T, et al. Path planning algorithm for unmanned surface vehicle based on local map complexity and dynamic potential field guidance[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(8): 321-329.
- [6] 陈正升, 田楚开, 刘凯旋, 等. 基于MBIT*的移动机器人渐进最优路径规划[J]. *仪器仪表学报*, 2025, 46(5): 352-364.
CHEN ZH SH, TIAN CH K, LIU K X, et al. MBIT* for asymptotically optimal path planning of mobile robot[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(5): 352-364.
- [7] 武晓雯, 郭孟营, 胡阿建, 等. 基于改进遗传粒子群算法的无人机路径规划[J]. *仪器仪表学报*, 2025, 46(4): 315-325.
WU X W, GUO M Y, HU A J, et al. Path planning for UAV based on improved hybrid genetic particle swarm

- algorithm[J]. Chinese Journal of Scientific Instrument, 2025, 46(4): 315-325.
- [8] 邓冬冬, 许建民, 孟寒, 等. 基于蚁群算法与人工势场法融合的移动机器人路径规划[[J]. 仪器仪表学报, 2025, 46(2): 1-16.
- DENG D D, XU J M, MENG H, et al. Mobile robot path planning based on the fusion of ant colony algorithm and artificial potential field method[J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 1-16.
- [9] YAMAUCHI B. A frontier-based approach for autonomous exploration [C]. Computational Intelligence in Robotics and Automation, 1997: 146-151.
- [10] ZHOU B Y, ZHANG Y CH, CHEN X Y, et al. FUEL: Fast UAV exploration using incremental frontier structure and hierarchical planning [J]. IEEE Robotics and Automation Letters, 2021, 6(2): 779-786.
- [11] TORDESILLAS J, LOPEZ B T, EVERETT M, et al. FASTER: Fast and safe trajectory planner for navigation in unknown environments [J]. IEEE Transactions on Robotics, 2022, 38(2): 922-938.
- [12] LA VALLE S M, KUFFNER JR J J. Randomized kinodynamic planning [J]. International Journal of Robotics Research, 2001, 20(5): 378-400.
- [13] BIRCHER A, KAMEL M, ALEXIS K, et al. Receding horizon "next-best-view" planner for 3D exploration[C]. 2016 IEEE International Conference on Robotics and Automation, 2016: 1462-1468.
- [14] QIAO W CH, FANG ZH, SI B L. Sample-based frontier detection for autonomous robot exploration [C]. 2018 IEEE International Conference on Robotics and Biomimetics, 2018: 1165-1170.
- [15] QIAO W CH, FANG ZH, SI B L. A sampling-based multi-tree fusion algorithm for frontier detection [J]. International Journal of Advanced Robotic Systems, 2019, 16(4): 1729881419865427.
- [16] DANG T, MASCARICH F, KHATTAK S, et al. Graph-based path planning for autonomous robotic exploration in subterranean environments[C]. 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2019: 3105-3112.
- [17] ZHANG ZH W, SHI CH H, ZHU P M, et al. Autonomous exploration of mobile robots via deep reinforcement learning based on spatiotemporal information on graph[J]. Applied Sciences, 2021, 11(18): 8299.
- [18] SCHMID L, NI CH, ZHONG Y L, et al. Fast and compute-efficient sampling-based local exploration planning via distribution learning[J]. IEEE Robotics and Automation Letters, 2022, 7(3): 7810-7817.
- [19] CAO Y H, HOU T X, WANG Y ZH, et al. ARiADNE: A reinforcement learning approach using attention-based deep networks for exploration[C]. 2023 IEEE International Conference on Robotics and Automation, 2023: 10219-10225.
- [20] CAO Y H, WANG Y ZH, VASHISTH A, et al. CatNIPP: Context-aware attention-based network for informative path planning[C]. 6th Conference on Robot Learning, 2023: 1928-1937.
- [21] CAO Y H, LEW J, LIANG J S, et al. DARE: Diffusion policy for autonomous robot exploration[C]. 2025 IEEE International Conference on Robotics and Automation, 2025: 11987-11993.
- [22] CIESLEWSKI T, KAUFMANN E, SCARAMUZZA D. Rapid exploration with multi-rotors: A frontier selection method for high speed flight [C]. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2017: 2135-2142.
- [23] DAI A, PAPATHEODOROU S, FUNK N, et al. Fast frontier-based information-driven autonomous exploration with an MAV [C]. 2020 IEEE International Conference on Robotics and Automation, 2020:9570-9576.
- [24] BATINOVIC A, PETROVIC T, IVANOVIC A, et al. A multi-resolution frontier-based planner for autonomous 3D exploration[J]. IEEE Robotics and Automation Letters, 2021, 6(3): 4528-4535.
- [25] CHEN F F, MARTIN J D, HUANG Y W, et al. Autonomous exploration under uncertainty via deep reinforcement learning on graphs [C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 6140-6147.
- [26] SCHMID L, PANTIC M, KHANNA R, et al. An efficient sampling-based method for online informative path planning in unknown environments [J]. IEEE Robotics and Automation Letters, 2020, 5(2): 1500-1507.
- [27] HUANG J L, ZHOU B, FAN ZH P, et al. FAEL: Fast autonomous exploration for large-scale environments with a mobile robot [J]. IEEE Robotics and Automation Letters, 2023, 8(3): 1667-1674.

- [28] ZHAO Y H, YAN L, XIE H, et al. Autonomous exploration method for fast unknown environment mapping by using UAV equipped with limited FOV sensor [J]. IEEE Transactions on Industrial Electronics, 2024, 71(5): 4933-4943.
- [29] CAO CH, ZHU H B, YANG F, et al. Autonomous exploration development environment and the planning algorithms[C]. 2022 International Conference on Robotics and Automation, 2022: 8921-8928.

作者简介



陶贤露(通信作者),2016年于武汉大学获得学士学位,2019年于武汉大学获得硕士学位,2023年于武汉大学获得博士学位,现为东南大学讲师,主要研究方向为GNSS高精度定位、多传感器融合导航及其应用。
E-mail:xltao@seu.edu.cn

Tao Xianlu (Corresponding author) received his B.Sc., M.Sc., and Ph.D. degrees all from Wuhan University in 2016, 2019, and 2023, respectively. He is currently a lecturer at Southeast University. His main research interests include GNSS high-precision positioning, multi-sensors integrated navigation, and its applications.



刘佳璇,2025年于北京交通大学获得学士学位,现为东南大学硕士研究生,主要研究方向为机器人自主探索、运动规划以及机器学习。

E-mail:220253869@seu.edu.cn

Liu Jiaxuan received her B.Sc. degree from Beijing Jiaotong University in 2025. She is currently pursuing her master's degree at Southeast University. Her main research interests include robot autonomous exploration, motion planning and machine learning.