

控制与决策

Control and Decision

一种基于运动学约束的改进RRT算法

李亦韩, 陈刚, 杨志伟, 赵青松, 倪雨

引用本文:

李亦韩, 陈刚, 杨志伟, 等. 一种基于运动学约束的改进RRT算法[J]. *控制与决策*, 2026, 41(1): 133–142.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0560>

您可能感兴趣的其他文章

Articles you may be interested in

基于视觉引导多AGV系统的改进A*路径规划算法

Improved A* path planning algorithm for vision-guided multi-AGV system

控制与决策. 2021, 36(8): 1881–1890 <https://doi.org/10.13195/j.kzyjc.2019.1670>

车辆跟随控制策略的状态可达集建模及验证方法

A modeling and verification method of state reachable set for vehicle following control strategy

控制与决策. 2021, 36(7): 1679–1685 <https://doi.org/10.13195/j.kzyjc.2019.1562>

基于Frenet坐标系的自动驾驶轨迹规划与优化算法

Trajectory planning and optimization algorithm for automated driving based on Frenet coordinate system

控制与决策. 2021, 36(4): 815–824 <https://doi.org/10.13195/j.kzyjc.2019.0748>

基于MCPDDPG的智能车辆路径规划方法及应用

The method and application of intelligent vehicle path planning based on MCPDDPG

控制与决策. 2021, 36(4): 835–846 <https://doi.org/10.13195/j.kzyjc.2019.0460>

基于混合整数规划的智能网联车冲突区时序优化模型

Mixed integer programming model of scheduling for connected automated vehicles in a conflict zone

控制与决策. 2021, 36(3): 705–710 <https://doi.org/10.13195/j.kzyjc.2019.0886>

一种基于运动学约束的改进 RRT 算法

李亦韩, 陈刚, 杨志伟[†], 赵青松, 倪雨

(国防科技大学 系统工程学院, 长沙 410073)

摘要: 提出一种基于运动学约束和动态优化的改进快速随机搜索树算法 (KD-RRT), 用于解决动态环境下的路径规划问题. 针对传统 RRT 算法在动态环境下存在的随机性高、路径适配性差以及动态响应不足等问题, 引入动态权重目标偏置采样、多因子耦合动态步长调整、运动学约束过滤以及增量式重规划机制, 显著提升了路径规划的效率和路径质量. 实验结果表明, KD-RRT 在路径长度、规划时间、重规划时间和路径曲度等方面均优于传统 RRT 算法, 尤其在复杂动态环境中表现出更强的适应性和鲁棒性. 所提出的算法为智能车辆在动态环境中的自主导航提供了有效的解决方案.

关键词: 路径规划; 快速扩展随机树; 运动学约束; 障碍物避障; 物资运输; 无人车

中图分类号: TP242.6 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.0560

引用格式: 李亦韩, 陈刚, 杨志伟, 等. 一种基于运动学约束的改进 RRT 算法 [J]. 控制与决策, 2026, 41(1): 133-142.

An improved RRT algorithm based on kinematic constraints

LI Yi-han, CHEN Gang, YANG Zhi-wei[†], ZHAO Qing-song, NI Yu

(College of Systems Engineering, National University of Defense Technology, Changsha 410073, China)

Abstract: This paper proposes an improved rapidly-exploring random tree (RRT) algorithm, termed kinetic and dynamic-RRT (KD-RRT), which incorporates kinematic constraints and dynamic optimization to address path planning problems in dynamic environments. In response to the challenges faced by traditional RRT algorithms—namely, high randomness, poor path adaptability, and insufficient responsiveness in dynamic scenarios—the KD-RRT introduces four key mechanisms: dynamic weight target-biased sampling, multi-factor coupled dynamic step-size adjustment, kinematic constraint filtering, and incremental re-planning. These enhancements significantly improve the efficiency and quality of path planning. Experimental results demonstrate that the KD-RRT outperforms the conventional RRT algorithm in terms of path length, planning time, re-planning time, and path curvature. In particular, the proposed method exhibits greater adaptability and robustness in complex dynamic environments. This algorithm thus provides an effective solution for autonomous navigation of intelligent vehicles operating in dynamic settings.

Keywords: path planning; rapidly-exploring random tree; kinematic constraints; obstacle avoidance; material transportation; unmanned vehicle

0 引言

在突发性城市公共事件中, 提升应急物资配送效率是减少人员伤亡与经济损失的关键策略之一^[1]. 地震发生后的黄金救援期内, 受损道路、临时障碍物、不断变化的地形以及通讯中断等问题, 对路径规划提出了极为严苛的实时性与可靠性要求. 为确保救援车辆能够快速、安全且有效地将急需物资送达指定地点, 亟待构建具备动态响应能力、运动学约束适应性以及环境适应能力的路径规划系统. 路径规

划技术的核心在于通过建模灾区地形与避障规则, 为救援车辆 (如无人运输车) 生成从起点 (如临时物资仓库) 至目标点 (如灾区中心、救援点) 的最优运输路线.

当前路径规划技术体系主要由全局路径规划和局部路径规划两大层级架构组成^[2]. 全局路径规划侧重于在完全已知的环境中, 依据先验地图数据与多目标优化准则 (如最短路径、最低能耗等), 为移动机器人构建理论最优的全局导航基准. 该层级采用

收稿日期: 2025-05-29; 录用日期: 2025-09-30.

基金项目: 湖南省自然科学基金项目 (2023JJ30641).

责任编辑: 陈家伟.

[†]通信作者. E-mail: zhwyang88@hotmail.com.

离线计算模式,其算法体系涵盖基于图搜索的确定性算法、基于概率采样的随机规划算法以及基于机器学习的环境理解与决策算法^[3].局部路径规划则作为动态环境下的实时导航策略,借助在线环境感知系统获取局部空间信息,赋予移动机器人即时避障与轨迹修正能力^[4].此反应式规划不依赖完整先验地图,而是基于传感器数据流进行在线决策,展现出更强的环境适应性和动态响应特性.全局规划与局部规划的协同作用构成了完整的自主导航系统,全局规划提供战略级路径基准,局部规划执行战术级运动控制.

全局规划通过先验环境建模构建完整的路径拓扑结构,能够在系统初始阶段确立满足运动学约束与任务目标的可行解空间,从而避免局部规划在未知环境中可能出现的路径不可达风险.传统的图搜索算法为静态路径规划,在模型、环境一致的情况下,只能规划出单一路径,在面对环境变化进行重规划时会出现路径冲突^[5].近些年来,蒙特卡洛树搜索(MCTS)^[6]、快速搜索随机树(RRT)^[7]和概率路线图(PRM)^[8]等采样方法在路径规划中得到了广泛应用.基于采样的随机搜索技术是全局路径规划算法中的一种重要方法,通过在规划空间内随机采样,可以快速获取大量可能的路径,从而加速路径规划的过程,同时满足多设备情况下的路径规划需求.

目前,国内外学者在RRT算法的基础上进行了大量研究.例如:Karaman等^[9]提出了RRT*算法,突破了传统RRT仅能保证可行解的局限,使采样规划具备逼近最优路径的能力;Gammell等^[10]在此基础上提出了Informed RRT*,通过椭圆启发式采样在搜索空间中集中采样,提高了收敛速度;Wang等^[11]提出了一种改进的双树障碍边缘搜索人工势场RRT*算法(IBPF-RRT*),通过障碍边缘搜索人工势场策略(ESAPF)加快路径搜索速度,并结合双向剪枝策略显著减少迭代次数,优化路径质量;陈志澜等^[12]提出了一种动态步长策略和采样优化方法融合改进RRT-Connect,提升了RRT算法在密集障碍物区域的通过性;陈丹等^[13]结合概率人工势场法产生启发式采样,使采样点更具目标导向性,并使用冗余节点删除策略剔除路径中的冗余节点来优化最终路径;Hong等^[14]提出了一种结合蚁群优化和RRT*的混合算法,降低了计算成本并提高了路径质量;李阿辉等^[15]提出了一种基于凸剖分知情采样的最优路径规划算法CDI-RRT*,通过构建动态采样域优化了初始树,有效提升了算法的求解效率;Langari等^[16]提出了一种非均匀RRT算法,通过引入启发式规则来引

导树的扩展,以提高路径规划的效率.

针对传统RRT算法在动态环境下存在随机性高、路径适配性差以及动态响应不足等问题,本文提出一种融合运动学约束与动态优化的改进RRT算法(KD-RRT).主要研究工作包括以下4个方面:

1) 动态权重目标偏置采样机制.采用分段自适应目标引导策略,通过动态调整目标方向与随机采样的权重比例,巧妙平衡全局探索与收敛效率.相较于固定概率偏置方法,此策略在迭代初期强化随机探索,有效规避局部最优困境;后期则增强目标导向,加速收敛进程,进而减少无效节点扩展.

2) 多因子耦合动态步长模型.设计基于目标距离、障碍物间距以及搜索进程的多因子步长调整函数,实现步长的自适应调节.在开阔区域采用大步长提升搜索效率,在狭窄区域切换为小步长保障避障精度,同时通过搜索进展因子抑制后期路径震荡.

3) 运动学约束驱动的路径过滤机制.建立车辆运动学验证流程,将路径曲率限制与转向角约束嵌入节点扩展过程,强制生成路径满足车辆最小转弯半径要求.通过离散曲率计算与碰撞检测联合验证,避免了传统算法因忽略运动学限制导致的路径不可行问题.

4) 增量式重规划策略.针对动态障碍物干扰,提出基于局部剪枝的增量更新方法.通过保留有效路径段并仅重构受障碍影响区域,避免全局搜索树重建,显著降低重规划耗时,实现复杂场景下的实时避障响应.

本文提出的改进措施通过算法流程整合,在路径质量、规划效率和动态适应性层面形成协同优化,为地震救灾等动态场景中的自主导航提供理论支持与技术保障.

1 基于运动学约束的动态环境路径规划

1.1 问题描述

基于运动学约束的动态环境路径规划问题是指在动态变化的环境中,智能体考虑自身运动学限制,搜索并优化一条从起始状态到目标状态的安全可行路径,同时避免与动态障碍物发生碰撞,可视化展示如图1所示.此问题的核心挑战在于如何在高维状态空间中高效处理环境不确定性、运动学约束以及规划路线与路线调整之间的复杂关系,从而确保智能体在动态环境中的自主导航能力.

设环境信息为 $E(x, y)$,障碍物信息为 $O(i)$,智能体的状态为 $N(t) = [p(t), \theta(t)]$, $p(t)$ 为智能体当前点的位置信息, $\theta(t)$ 为方向角信息,系统的运动学

约束为 C . 设起始状态为 q_{start} , 终止状态为 q_{goal} , 规划目标是找到一条满足 C 的可行轨迹 $\tau(t)$, 使 $\tau(t) = N(t)$ 满足任意 $N(t)$ 不与 $O(i)$ 发生碰撞, 且在障碍物信息更新后能及时给出被影响路线的新路线.




图1 动态环境路径规划问题

1.2 运动学模型

在路径规划中, 车辆运动学模型通常用于描述和预测车辆在行驶过程中的动态行为, 通过构建车辆运动学模型, 可以更好地理解车辆的运动特性, 从而使路径规划更加精确可靠. 运动学模型主要研究车辆在时间上的位移等动力学参数的变化趋势. 此类模型大多建立在牛顿运动定律的基础之上, 综合考虑车辆的几何特性及其在运动过程中需遵循的各类约束条件. 约束条件包括车辆的起始和终止位置设定、速度的最大与最小限制范围以及加速度的限制要求等. 基于本文研究做出如下定义与假设.

定义 1 最大转向角. 车辆具有长度和转弯半径, 在有限空间内可进行转向的范围有限, 最大的转向角度即为最大转向角.

定义 2 碰撞. 车辆具有一定尺寸, 不可视为质点, 故与障碍之间可能存在位置上的重叠, 即为碰撞.

假设 1 车辆是一个刚性系统.

假设 2 车辆的转向功能主要是通过前轮的驱动和引导实现的.

假设 3 车辆在地面上进行匀速运动, 且不考虑小范围内的加速度, 即认为车辆速度的改变为瞬时变化.

假设 4 车辆在前进过程中不会发生侧向位移.

假设 5 地图单元尺寸远大于车身宽度, 故不考虑车身宽度的限制.

假设 6 在极短时间 Δt 内, 车辆速度与车身方向一致.

基于上述假设与实际需求, 本文选取单车模型对车辆模型进行简化, 以期得到符合车辆转向限制的可行路径. 单车模型是一种常见的车辆运动学模型, 能够相对真实直观地反映车辆平面运动特性^[17]. 在此模型中, 车辆被视为在平面上运动的、由硬杆连接的两个车轮, 车辆模型简化如图 2 所示. 图 2 中

L 为车身长度, R 为转弯半径, δ 为转向角. k 为转弯弧度曲率, 其关系为

$$k_{\text{max}} = \frac{\tan(\delta_{\text{max}})}{L} = \frac{1}{R_{\text{min}}}. \quad (1)$$

其中: k_{max} 为最大曲率, R_{min} 为最小转弯半径.




图2 车辆运动学模型

在路径规划过程中, 可限制目标曲率 k 在区间 $[-k_{\text{max}}, k_{\text{max}}]$ 内, 应用场景如图 3 所示. 设起点为 S , 目标点为 N , 二者直线距离为 D , 目标偏向角为 φ , 可得目标曲率为

$$k = \frac{2\sin\varphi}{D}. \quad (2)$$




图3 转向约束

曲度 k_s 为路径局部弯曲程度的度量, 定义为路径切线方向的变化率. 对于二维平面中的路径, 曲度可以通过下式计算:

$$k_s = \frac{|\dot{x}\ddot{y} - \ddot{x}y|}{(\dot{x}^2 + \dot{y}^2)^{\frac{3}{2}}}. \quad (3)$$

其中: \dot{x} 和 \dot{y} 为路径在 x 和 y 方向的一阶导数(速度), \ddot{x} 和 \ddot{y} 为路径在 x 和 y 方向的二阶导数(加速度), 在离散路径可使用有限差分法计算.

2 改进的RRT算法

2.1 RRT算法流程

RRT算法是一种使用增长树的随机采样搜索算法^[18]. 此算法基于随机采样进行路径规划, 其目的是尽可能快速地找到一条从起点到终点的可行路径, 其搜索过程类似于一棵树不断生长、向四周扩散的过程, 以起点作为根节点构建一棵搜索树, 在空间中随机采样, 并找到搜索树上与采样点最接近且能与其无障碍连接的点, 连接此点与采样点, 将采样点加入搜索树, 直至终点附近区域被探索到. 算法的基本流程如下:

step 1: 初始化. 以起点 N_{start} 作为搜索树 T 的根节点.

step 2: 随机采样. 在状态空间中随机生成采样点 N_{rand} .

step 3: 临近点选择. 选取距离随机点最近的树节点 N_{near} .

step 4: 树扩展阶段. 从 N_{near} 向 N_{rand} 方向扩展一个固定步长 d_s , 生成新节点 N_{new} , 检查路径是否与障碍物发生碰撞. 若无碰撞, 则将点 N_{new} 加入搜索树 T .

step 5: 终止条件. 若 N_{new} 接近目标点 N_{goal} , 则算法终止并返回路径, 否则重复上述步骤.

尽管 RRT 算法具有概率完备性, 但其随机性高、路径质量差且动态响应能力不足, 难以满足复杂动态环境的需求.

2.2 算法流程改进

2.2.1 动态权重目标偏置采样

原始 RRT 算法的采样策略为采样空间内随机采样, 虽然可以发现更多路径, 但是大大降低了效率, 因此可以通过采取其他的采样方式提高效率. 本文引入一种基于目标点方向的采样策略. 在传统的随机采样方法中, 采样点均匀随机分布在状态空间中, 而本文通过引入目标点方向信息^[19], 使得采样点更有可能朝向目标点, 以加速路径规划过程.

一种比较易得的采样方式为目标引导采样, 即在每次采样时, 以一定的概率选择朝向目标点的方向进行采样, 并以另外的概率进行随机采样, 以确保搜索的全局性^[20]. 此方式虽然可以较大程度地加快路径规划的效率, 但是对环境的探索程度较低, 容易陷入局部最优解. 本文引入混合采样策略, 通过加权的方式结合传统的均匀随机采样与目标引导采样, 并通过自适应调整目标方向权重以平衡探索性与收敛性, 具体示例如图 4 所示. 加权采样公式如下:

$$N_{sample} = w_1 N_{goal} + w_2 N_{rand}. \quad (4)$$

其中: N_{rand} 与 N_{goal} 分别为随机点与目标点的坐标, 通过加权, 生成采样点 N_{sample} , w_1 与 w_2 为随机权重与目标权重. 权重随迭代进程动态调整, 且满足

$$w_1 + w_2 = 1. \quad (5)$$

权重更新采用分段函数策略, 设最大迭代次数为 T_{max} , 分段点为 $T_{threshold}$, 权重增长系数为 α , 则有

$$w_1 = \begin{cases} w_{min} + \alpha \frac{t}{T_{max}}, & t \leq T_{threshold}; \\ w_{max}, & \text{otherwise.} \end{cases} \quad (6)$$

在实际采样时, 以概率 $p \in [0, 1]$ 进行完全随机采样, 生成状态空间中均匀分布的采样点, 以概率

$1 - p$ 进行加权采样.




图4 加权目标偏置采样

2.2.2 动态步长调整

在传统 RRT 算法中, 路径规划通常采用固定步长进行节点扩展, 虽然简单易实现, 但在实际应用中存在路径粗糙的问题, 路径的局部细节难以精确刻画, 可能导致路径不平滑或避障失败. 本文使用一种动态步长调整策略, 通过自适应调整步长以平衡全局搜索效率与局部路径精度, 通过综合多种关键因素动态调整扩展步长, 包括当前节点到目标点的距离、与最近障碍物的距离以及搜索进展. 扩展步长计算公式如下:

$$d = \min(d_{max}, \alpha d_{goal} + \beta d_{obstacle} + \gamma S_p). \quad (7)$$

d_{goal} 为目标点距离因子, 使用 α 作为权重系数, 用于衡量当前节点与目标点之间的欧氏距离. 其设计目的是引导算法在远离目标点时采用较大步长, 以加速搜索进程; 而在接近目标点时, 逐步减小步长以提高路径的精确性. 其计算公式为

$$d_{goal} = \|N_{current} - N_{goal}\|. \quad (8)$$

$d_{obstacle}$ 为障碍物距离因子, 使用 β 作为权重系数, 用于评估当前节点与最近障碍物之间的最短距离. 其设计目的是在远离障碍物时采用较大步长以提升搜索效率; 而在接近障碍物时, 减小步长以避免碰撞并提高路径的安全性. 设 E 表示环境中所有障碍物的集合, 其计算公式为

$$d_{obstacle} = \min_{ob \in E} \|N_{current} - ob\|. \quad (9)$$

S_p 为搜索进展因子, 使用 γ 作为权重系数, 用于量化算法的搜索进程. 其设计目的是在搜索初期采用较大步长以快速探索未知空间; 而在搜索后期逐步减小步长以优化路径精度. 其计算公式为

$$S_p = 1 - \frac{t}{T_{max}}. \quad (10)$$

2.2.3 运动学约束过滤

为了使所规划的路径能够更好地符合实际环境, 本文在设计采样空间时, 加入车辆的运动学约束, 即确定车辆在当前环境中可以执行的运动学状态. 然后, 根据所确定的状态限制采样点的选取, 所设计的

采样空间可以有效避免生成的路径超出车辆能够实际执行的范围. 在 RRT 算法中, 状态扩展主要依赖于当前节点向新采样点延伸边缘的过程. 在改进后的算法中, 状态扩展环节还增加了额外的运动学约束验证步骤, 从而确保新生成的状态能够符合运动学约束的限制条件. 具体验证步骤如下:

step 1: 计算转向角. 对于扩展的新状态, 首先计算从当前状态到新状态的距离, 然后根据式 (2) 计算对应的目标曲率大小.

step 2: 验证运动学限制. 将计算得出的目标曲率与车辆实际能够执行的最大曲率进行对比, 若计算出的目标曲率超出车辆实际可执行的最大曲率范围, 则表明该状态未能满足运动学约束的限制条件, 需进行相应的修正或予以舍弃.

2.2.4 增量式重规划

在传统 RRT 算法的规划过程中, 障碍物通常被视为固定不动的静态实体. 在动态环境中, 障碍物可能会呈现移动或即时生成的状态, 故要求车辆必须不断地调整路径以应对障碍物的变化. 为此本文引入一种动态路径更新机制, 根据实时更新的障碍物信息, 及时调整车辆路径, 以确保车辆能够在动态环境中安全行驶.

增量式重规划机制的核心思想是在保留原路径部分节点或路径段的基础上, 仅对受动态障碍物影响的部分路径进行局部调整, 从而避免完全重新生成整条路径. 具体步骤如下:

step 1: 当检测到动态障碍物时, 首先判断当前路径是否与障碍物发生冲突. 若存在冲突, 则标记受影响的路径段及节点.

step 2: 通过剪枝, 修剪掉失效的节点与边, 同时剪去与搜索树断开的子树, 确保搜索树与起点的连通性.

step 3: 在修剪后的搜索树基础上重新规划断开点到终点的可行路径.

2.3 改进 RRT 算法步骤

通过将上述改进措施结合到 RRT 算法中, 本文提出一种 KD-RRT 算法, 即基于运动学约束的改进动态 RRT 算法, 其步骤及伪代码如下:

step 1: 初始化. 定义算法的全局参数, 包括车辆运动学约束、搜索步长权重、目标偏置权重和最大迭代次数. 这些参数为计算和优化提供基础, 影响路径质量和效率.

step 2: 加权采样. 基于目标与随机点进行加权生成采样点, 并动态调整目标域随机点的权重.

step 3: 临近点选择. 选取距离随机点最近的树节点, 并进行运动学检测.

step 4: 树扩展阶段. 临近点和随机点生成扩展点, 若无碰撞, 则连接扩展点与临近点, 扩展搜索树.

step 5: 环境更新. 若存在新障碍物, 则检测新障碍物与搜索树冲突, 删除冲突点和边, 判断是否存在可行路径; 若原路径未受到影响, 则算法终止.

step 6: 重规划. 若原路径被截断, 则继续迭代, 采用增量式重规划, 在保留原有部分搜索树的基础上, 重新规划路径.

Algorithm 1 KD-RRT.

```

1) 定义全局参数: 车辆运动学约束、搜索步长权重、目标偏置权重、最大迭代次数
2)  $T \leftarrow$  初始化搜索树
3)  $goal\_found \leftarrow$  False
4) while  $t < T_{max}$  and  $goal\_found ==$  False do
5)  $x_{rand} \leftarrow$  混合采样策略采样
6) 动态调整目标与随机点的权重
7)  $x_{near} \leftarrow$  选取距离  $x_{rand}$  最近的树节点
8)  $x_{new} \leftarrow$  生成扩展点 ( $x_{near}, x_{rand}$ )
9) if 无碰撞( $x_{new}$ ) and 运动学检测通过 then
10) 连接  $x_{new}$  与  $x_{near}$ , 扩展搜索树  $T$ 
11) if  $x_{new}$  接近目标点 then
12)  $goal\_found \leftarrow$  True
13) end if
14) end if
15) if 存在新障碍物 then
16) 检测新障碍物与搜索树  $T$  的冲突
17) 删除冲突点和边
18) if 原路径未受到影响 then
19) 算法终止
20) end if
21) end if
22) if 原路径被截断 then
23) 继续迭代, 采用增量式重规划
24) 在保留原有部分搜索树基础上, 重新规划路径
25) end if
26) end while
27) if  $goal\_found ==$  True then
28) return 可行路径
29) else
30) return 无可行路径
31) end if

```

2.4 算法时空复杂度分析

为了评估所提出算法的计算开销与存储需求, 本文从理论角度分析其时间复杂度与空间复杂度.

2.4.1 时间复杂度分析

本文算法的主要运行流程包括随机采样、最近邻搜索、扩展与碰撞检测以及(若触发)重规划操作。

1) 随机采样. 在配置空间中生成一个随机点, 复杂度为 $O(1)$.

2) 最近邻搜索. 在已有 n 个树节点中寻找与采样点最近的节点. 若采用朴素线性搜索, 则复杂度为 $O(n)$; 若使用 KD-Tree 等数据结构, 则复杂度可降至 $O(\log_2 n)$.

3) 扩展与碰撞检测. 对路径段进行离散化并检测与障碍物的交互, 设障碍物数为 m , 则单次检测复杂度约为 $O(m)$.

4) 重规划. 当环境发生变化时, 需要更新部分树结构, 其复杂度与节点数相关, 通常为 $O(n)$.

综上所述, 在树节点数量为 n 、障碍物数量为 m 时, 算法的平均时间复杂度可表示为

$$T(n, m) = O(n(m + \log_2 n)). \quad (11)$$

本文所提出的动态步长调节和分段自适应权重等策略引入了额外计算, 但仅增加了常数级开销, 不改变整体复杂度阶数。

2.4.2 空间复杂度分析

本文算法的存储需求主要来自以下几个方面:

1) 树节点存储. 每个节点需保存位置、父节点指针以及路径代价等信息. 若状态空间维度为 e , 则空间复杂度为 $O(ne)$.

2) 辅助数据结构. 若采用 KD-Tree 等结构加速最近邻搜索, 则需额外复杂度 $O(n)$ 的空间。

3) 参数与缓存. 动态步长和自适应权重引入的参数量级为常数, 重规划缓存与边信息存储复杂度均为 $O(n)$.

综上, 算法的整体空间复杂度可表示为

$$S(n, e) = O(ne). \quad (12)$$

综上所述, 本文所提出算法的时间复杂度主要受树节点数与障碍物规模影响, 平均时间复杂度为 $O(n(m + \log_2 n))$; 空间复杂度主要由状态空间维度与节点数决定, 为 $O(ne)$. 与基础 RRT 算法相比, 所提出方法在复杂度阶数上保持一致, 仅在常数因子有所增加, 仍具备良好的可扩展性与工程可行性。

3 算例分析

3.1 实验环境与参数设置

为了验证改进算法的有效性, 本文在相同实验条件下对基础 RRT 算法、目标引导 RRT 算法、动态 RRT 算法以及本文提出的 KD-RRT 算法进行对比测试. 由于算法具有随机性, 所有算法均在同一张

地图上各运行 200 次, 对比指标取平均值. 对比指标包括路径长度、规划时间、重规划时间和路径曲度。

实验的路径规划环境设置为不同尺寸的矩形区域, 分别为 20×20 、 100×100 、 500×500 , 区域内随机分布静态障碍物, 并另设 1 组 100×100 密集障碍物地图. 在规划完成后, 随机选取规划路径上的节点插入一个固定半径的障碍物对原路径进行截断, 以模拟动态环境。

算法参数设置依据前期预实验优化结果: 迭代次数为 5000 次, 基础步长设为 1、3、5(平衡搜索效率与路径分辨率), 目标引导初始权重为 0.3, 最大值设置为 0.9, 步长因子 $(\alpha, \beta, \gamma) = (0.4, 0.4, 0.2)$. 运动学约束参数基于无人车模型: 最小转弯半径 0.6 m, 车身长度 0.4 m.

仿真实验软硬件配置为: 操作系统 Windows 11, CPU Intel(R) Core(TM) i7-14650HX, 主频 2.20 GHz, 内存 32 GB, 编程语言 Python.

3.2 对比算法与评价指标

对比算法包括:

1) 基础 RRT 算法, 采样策略使用随机采样, 无运动学约束与动态规划机制。

2) 目标引导 RRT 算法 (GRRT), 仅加入目标方向概率引导采样策略的 RRT 算法。

3) 动态 RRT 算法 (DRRT), 采取增量式重规划的动态 RRT 算法。

4) Informed RRT 算法 (InfoRRT), 采取椭圆区域采样的 RRT 算法。

5) KD-RRT 算法, 本文提出的融合引导采样、运动学约束与增量式重规划算法。

评价指标包括:

1) 路径长度, 规划路径的欧氏距离累计值。

2) 规划时间, 首次规划完成耗时。

3) 动态环境重规划时间, 动态障碍物触发重规划后规划完成的耗时。

4) 路径曲度 (路径平滑性), 通过离散点曲率均值、最大值以及标准差评估平滑性。

5) 失败率, 路径规划失败次数占比。

3.3 实验结果与分析

实验结果如表 1 所示。

1) 20×20 地图实验结果。

在 20×20 小规模地图中, 由于地图规模较小, 在路径长度上差异不大, 但综合分析可知: KD-RRT 算法的整体性能最优. 其路径长度为 31.6746 m, 相较于传统 RRT 缩短约 3.73%; 规划时间为 0.0661 s,

表1 多规模地图实验结果对比 (200 轮均值)

规模	算法	对比指标						
		路径长度 / m	规划时间 / s	重规划时间 / s	平均曲度	最大曲度	曲度标准差	失败率 / %
20 × 20	RRT	32.9026	0.0968	0.3647	0.2300	0.3713	0.0477	0
	GRRT	31.5661	0.0586	0.0547	0.1801	0.2720	0.0548	0
	DRRT	33.7062	0.0881	0.5027	0.2331	0.3795	0.0427	0
	InfoRRT	32.5492	0.1409	0.4215	0.2430	0.3351	0.1330	0
	KD-RRT	31.6746	0.0661	0.0531	0.0865	0.1751	0.0369	0
100 × 100	RRT	171.7940	3.7626	3.5122	0.1814	0.2165	0.0161	3
	GRRT	156.2666	0.2447	0.2368	0.1291	0.1684	0.0164	0
	DRRT	170.5799	3.8698	5.9614	0.1859	0.2249	0.0155	2
	InfoRRT	156.9787	0.9906	0.9624	0.1593	0.2017	0.0159	0
	KD-RRT	155.3969	0.1795	0.1373	0.0892	0.1278	0.0146	0
100 × 100 密集障碍物	RRT	176.0114	4.3595	4.1204	0.2635	0.3076	0.0189	9
	GRRT	161.9252	0.4360	0.4513	0.2046	0.2594	0.0219	1
	DRRT	176.2712	5.0290	9.4576	0.2679	0.3066	0.0179	7
	InfoRRT	162.3901	1.3479	0.9949	0.1747	0.2242	0.0182	1
	KD-RRT	159.8906	0.3860	0.2367	0.1115	0.1387	0.0131	0
500 × 500	RRT	852.2261	47.1030	50.1975	0.1623	0.2124	0.0156	37
	GRRT	782.8991	3.0445	2.3997	0.1201	0.1634	0.0115	6
	DRRT	853.5416	47.5172	36.8092	0.1668	0.2231	0.0154	34
	InfoRRT	802.5708	2.1260	1.1245	0.1434	0.1874	0.0165	11
	KD-RRT	778.0623	1.3479	0.9949	0.1152	0.1402	0.0107	1

与 GRRT 相近 (GRRT 直接采样目标点, 因此在小规模地图中收敛速度快); 重规划时间为 0.0531 s, 显著优于 DRRT(0.5027 s), 提升幅度超过 89%。在路径平滑性方面, KD-RRT 的平均曲度 (0.0865)、最大曲度 (0.1751) 以及曲度标准差 (0.0369) 均为最优, 表明其路径不仅更短, 且更为平滑和稳定。

2) 100 × 100 地图实验结果。

在 100 × 100 地图中, KD-RRT 同样展现出其优势。其路径长度为 155.3969 m, 相较于传统 RRT 缩短 9.54%; 规划时间仅 0.1795 s, 远低于 RRT(3.7626 s) 和 DRRT(3.8698 s); 重规划时间为 0.1673 s, 相较于 DRRT(5.9614 s) 提升超过 97%。与改进采样方式的

两种 RRT 算法相比, KD-RRT 在规划时间和路径长度上均取得了一定优势。在曲度指标方面, KD-RRT 的平均曲度 (0.0692)、最大曲度 (0.1078) 和标准差 (0.0146) 均为最优, 表明其路径不仅最短, 而且平滑性和一致性均表现最佳。算法规划路径对比如图 5 所示。

3) 100 × 100 障碍物密集地图实验结果。

在障碍物密集场景下, KD-RRT 的表现尤为突出。其路径长度为 159.8906 m, 相较于传统 RRT 缩短 9.18%; 规划时间为 0.3860 s, 远低于 RRT(4.3595 s) 和 DRRT(5.0290 s); 重规划时间为 0.3367 s, 相较于 DRRT(9.4576 s) 提升超过 96%。与 GRRT、InfoRRT

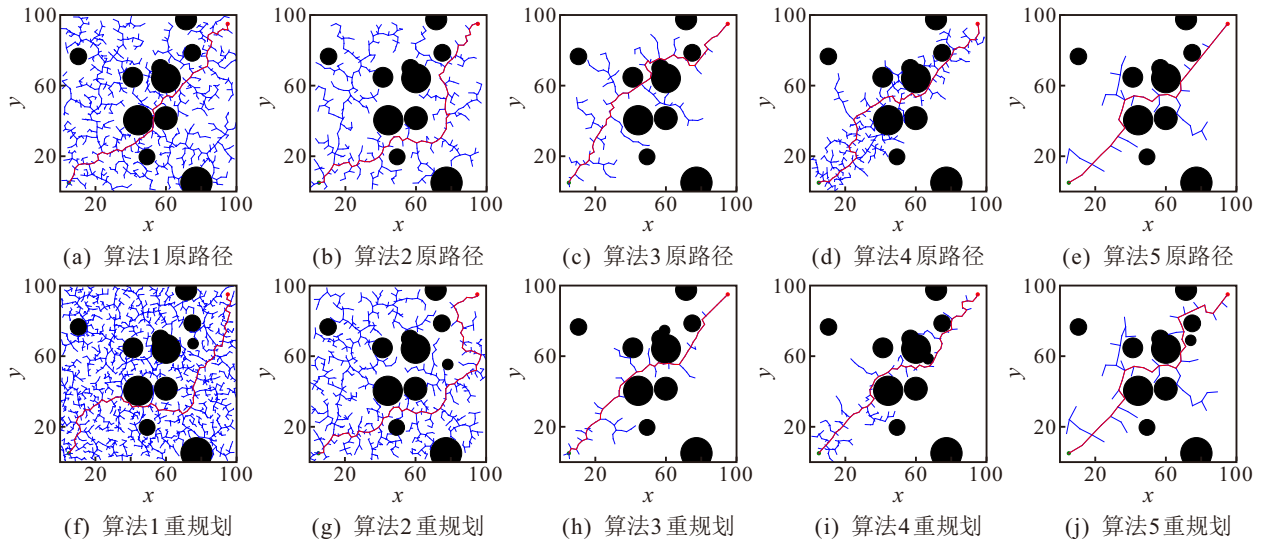


图5 100 × 100 地图实验结果路径展示

对比可见, KD-RRT 算法有效改善了引导信息单一导致的采样频繁失败问题. 在曲度方面, KD-RRT 的平均曲度 (0.1115)、最大曲度 (0.1387)、标准差 (0.0131) 均优于其他算法, 表现出对复杂环境的强适应性和路径稳定性.

4) 500 × 500 地图实验结果.

在大规模地图中, KD-RRT 保持显著优势. 其路径长度为 778.0623 m, 相较于 RRT 缩短 8.70%; 规划时间为 2.1260 s, 远低于 RRT (47.1030 s) 和 DRRT (47.5172 s); 重规划时间为 1.1245 s, 相较于 DRRT (36.8092 s) 提升超过 96%. 在曲度指标上, KD-RRT

的平均曲度 (0.1152)、最大曲度 (0.1602) 和标准差 (0.0267) 均处于最优水平. KD-RRT 算法在大规模地图上的失败率显著低于其他传统 RRT 算法, 表明其在大规模环境下依旧能保持路径的平滑与鲁棒性.

5) 典型场景下的路径对比.

为了对比本文所提出 KD-RRT 算法在实际情况下的路径规划能力, 选取随机走廊地图与仓库地图 2 种实际场景进行对比实验, 最终路径对比如图 6 所示. 由图 6 可见, 本文所提出的改进算法在路径质量和节点扩展数量上明显优于其他传统算法, 实际规划时间相较传统 RRT 算法缩短 2 个数量级.

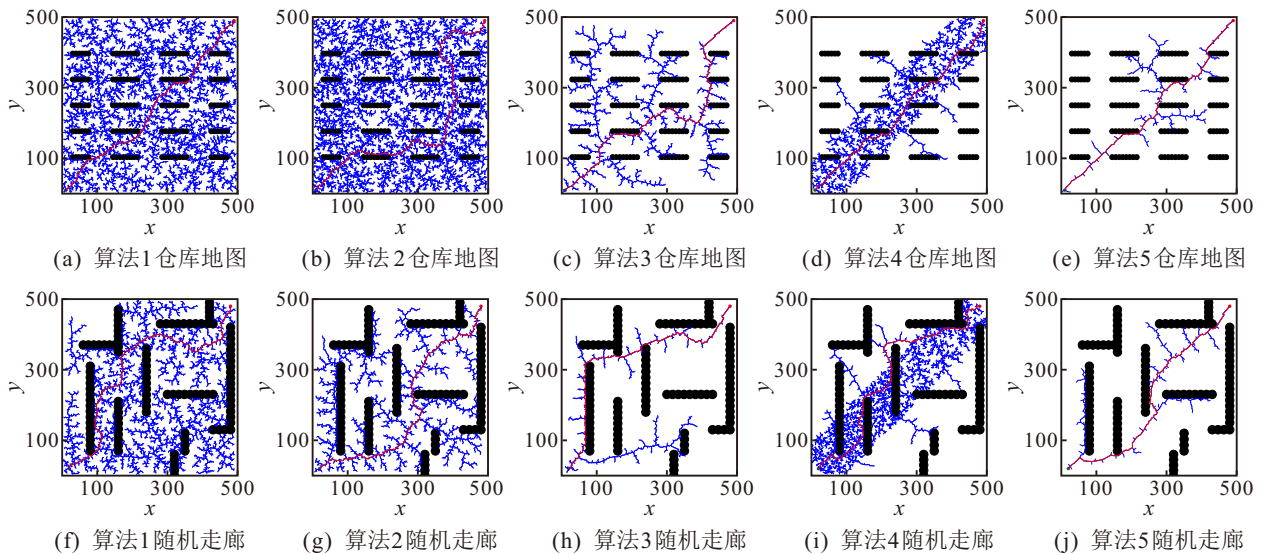


图6 典型地图实验结果路径展示

3.4 参数敏感性分析

为了评估所提出算法对关键参数设置的敏感性, 本文在 100×100 随机障碍物地图环境下, 对目标偏置采样权重参数 ω_{\min} 、 ω_{\max} 以及分段自适应步长权重参数 α 、 β 、 γ 进行灵敏度测试. 测试过程采用单因素控制方法: 在测试采样参数时, 固定步长参数; 在测试步长参数时, 固定采样参数. 具体设置为: ω_{\min} 取 0.1、0.2、0.3、0.4, ω_{\max} 取 0.5、0.9, 并且额外设置 1 组 $\omega_{\min} = 0$ 、 $\omega_{\max} = 1$ 的特殊情况, 共 9 组组合, 实验结果如图 7(a) 和图 7(b) 所示; 步长权重参数 α 、 β 、 γ 则选取 (0.4, 0.4, 0.2)、(0.2, 0.4, 0.4)、(0.4, 0.2, 0.4)、(0.6, 0.2, 0.2)、(0.2, 0.6, 0.2)、(0.2, 0.2, 0.6)、(0.3, 0.3, 0.3) 等 7 组进行对比, 实验结果如图 7(c) 和图 7(d) 所示. 以图 7(a) 第 1 组参数为例, 横坐标 0109_040402 表示 ω_{\min} 取 0.1, ω_{\max} 取 0.9, $\alpha = 0.4$, $\beta = 0.4$, $\gamma = 0.2$. 具体实验对比结果如图 7 所示, 结果表明本文基准参数配置在综合性能上最优, 能够在路径质量与计算效率之间实现较好的平衡.

4 结论

本文针对动态环境下的路径规划问题, 提出了一种基于运动学约束的改进 RRT 算法 (KD-RRT). 通过引入动态权重目标偏置采样、多因子耦合动态步长调整、运动学约束过滤和增量式重规划机制, 使算法在路径长度、规划时间、重规划时间和路径曲度等方面均取得了显著的改进. 通过仿真实验验证了 KD-RRT 在不同尺寸地图 (20×20 、 100×100 、 500×500) 和不同障碍物密度的环境中均表现出优异的性能. 与基础 RRT 算法相比, 在路径长度、规划时间、路径曲度指标以及成功率方面均有显著优势. 此外, KD-RRT 在动态障碍物干扰下能够快速响应, 生成替代路径, 显著提高了路径规划的适应性和鲁棒性.

尽管 KD-RRT 在动态环境下的路径规划中表现出色, 但仍存在进一步改进的空间. 未来的研究可从以下几个方面开展:

1) 多模式动态障碍物. 目前动态环境的表现形式仅为插入障碍物, 并不能很好地模拟实际工况中




图7 参数敏感性分析结果

的障碍物运动情况.一方面,当障碍物发生位置或密度变化时,既有路径可能失效,算法必须进行部分或全局重规划,从而增加额外的计算开销;另一方面,动态环境会打断树的逐步扩展过程,导致算法的收敛速度明显减缓.未来可考虑加入移动障碍物,如随机游走或固定路线移动,使测试环境更贴近实际场景,以更好地验证算法性能.

2) 多模态约束融合.目前的地图建模大多停留在二维平面层面,路径规划过程中未能充分体现真实环境中的多样化约束条件,如能耗消耗、地形坡度和环境障碍物特征等.其导致规划结果与实际应用场景之间存在差距.未来研究可尝试引入多模态约束融合方法,将能耗模型、动力学特性以及坡度、摩擦系数等环境要素统一纳入约束框架.

3) 三维空间扩展.现有 KD-RRT 算法主要应用于二维场景,难以满足无人机和水下机器人等三维运动载体的路径规划需求.三维空间扩展不仅涉及路径节点的三维坐标生成与碰撞检测,还需考虑空间障碍物建模与复杂动力学约束的耦合问题.未来研究可在 KD-RRT 框架下设计高效的三维采样策略和空间约束检测机制,并结合能量消耗与安全飞行走廊等约束条件,实现真正意义上的三维路径优化.

参考文献 (References)

- [1] 于彦鹏, 余墨多, 汤奇荣, 等. 面向城市应急物资配送的多无人机协同路径规划算法[J]. 控制与决策, 2025, 40(4): 1098-1106.
(Yu Y P, Yu M D, Tang Q R, et al. Multi-UAV cooperative path planning algorithm for urban emergency material distribution[J]. Control and Decision, 2025, 40(4): 1098-1106.)
- [2] 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.)
- [3] 赵永昊. 基于人工智能算法的物流工程路径规划与调度优化[J]. 中国科技期刊数据库: 工业 A, 2023(7): 17-20.
(Zhao Y H. Path planning and scheduling optimization of logistics engineering based on artificial intelligence algorithm[J]. China Science and Technology Journal Database: Industrial A, 2023(7): 17-20.)
- [4] Huang H Y, Liu Y C, Liu J X, et al. General optimal trajectory planning: Enabling autonomous vehicles with the principle of least action[J]. Engineering, 2024, 33: 63-76.

- [5] 黄鲁, 周非同. 基于路径优化 D*Lite 算法的机器人路径规划[J]. 控制与决策, 2020, 35(4): 877-884. (Huang L, Zhou F T. Path planning of moving robot based on path optimization of D*Lite algorithm[J]. Control and Decision, 2020, 35(4): 877-884.)
- [6] Zheng X L, Zhang X Z, Xu D H. Speeding up path planning via reinforcement learning in MCTS for automated parking[C]. 2024 IEEE/RSJ International Conference on Intelligent Robots and Systems. Abu Dhabi, 2024: 5410-5415.
- [7] Davarzani S, Ejaz M T. A 2D path-planning performance comparison of RRT and RRT* for unmanned ground vehicle[J]. IAES International Journal of Robotics and Automation, 2024, 13(1): 105-112.
- [8] Gökteş A G, Sezer S. A new local path planning approach by synthesis of PRM and RRT* algorithms for an autonomous mobile robot[J]. Journal of Control, Automation and Electrical Systems, 2025, 36: 72-85.
- [9] Karaman S, Frazzoli E. Sampling-based algorithms for optimal motion planning[J]. International Journal of Robotics Research, 2011, 30(7): 846-894.
- [10] Gammell J D, Srinivasa S S, Barfoot T D. Informed RRT*: Optimal sampling-based path planning focused via direct sampling of an admissible ellipsoidal heuristic[C]. 2014 IEEE/RSJ International Conference on Intelligent Robots and Systems. Chicago, 2014: 2997-3004.
- [11] Wang H D, Lai H C, Du H H, et al. IBPF-RRT*: An improved path planning algorithm with Ultra-low number of iterations and stabilized optimal path quality[J]. Journal of King Saud University-Computer and Information Sciences, 2024, 36(7): 102146.
- [12] 陈志澜, 唐昊阳. 改进 RRT-Connect 算法的机器人路径规划研究[J]. 计算机科学与探索, 2025, 19(2): 396-405. (Chen Z L, Tang H Y. Research on robot path planning based on improved RRT-Connect algorithm[J]. Journal of Frontiers of Computer Science and Technology, 2025, 19(2): 396-405.)
- [13] 陈丹, 谭钦, 徐哲壮. 基于采样点优化 RRT 算法的机械臂路径规划[J]. 控制与决策, 2024, 39(8): 2597-2604. (Chen D, Tan Q, Xu Z Z. Robotic arm path planning based on sampling point optimization RRT algorithm[J]. Control and Decision, 2024, 39(8): 2597-2604.)
- [14] Hong K R, Kim H, Kim T S, et al. Optimizing radiation exposure in dynamic radioactive environments: Dynamic ACO-RRT* path planning algorithm[J]. Radiation Protection and Environment, 2024, 47(2): 102-114.
- [15] 李阿辉, 刘锦元, 付明磊, 等. 一种基于凸剖分知情采样最优路径规划算法[J]. 控制与决策, 2025, 40(6): 1994-2002. (Li A H, Liu J Y, Fu M L, et al. An optimal path planning algorithm based on informed sampling of convex dissection[J]. Control and Decision, 2025, 40(6): 1994-2002.)
- [16] Langari S M, Vahdatikhaki F, Hammad A. Improving the performance of RRT path planning of excavators by embedding heuristic rules[J]. Advanced Engineering Informatics, 2024, 62: 102724.
- [17] 喻娟, 王俊勇, 周胜, 等. 全轴转向半挂铰接车辆通过性优化及验证[J]. 交通科技与经济, 2021, 23(5): 45-50. (Yu J, Wang J Y, Zhou S, et al. Optimization and verification of passing ability for articulated semi-trailer vehicle with full-axle steering[J]. Technology and Economy in Areas of Communications, 2021, 23(5): 45-50.)
- [18] 张卫波, 肖继亮. 改进 RRT 算法在复杂环境下智能车路径规划中的应用[J]. 中国公路学报, 2021, 34(3): 225-234. (Zhang W B, Xiao J L. Application of improved RRT algorithm in intelligent vehicle path planning under complicated environment[J]. China Journal of Highway and Transport, 2021, 34(3): 225-234.)
- [19] 刘坤, 葛俊锋, 罗予频, 等. 概率引导的随机采样一致性算法[J]. 计算机辅助设计与图形学学报, 2009, 21(5): 657-662. (Liu K, Ge J F, Luo Y P, et al. Probability guided random sample consensus[J]. Journal of Computer-Aided Design and Computer Graphics, 2009, 21(5): 657-662.)
- [20] 朱允梁. 基于视觉感知的多机器人协同自主建图策略研究[D]. 哈尔滨: 哈尔滨工业大学, 2021. (Zhu Y L. Research on multi-robot collaborative autonomous mapping strategy based on visual perception[D]. Harbin: Harbin Institute of Technology, 2021.)

作者简介

李亦韩 (2002-), 男, 硕士生, 主要研究方向为任务规划、体系评估优化, E-mail: liyihan20@nudt.edu.cn;

陈刚 (1997-), 男, 博士生, 主要研究方向为作战体系博弈、作战网络评估优化, E-mail: chengang@nudt.edu.cn;

杨志伟 (1988-), 男, 副教授, 博士, 硕士生导师, 主要研究方向为武器装备体系技术、任务规划, E-mail: zhwyang88@hotmail.com;

赵青松 (1975-), 男, 教授, 博士, 博士生导师, 主要研究方向为国防采办与体系工程管理、数据分析与智能决策, E-mail: zhaqing song@nudt.edu.cn;

倪雨 (2002-), 女, 硕士生, 主要研究方向为人机协同、多智能体优化, E-mail: [niyu20@nudt.edu.cn](mailto:nuyu20@nudt.edu.cn).