

# 基于滚动时域和拓扑学优化的无人船多未知区域自主探索方法

王昱, 马俨, 王冰<sup>†</sup>

(河海大学 人工智能与自动化学院, 江苏 常州 213200)

**摘要:** 本文针对无人船多区域自主探索缺乏前瞻性、探索面积大、受海流影响的问题, 提出一种基于滚动时域和拓扑学优化 (RHTO) 的自主探索方法. 首先, 利用滚动时域的思想将整个探索任务分解, 通过当前已知信息估算全局最佳探索路径, 并只执行部分路径; 其次, 通过边界检测和循环采样快速构建连通当前可达区域的基础路径网, 配合拓扑学优化算法快速收敛得到最短路径网; 最后通过评价函数计算每条路径的航行成本, 使用遗传算法规划最佳探索顺序和探索路径, 生成覆盖路径点作为视点引导无人船探索, 最终回到起点. 仿真实验结果表明采用 RHTO 方法相比常见的几种自主探索算法, 无人船在海上多区域探索结束后, 路径总长度、路径外角和以及克服洋流能耗三项指标最小, 鲁棒性更好.

**关键词:** 无人船; 未知环境; 自主探索; 滚动时域; 拓扑学优化

**中图分类号:** TP242.6 **文献标志码:** A

**DOI:** 10.13195/j.kzyjc.2025.1139

**引用格式:** 王昱, 马俨, 王冰. 基于滚动时域和拓扑学优化的无人船多未知区域自主探索方法 [J]. 控制与决策, xxxx, x(x): xxxx-xxxx.

## A receding horizon and topology optimization-based autonomous exploration method for unmanned surface vehicle in multiple unknown regions

WANG Yu, MA Yan, WANG Bing<sup>†</sup>

(College of Artificial Intelligence and Automation, Hohai University, Changzhou 213200, China)

**Abstract:** In this paper, a receding horizon and topology optimization (RHTO)-based autonomous exploration method is proposed to address the issues of lack of foresight, large exploration areas, and susceptibility to ocean currents in multi-region autonomous exploration for unmanned surface vehicle (USV). First, the overall exploration task is decomposed using a receding horizon approach, which estimates the optimal global exploration path for a future period based on currently known information and executes only a portion of the path. Second, a basic path network connecting currently accessible regions is rapidly constructed through frontier detection and cyclic sampling. This is combined with a topology optimization algorithm to quickly converge to the shortest path network. Finally, a cost function is used to evaluate the navigation cost of each path. A genetic algorithm is applied to plan the optimal exploration sequence and paths, generating coverage waypoints as viewpoints to guide the USV's exploration before eventually returning to the starting point. Simulation results demonstrate that, compared to several common autonomous exploration algorithms, the RHTO method achieves the smallest values in three key metrics: total path length, total path turning angle, and energy consumption to overcome water resistance, while also exhibiting better robustness.

**Keywords:** unmanned surface vehicle; unknown environment; autonomous exploration; receding horizon; topology optimization

## 0 引言

无人船具有载荷大, 续航长, 船体效应小, 安全性高等优势, 十分适合在广阔复杂的水域进行长时间探测作业<sup>[1,2]</sup>, 但也面临通信和能源受限, 因此具有

自主作业的能力十分重要, 尤其是大范围自主探索未知区域的能力. 无人船自主探索需要在部分地图信息未知的广阔水域自主生成视点, 行驶到视点的过程中用传感器探索环境并更新地图<sup>[3,4]</sup>, 根据新的

收稿日期: xxxx-xx-xx; 录用日期: 2026-03-01.

基金项目: 江苏省基础研究计划 (BK20240349).

<sup>†</sup>通信作者. E-mail: icekingking@hhu.edu.cn.

地图信息继续规划下一步行动, 最终实现未知区域尽可能地探索。

自主探索技术主要研究如何生成视点和选择视点, Yamauchi<sup>[5]</sup>提出基于边界的探索规划方法, 引导机器人连续移动至已知区域边界来探索环境, 但缺乏全局规划; Bircher等<sup>[6]</sup>提出了基于滚动时域的下一最优视点的规划方法 (Receding Horizon Next Best View-Point, RH-NBV), 通过考虑传感器的观测能力, 评估一条最佳路径并选取第一节点探索, 使探索初步有了前瞻性, 但是评估视野价值计算消耗大, 不能预测全局路径或未知区域内的路径; Wang等<sup>[7]</sup>通过在3D环境维护一个增量式拓扑地图来提升NBV的规划效率, 减少了NBV的计算消耗; Umari等<sup>[8]</sup>提出了一种基于多棵快速探索随机树 (Multi Rapid-exploration Random Tree, M-RRT) 的探索策略, 使用全局和局部两棵随机树分别负责寻找未知区域和引导机器人前进探索, 为后续研究提供了强大的方法框架; Zhu等<sup>[9]</sup>在M-RRT的基础上提出双阶段视点规划方法DSVP, 局部视点用于前向完备探索, 全局视点用于重定位到下一未知区域, 减少了回溯, 但全局上仍是最邻近探索; Janoš等<sup>[10]</sup>结合M-RRT和RRT\*的思想, 在多目标规划中于每个目标点处生长一棵随机树, 共同维护所有树并尝试相互连接形成填充森林 (Space Filling Forest, SFF\*), 优化了多目标规划中的全局路径, 有利于旅行商问题 (TSP) 求解, 但计算量大难以适应复杂未知环境; 齐立哲<sup>[11]</sup>等通过构建拓扑地图来评估移动代价和记忆已探索区域, 但其拓扑路径未优化且会不断增加, 不适用于大范围复杂环境。

由于海上未知区域面积较大, 需要考虑覆盖式探索 (Coverage Exploration), 陈彦杰等<sup>[12]</sup>在未知环境的覆盖任务中通过平衡框架平衡探索和覆盖, 设计覆盖奖励函数引导机器人高效完成全覆盖探索, 然而, 该方法主要针对机器人传感器半径远大于待覆盖区域的场景, 且其“平衡框架”需要针对特定环境精细调参, 不适用于海上不同约束形式的大范围覆盖任务; Li等<sup>[13]</sup>提出分层覆盖规划, 通过全局和局部规划层维护区域连通性, 避免过早地访问破坏连通性的区域, 减少了重复路径和锁死, 然而这种覆盖探索方式没办法控制终点位置, 在面对多块未知区域覆盖任务时未考虑下一区域; 曹路阳等<sup>[14]</sup>基于增量更新的可视图, 采用一种指数衰减形式的评估函数挑选下一最佳视点, 算法轻量化, 路径代价评估准确, 能规划未知区域内的路径, 但地图的简化更适合结构化场景。

综上, 主流自主探索方法虽致力于缓解局部极值问题, 但其底层基于贪心策略的视点选择 (如最大化即时信息增益或趋近前沿) 决定了该方法本质仍限于局部优化, 难以从根本上避免局部最优。若追求全局最优探索, 还须引入全局规划。传统探索方法通常回避显式的全局规划, 主要基于两方面因素: 其一, 在完全或高度未知的环境下, 全局规划依赖于对未知区域的预测, 而预测的不确定性高, 可能导致规划频繁失效与重规划, 计算性价比低; 其二, 在典型结构化场景中, 可行路径的拓扑结构相对简单, 局部贪心策略往往能以较低计算成本获得较优解, 进行复杂全局优化的边际收益有限。然而, 对于有部分先验海图的海上多区域探索任务, 全局预测规划便有了发挥的空间。海上的可通行区域广阔, 且障碍物多为礁石、岛屿等孤立障碍物, 可选路径多。海流影响使同一条路径不同方向的航行成本不同, 如果有已知的海流场, 便可提前规划阻力小的探索方向, 同时未知区域面积大, 可以引入覆盖式探索规划。多未知区域的探索也可以通过构建路径图求解TSP。

针对海上多区域探索的特殊情况, 本文提出一种基于滚动时域和拓扑学优化 (receding horizon and topology optimization, RHTO) 的多区域自主探索策略。本方法的创新之处在于:

1) 提出一种基于滚动时域的全局预测探索框架。在每一决策时刻根据当前地图信息进行全局规划, 预估遍历所有未知区域的最佳顺序和下一目标区域的覆盖路径, 仅执行第一个目标区域的第一个覆盖路径点的探索, 区别于仅考虑局部优化的方法<sup>[6]</sup>, 本文将全局优化引入自主探索。

2) 针对传统探索方法评估移动代价时效率低下, 提出一种基于拓扑路径网络的移动代价评估方式。在构建拓扑路径网络时, 基础连通层使用边界检测和循环采样RRT来构建并维护增量式基础路径网, 优化更新层利用拓扑学路径优化算法抽象化未知区域, 快速收敛得到区域间最短路径, 再综合考虑路径距离、转向代价和海流影响, 得到更适合水上复杂环境的移动代价。

3) 提出一种双层视点预估方法。第一层通过引入TSP求解得到最佳访问顺序和区域进出口, 第二层使用覆盖路径规划 (Coverage Path Planning, CPP) 生成目标区域的覆盖路径点作为预估视点, 不同于传统探索方法中视点只能生成在已知区域或未知边界<sup>[9]</sup>, 本文方法直接在未知区域内生成视点, 能直接引导无人船进入未知区域, 提升规划前瞻性。

## 1 问题描述

本文研究在有部分先验海图的情况下单艘无人船自主探索多块未知区域并回到起点的探索效率和能耗最优问题. 现在分别介绍传统探索方式和本文方法的问题定义.

### 1.1 传统自主探索任务定义

传统自主探索任务可描述为从初始位置 $P_{start}$ 开始, 寻找当前可达的未知区域 $U$ 和已知区域的边界点 $F$ 生成观测视点集 $P_{view}$ <sup>[8]</sup>, 根据传感器半径 $r$ 和到达视点的路径, 选择探索收益大且移动代价低的视点探索, 同时避开已知障碍物 $O_{now}$ ,  $O_{now} \in O_{all}$ ,  $O_{all}$ 为任务区域内所有障碍物, 最终实现未知区域被穷尽探索.

### 1.2 无人船自主探索任务定义

当未知区域为多块孤立区域时, 传统探索问题以前沿点为探索单元<sup>[5]</sup>, 本质是贪心策略, 缺乏全局规划, 易于导致局部最优. 据此, 我们重新定义探索问题如下:

将未知区域根据中心点编号为点集 $C$ , 在地图上的横纵坐标为 $(x, y)$ , 则有:

$$C = [(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)]. \quad (1)$$

其中 $n$ 代表中心点个数, 规划到达各个未知区域的路径 $\sigma$ , 计算得到遍历所有区域的移动代价最低的路径, 到达目标未知区域后在该区域内生成一系列视点, 保证依次探索视点能带领无人船高效探索完目标区域后离开. 行驶的过程中探索传感器半径 $r$ 内的未知区域, 同时避开已知障碍物 $O_{now}$ , 并根据更新的地图信息进行重规划. 最终实现探索完毕回到起点后总路径 $T$ 的代价最小. 定义路径代价为 $Cost$ , 其计算式如下:

$$Cost = aL + b\psi + cE, \quad (2)$$

$$E = \sum_{k=1}^K \frac{W \cos \psi_k}{L_k^{flow}}. \quad (3)$$

其中 $L$ 代表路径总长度,  $\psi$ 表示路径外角和(即总转向角度),  $W$ 代表海流场, 包含坐标和海流向量,  $E$ 为无人船克服海流阻力的能量消耗.  $a, b, c$ 分别为路径总长度、路径外角和以及克服海流阻力消耗三项指标的代价系数. 其中 $\psi_k$ 为第 $k$ 段水流内路径航向与水流方向夹角,  $L_k^{flow}$ 为第 $k$ 段水流内路径的长度,  $K$ 为水流内路径段总数. 任务示意图如图1.

为了聚焦探索问题, 本文做出如下假设:

- 1) 无人船先验地图信息正确且能准确定位;
- 2) 无人船雷达范围内的未知区域都能被探索且




图1 无人船探索任务示意图

准确获得其中的环境信息;

3) 地图中各块未知区域互不相连, 未知区域内部环境和连通性未知.

## 2 面向多未知区域的自主探索方法

针对无人船多区域自主探索缺乏前瞻性、探索面积大、受海流影响的问题, 为了提高无人船多区域自主探索能力, 实现全局优化, 本文提出 RHTO 方法.

### 2.1 RHTO 方法框架

RHTO 方法采用一种双层预测框架来解决多区域探索问题. 上层预测负责规划多个待探索区域的最佳访问序列 $S$ 、区域入口 $D^I$ 和区域出口 $D^O$ ; 下层预测则在当前目标区域内, 生成一条从入口到出口覆盖该区域的最优路径 $\delta$ , 如式(4)-(6). 算法仅执行两级预测结果中的下一个动作(进入下一个区域或驶向下一个路径点), 随后根据实时环境信息(如发现新障碍或完成区域探索)触发重规划, 动态更新两层预测结果, 形成一个闭环的自主探索系统, 实现最终行驶路径 $T$ 的 $Cost$ 最小化.

$$\sigma_{ij} = [D_i^O, (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n), D_j^I], \quad (4)$$

$$\delta_j = [D_j^I, (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n), D_j^O], \quad (5)$$

$$T_{ij} = \sigma_{ij} + \delta_j. \quad (6)$$

其中 $i$ 表示当前所在区域,  $j$ 表示当前目标区域.

预测方法的核心是假设未知区域内部障碍物不会阻碍规划的路径, 便可以根据已知障碍物和未知区域规划一条遍历所有未知区域中心点后回到起点的最低航行成本路径. 未知区域内的路径点作为视

点, 每次导航到下一个视点探索. 访问顺序的预测时域为当前已连接但未探索的区域数 (可达区域), 视点的预测时域为从目标区域入口或 USV 当前位置到出口需要的最少覆盖路径点数. 当出现下一视点在障碍物中时, 局部重规划剩余视点, 当出现未知区域内部不连通时, 优先探索完连通的剩余视点, 将不连通区域定义为新区域进行全局重规划. 每一块区域探索完成或失败后进行全局重规划, 直到探索完毕回到起点. RHTO 方法的整体框架如图 2, 主要算法见算法 1.

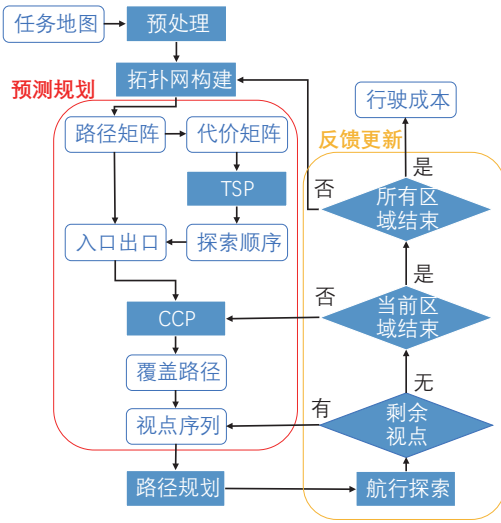


图2 RHTO 方法框架图

### 算法1 RHTO

Input:  $O, U, W, P_{start}$

Output:  $T, L, E, \psi$

Initialize:  $O_{closed}, r, FindAllU \leftarrow false, tree, \delta, \sigma, replan \leftarrow false$

1. BuildMap ( $O, U, W$ ) // 建立地图
2.  $O_{now} \leftarrow GetO(U, O)$  // 提取已知障碍物
3.  $[F_{all}, F_{free}] \leftarrow FrontierDetect(U, O_{now})$  // 边界检测
4.  $[C] \leftarrow DBscan(F_{all})$  // 聚类得到各区域中心点
5. while  $|O_{closed}| < |C| + 1$  do
6. while  $\neg replan$  do
7. if  $\neg FindAllU$  then
8.  $[tree, idx, FindAllU] \leftarrow CyclicRRT(F, C, tree, O_{now}, F_{all})$  // 随机树循环采样寻找当前可达的未知区域
9. end if
10. PathMatrix  $\leftarrow GetTreePath(tree, idx)$  // 通过随机树构建基础路径矩阵
11. TopoMatrix  $\leftarrow TopologySimplify(PathMatrix, O_{now})$  // 拓扑学优化路径
12.  $\sigma \leftarrow GetFeasiblePath(TopoMatrix, U)$  // 提取已知区域内的路径构建实际路径矩阵

13. TSPMatrix  $\leftarrow CalculateCostMatrix(TopoMatrix, W)$  // 计算得到TSP代价矩阵
14.  $S \leftarrow TSPGA(TSPMatrix, O_{closed})$  // 求解最佳探索顺序
15.  $i \leftarrow S(|S_{closed}| + 1)$  // 当前区域编号
16.  $j \leftarrow S(|S_{closed}| + 2)$  // 目标区域编号
17.  $n \leftarrow S(|S_{closed}| + 3)$  // 后续目标编号
18.  $D^I \leftarrow \sigma_{jn}(end)$  // 目标区域入口
19.  $D^O \leftarrow \sigma_{jn}(1)$  // 目标区域出口
20.  $\delta \leftarrow BoustrophedonGA(D^I, D^O, F_{all})$  // 预测覆盖路径
21.  $U_k^* \leftarrow \sigma_{ij} \cup \delta$  // 预测最佳视点队列
22.  $[T, U, replan, O_{now}] \leftarrow Explore(U, U_k^*, r, O_{now})$  // 执行探索
23. end while
24.  $[tree, idx] \leftarrow GoalBiasRRT(tree, T(end), O_{now})$  // 基础路径网连接当前位置
25.  $O_{closed} \leftarrow O_{closed} \cup \{j\}$  // 记录已探索区域
26.  $C(j) \leftarrow T(end)$  // 用当前位置替代当前区域中心点
26. end while
27.  $[L, E, \psi] \leftarrow CalculateFinalCost(T, W)$  // 计算探索成本
28. return  $L, E, \psi, T$

第一阶段, 地图建模与预处理. 根据像素海图建立障碍物点云地图, 添加自定义未知区域和海流场, 提取已知信息, 将包含所有未知区域的最小矩形区域内地图栅格化, 使用基于形态学的方法进行边界检测找到未知区域边界点, 筛选出未接触已知障碍物的空闲边界点, 用 DBscan 对边界点进行聚类, 得到各未知区域聚类中心并将未知区域编号.

第二阶段, 拓扑路径网络构建. 用循环采样随机树对边界点进行双层循环采样, 快速找到起点到每个未知区域的至少一条路径. 部分未知区域当前可能无法到达或者路径过于难找, 到达最大迭代次数后结束, 待部分区域被探索后再次寻找. 然后将路径末端与未知区域中心点相连, 构建起点到各未知区域中心的拓扑路径网络, 使用拓扑学路径优化算法得到各个节点间最短路径.

第三阶段, 最佳访问顺序规划. 通过截取拓扑路径网络中已知区域内的路径并综合考虑海流计算航行成本, 得到加权拓扑网 (抽象为代价矩阵), 使用遗传算法计算遍历所有节点并回到起点的最小成本路径, 根据当前问题规模动态调整收敛速度, 得到下一目标区域和出入口.

第四阶段,覆盖视点规划.按照未知区域形状和出入口,使用牛耕法规划一条向出口逼近的覆盖路径,再通过插值和遗传算法求解最佳覆盖顺序,按照顺序探索视点,并根据最新地图信息进行局部重规划或全局重规划.

## 2.2 拓扑路径网

要评估各区域间的航行成本,就需要知道各区域间的路径网络,由于探索任务漫长且地图信息会变化,因此需要一种既能适应大范围复杂地图,又能适应快速变化的增量环境信息的路径构建方法.本部分提出一种双层路径规划方法,该方法示意图如图3所示.




图3 双层路径规划方法示意图

所提双层路径规划方法包含两个层级,基础连通层负责发现并记录如何从起点到达各未知区域,通过构建类似斯坦纳树的基础路径网(暂时不要求总路径最短),将当前能到达的区域与USV所在位置连接(无论USV在起点还是别处),确保USV总能搜索到一条到达所有可达未知区域的路径,优化更新层负责在需要评估任意两点间的航行成本时快速收敛得到一条最短路径.

如图4所示,基础路径网络通过一棵以起点为根节点的随机树不断扩张构成.传统的基于随机树的探索方法需要靠随机树大量覆盖已知区域以搜索未知区域,为了避免遗漏,随着探索进行还要不断迭代生长,在面对大面积非结构化场景的海上探索任务时容易出现后期扩张和维护随机树的计算开销过大.本文利用边界检测和聚类得到的边界点引导随机树偏置采样,采样在两个层面循环,第一层,在所有未找到至少一条路径的未知区域间循环;第二层,在该未知区域所有空闲边界点间循环,快速找到起点到每个未知区域的至少一条路径.

## 2.3 拓扑学路径优化算法

基础路径网络只是为了找出当前可达区域,初始路径过于曲折冗余不利于评估航行成本,而如果采用RRT\*进一步优化各区域间路径,考虑到地形复杂和每两个未知区域之间都要规划一次,假设有 $n$ 个未知区域,根据式(7),需要规划 $(n+1)n/2$ 次,计算

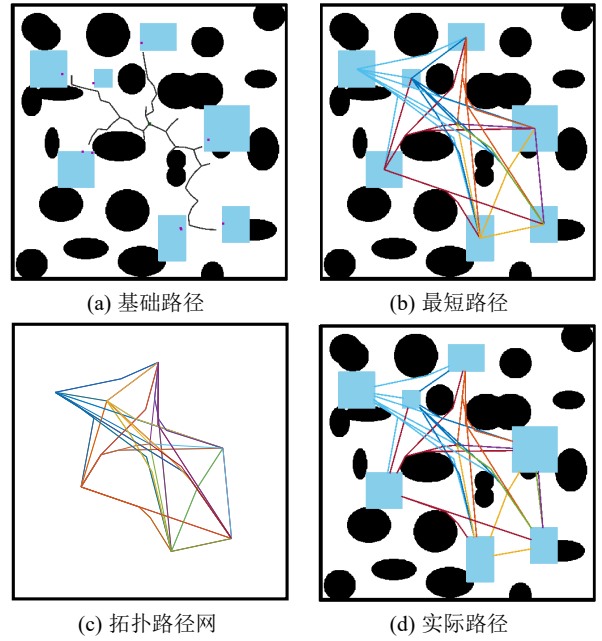


图4 路径网络构建

量过大且随着探索进行需要频繁重规划.

$$C(n+1, 2) = \frac{(n+1)!}{2!(n-1)!}. \quad (7)$$

对此本文提出一种基于拓扑学的路径优化方式,用于在海上环境中绕开孤立障碍物,忽视复杂障碍物形状,快速收敛得到更接近直线的路径.加上节点简化和曲线优化<sup>[15]</sup>可以得到更短更平滑的路径.核心思想在于构建连通图,不断搜索区域包围内的靠近起点到终点连线的空闲节点,示意图如图5,伪代码如算法2.

### 算法2 Topology-based Path Simplification

1. filtered\_B  $\leftarrow$  FilterObstaclesInPathArea(raw\_s,  $B_{now}$ ,  $U$ ) // 提取范围内障碍物
2. simplified\_s  $\leftarrow$  SimplifyPath(raw\_s, filtered\_B) // 初步简化路径
3. if path\_too\_short(simplified\_s) then // 如果路径是两点间最短路径
4. return simplified\_s // 返回简化路径
5. end if
6. [interpolated\_path, turning\_points]  $\leftarrow$  InsertPoints(simplified\_s) // 插值
7. grid  $\leftarrow$  ConstructTopologyGrid(interpolated\_s, turning\_points, filtered\_B) // 绘制网格
8. inward\_s  $\leftarrow$  ConnectGoalToStart(grid, filtered\_B) // 连接内收线段
9. simplified\_s  $\leftarrow$  SimplifyPath(inward\_s, filtered\_B) // 再次节点简化

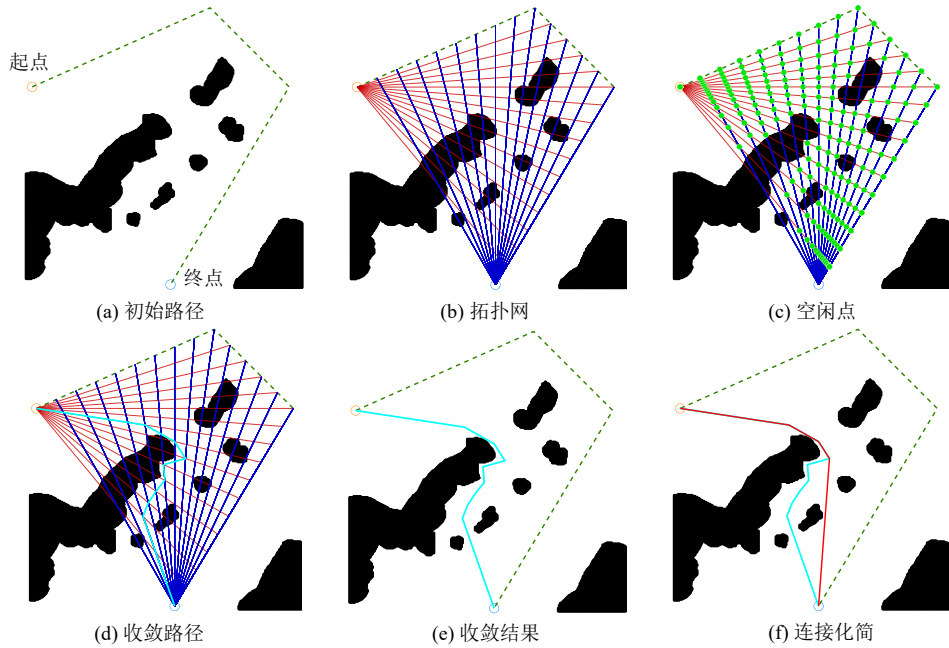


图5 拓扑路径优化示意图

```
10. smoothed_s ← BézierCurve (simplified_s, filtered_B) //
贝塞尔曲线
```

如图 5 (a), USV 到两区域中心的随机树路径可以被简化为绿色虚线所示路径, 假设两区域中心点分别为起点和终点, 由起点连接第一个路径转角后的所有插值点构成红色起点射线, 由终点连接倒数第二个转角前的所有插值点构成蓝色终点射线, 组成拓扑网, 如图 5 (b). 从最靠近终点的起点射线开始搜索未被障碍物占用的交点, 按离起点由近及远排列为当前射线的空闲点, 所有空闲点如图 5 (c) 绿点. 反向搜索路径, 由终点开始尝试连接第一条起点射线上最靠近起点的点, 连接成功就尝试连接下一条起点射线上最靠近起点的点, 该方法会不断朝着起点方向收敛得到图 5 (d) 青色内收路径, 可以绕开孤立障碍物, 但是并不平直, 使用节点简化便可得到图 5 (f) 中的红色最终路径. 为防止出现图 6 所示的情况, 引入超调规划<sup>[16]</sup>, 即当内收路径不是直线时, 将内收路径对起点终点连线作对称路径, 继续使用拓扑优化法尝试搜索更短内收的路径.




图6 超调规划示意图

## 2.4 动态 TSP 建模与求解

为了适应探索过程中部分区域逐渐被探索, 剩余区域逐渐被发现或产生新的路径的过程, 使用遗传算法动态求解 TSP 得到最佳探索顺序.

要获得 TSP 代价矩阵, 需计算每两个区域之间的航行成本, 根据拓扑路径网络和当前未知区域信息便可以得到已知区域中的实际路径网络, 根据已知海流场, 使用  $Cost$  计算式得到, 综合考虑路径长度, 路径外角和以及海流阻碍消耗的代价矩阵. 每次探索过后假设路径矩阵中有  $m$  个节点变动, 连通但未探索区域有  $n$  个, 则共有  $mn - C(m, 2)$  条路径改变, 虽然路径代价是双向不同的, 但并不需要重新计算  $2[mn - C(m, 2)]$  次, 每条路径的海流阻碍消耗只要计算一次, 对向路径取反即可.

通过输入已访问区域  $O_{closed}$ , 每次求解时固定起点到当前区域的顺序和路径长度, 排除未找到的区域 (即代价矩阵中代价为 0 的区域), 计算遍历剩余区域并回到起点的代价. 算法根据问题规模自适应调整算法参数, 在探索的某些时期会出现待探索区域很少的情况, 当待探索区域数量小于 4 时, 遗传算法往往用很少的迭代次数就能得到最优序列, 使用早停机机制检测收敛即提前终止, 避免部分探索时期区域过少导致计算冗余. 初始化阶段采用混合初始化策略, 结合随机与启发式策略, 提升初始解质量, 为了在少数次迭代后确保选出最优顺序, 采用严格的锦标赛选择和变异率策略.

## 2.5 覆盖路径规划

在获得了最佳探索顺序后, 可知道前往当前目

标区域的路径和前往下个区域的路径,从而得到目标区域的入口和出口,使用牛耕法融合遗传算法获得最佳覆盖路径。

牛耕法首先根据区域入口与出口的相对位置用式(8)自动确定最优的犁沟方向,以direction确定上下走向还是左右走向,以参数A或B的正负确定方向,以求从一个方向较少转向地探索至另一个方向,在遇到障碍物将区域分割时方便重规划。犁沟间距为传感器半径向下取整栅格分辨率的整数倍确定,因为Q的间距是栅格分辨率决定的。其余部分和传统牛耕法相同,算法最终生成一条连续的、从入口向出口慢慢靠近的“弓”字覆盖路径。

$$\text{direction} = \begin{cases} \text{horizontal}, & |A| > |B| \\ \text{vertical}, & |A| < |B| \end{cases}, \quad (8)$$

$$A = (D_x^I - D_x^O) / (Q_x^{\max} - Q_x^{\min}), \quad (9)$$

$$B = (D_y^I - D_y^O) / (Q_y^{\max} - Q_y^{\min}). \quad (10)$$

对该路径中犁沟方向的路径段进行插值处理,确保任意两点间的距离小于2倍传感器半径,目的是当路径点的覆盖顺序不同时保障覆盖面积。然后使用遗传算法求解最佳覆盖顺序。可采用原覆盖路径作为初始种群,提高收敛速度。

图7所示为当遇到视点在障碍物中的情况时,如果还有剩余视点,遗传算法可重规划到达出口的最佳顺序。目标是在未知的环境中尽可能高效地引导无人船遍历视点同时趋近出口,因为出口位置是到达下一未知区域的理想路径的起点,但是实际探索中可能遇到覆盖完毕后无人船远离出口的情况,如图8,因此不必继续前往出口,预测序列执行完毕后使基础路径层的随机树以当前位置偏置采样,将基础路径网连接到当前位置,配合拓扑学优化高效得到新目标,避免了目标区域改变造成路径冗余。




图7 B-GA 示意图

### 3 实验

为了验证本文方法在无人船自主探索任务中的效果,本部分在 Matlab 上进行了仿真实验与分析。




图8 覆盖完毕产生新目标区域示意图

#### 3.1 双层循环调度 RRT 对比实验

在大小为  $30 \text{ km} \times 30 \text{ km}$  的区域中分别导入三个海图,根据复杂程度分为简单/一般/复杂地图,简单地图和复杂地图均为截取的部分地中海地图(有缩放处理),中等地图为随机孤立椭圆障碍物地图。分别在其中设置 5-6 块淡蓝色未知区域,无人船起点在地图中心处。测试如下 3 种采样方式,最大迭代次数为 300,步长均为  $1 \text{ km}$ 。

如图 9 所示,实验结果表明不同复杂程度的地形中双层循环采样 RRT 寻找未知区域效率最高,冗余点最少,单层循环在复杂地图中容易出现局部最优。表 1 为不同复杂程度的地图中不同采样策略在五次实验中的平均值和标准差。

#### 3.2 RHTO 对比实验

为分析本文自主探索方法 RHTO 的效果,在不同复杂程度地图上与下列 4 种常见自主探索方法进行对比实验。

1) Multi-Step NBV(MS-NBV)<sup>[5]</sup>,基于下一最佳视点法,通过固定深度采样生成视点,选择视野价值最高的路径,探索整条路径;

2) Receding Horizon NBV(RH-NBV)<sup>[5]</sup>,将滚动优化的思想的与 Multi-Step NBV 结合,每次只前往视野价值最高的路径中的第一个节点;

3) Greedy Frontier-based(GFB)<sup>[4]</sup>,在栅格地图上通过实时边界检测寻找欧式距离最近的边界探索;

4) Hierarchical RRT(H-RRT)<sup>[8]</sup>,用局部和全局两棵随机树引导探索。

实验地图均为  $30 \text{ km} \times 30 \text{ km}$ ,传感器探测半径为  $1 \text{ km}$ ,地图中海流区域和向量用蓝线绘制,所有掉头路径按照转向  $180$  度计算航行成本,克服水流消耗在探索结束后根据路径统计得出。表 2 展示每个算法的统计结果平均值和标准差。

图 10 为仿真的数据分布箱线图,结合表 2 可知,RHTO 的最终路径在海流阻力、转向角度和总距离上有明显优势,且鲁棒性更强,体现了引入全局优化




图9 不同采样策略 RRT 对比实验结果

表1 不同采样方式迭代次数对比实验结果

| 仿真场景 | 随机采样   | 单层循环采样 | 双层循环采样 |
|------|--------|--------|--------|
| 简单地图 | 193±15 | 118±19 | 64±5   |
| 一般地图 | 254±31 | 126±22 | 53±7   |
| 复杂地图 | 235±56 | 210±33 | 110±20 |

的优势. 但当未知区域的障碍物影响了预估的探索路径时, 会出现部分细节遗漏的情况, 因此覆盖率略低于基于边界和基于 NBV 的探索方法, 也因此不容易受“信息诱饵”影响.

如图 11 和图 12 所示的仿真结果中, 各种算法在一般地图均不容易出现回溯, 但是复杂地图中

GFB 和 H-RRT 出现较多回溯, MS-NBV 和 RH-NBV 则在覆盖效率和路径平滑程度上有劣势, 综合来看 RHTO 路径质量最佳, 体现了拓扑学优化和覆盖路径规划的优势.

## 4 结论

本文针对无人船在大范围多未知区域中的探索任务提出了 RHTO 方法, 首先通过使用边界检测和循环采样随机树快速连接各未知区域, 其次通过拓扑学优化快速构建区域间路径网络, 随后根据当前地图信息和评价权重预估最佳探索顺序和覆盖视点, 最后在执行视点探索的过程利用滚动时域的思想根

表2 探索方法对比实验结果

| 场景   | 方法名称   | 克服水流能耗    | 总转向角度/°      | 总距离/km    | 平均覆盖率/% |
|------|--------|-----------|--------------|-----------|---------|
| 一般地图 | RHTO   | -7.35±1.4 | 3614.12±54   | 98.46±12  | 99.44   |
|      | GFB    | -4.43±2.2 | 3996.20±135  | 119.41±31 | 99.61   |
|      | H-RRT  | -0.20±3.2 | 4556.74±221  | 127.25±34 | 98.89   |
|      | MS-NBV | -2.56±3.6 | 8990.92±340  | 150.25±35 | 100.00  |
|      | RH-NBV | -5.91±4.1 | 13459.29±422 | 160.23±41 | 100.00  |
| 复杂地图 | RHTO   | -5.84±3.0 | 5361.57±103  | 113.96±18 | 98.79   |
|      | GFB    | -0.11±6.2 | 5910.18±142  | 179.15±19 | 99.90   |
|      | H-RRT  | -0.73±4.9 | 6880.46±160  | 178.83±19 | 99.73   |
|      | MS-NBV | 0.20±5.3  | 9224.37±199  | 167.27±24 | 99.22   |
|      | RH-NBV | -0.88±4.9 | 12026.03±216 | 182.28±21 | 99.42   |




图10 探索方法对比仿真结果箱线图




图11 一般地图仿真实验结果

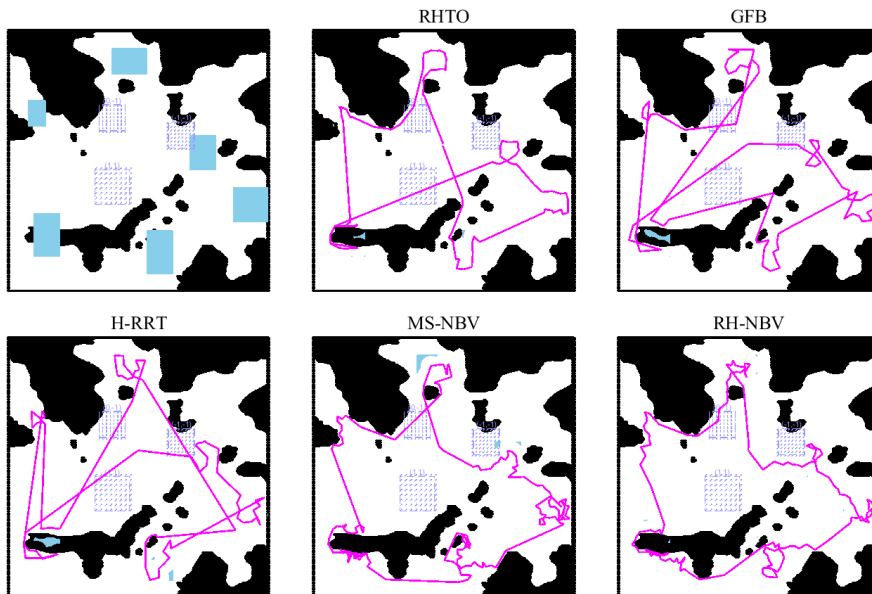


图12 复杂地图仿真实验结果

据当前地图信息和任务进度动态调整代价矩阵和重规划。RHTO 提升了自主探索的前瞻性和鲁棒性,在仿真实验中验证了其在海洋多未知区域探索任务中,路径长度、路径外角和与克服海流阻力能耗三方面优于其他方法。

#### 参考文献 (References)

- [1] Yang G, Huang J, Zhang N, et al. Wind-solar hybrid drive-controlled autonomous ship for exploration based on Raspberry Pi[J]. *Journal of Computer Science and Electrical Engineering*, 2025, 7(6): 22-29.
- [2] Zhang Q F, Liu X, Shao M Z, et al. USVRT-DETR: A transformer-based detector with multi-scale feature fusion and intra-scale interaction for USV surface scenarios[J]. *Ocean Engineering*, 2025, 342: 122926.
- [3] 常路, 单梁, 张伟龙, 等. 未知环境下基于激光雷达的启发式导航算法[J]. *控制与决策*, 2024, 39(9): 2903-2912.  
(Chang L, Shan L, Zhang W L, et al. Heuristic navigation based on LiDAR in unknown environments[J]. *Control and Decision*, 2024, 39(9): 2903-2912.)
- [4] Jin S, Yang S D, Wang H Y, et al. Learning “where to look” for visual exploration of autonomous mobile robot in indoor unknown environments[J]. *Robotica*, 2025, 43(9): 3257-3276.
- [5] Yamauchi B. A frontier-based approach for autonomous exploration[C]. *Proceedings 1997 IEEE International Symposium on Computational Intelligence in Robotics and Automation CIRA'97*. Monterey, 2002: 146-151.
- [6] 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*. Stockholm, 2016: 1462-1468.
- [7] Wang C Q, Ma H, Chen W N, et al. Efficient autonomous exploration with incrementally built topological map in 3-D environments[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(12): 9853-9865.
- [8] Umari H, Mukhopadhyay S. Autonomous robotic exploration based on multiple rapidly-exploring randomized trees[C]. *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems*. Vancouver, 2017: 1396-1402.
- [9] Zhu H B, Cao C, Xia Y K, et al. DSVP: Dual-stage viewpoint planner for rapid exploration by dynamic expansion[C]. *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems*. Prague, 2021: 7623-7630.
- [10] Janoš J, Vonásek V, Pěnička R. Multi-goal path planning using multiple random trees[J]. *IEEE Robotics and Automation Letters*, 2021, 6(2): 4201-4208.
- [11] 齐立哲, 何东东, 陈睿, 等. 基于拓扑地图的移动机器人室内环境高效自主探索算法[J]. *机器人*, 2023, 45(3): 313-320.  
(Qi L Z, He D D, Chen Q, et al. An efficient autonomous exploration algorithm of indoor environment for mobile robots using topological map[J]. *Robot*, 2023, 45(3): 313-320.)
- [12] 陈彦杰, 范俊炜, 张丽萍, 等. 面向未知目标收集的移动机器人规划方法研究[J]. *控制与决策*, 2025, 40(9): 2654-2662.  
(Chen Y J, Fan J W, Zhang L P, et al. Research on mobile robot planning methods for unknown target collection[J]. *Control and Decision*, 2025, 40(9): 2654-2662.)
- [13] Li L, Shi D X, Jin S C, et al. Hierarchy coverage path planning with proactive extremum prevention in unknown environments[J]. *IEEE Robotics and Automation Letters*, 2025, 10(4): 3358-3365.
- [14] 曹路阳, 周乐来, 戴骁蒙, 等. 基于分层边界与可视图的移动机器人自主探索算法[J]. *控制与决策*, 2025, 40(4): 1207-1216.  
(Cao L Y, Zhou L L, Dai X M, et al. An autonomous exploration algorithm of mobile robots based on hierarchical frontier and visibility graph[J]. *Control and Decision*, 2025, 40(4): 1207-1216.)
- [15] 胡耀炜, 汤萍萍, 张晖, 等. 复杂动态环境中移动机器人双层路径规划方法[J]. *控制与决策*, 2025, 40(10): 2995-3004.  
(Hu Y W, Tang P P, Zhang H, et al. Two-layer path planning method for mobile robots in complex and dynamic environments[J]. *Control and Decision*, 2025, 40(10): 2995-3004.)
- [16] Ghadimi E, Feyzmahdavian H R, Johansson M. Global convergence of the Heavy-ball method for convex optimization[C]. *2015 European Control Conference*. Linz, 2015: 310-315.

#### 作者简介

王昱 (1991-), 男, 副教授, 博士, 主要研究方向为无人系统智能控制、先进探测感知, E-mail: [andyu@hhu.edu.cn](mailto:andyu@hhu.edu.cn);

马俨 (2001-), 男, 本科生, 主要研究方向为移动机器人自主导航, E-mail: [mcreepyforreal@outlook.com](mailto:mcreepyforreal@outlook.com);

王冰 (1975-), 男, 教授, 博士, 主要研究方向为新能源控制技术、无人系统控制, E-mail: [icekingking@hhu.edu.cn](mailto:icekingking@hhu.edu.cn).