

基于改进 RRT-Connect 算法的无人车路径规划

姚利娜, 李金龙

(郑州大学 电气与信息工程学院, 河南 郑州 450001)

摘要: 针对传统双向快速扩展随机树算法搜索盲目、节点冗余和路径不平滑等问题, 对其在目标采样、节点扩展以及轨迹优化等方面进行了改进。首先, 引入目标动态概率采样策略, 根据当前随机树的扩展状态与目标点的位置, 动态调整目标采样点的采样概率, 对生成的随机点进行筛选, 从而提高采样效率, 加快算法收敛速度; 其次, 在节点扩展过程加入基于出逃力的改进人工势场分量, 在避免陷入局部最优的同时提高无人车的目标搜索能力和节点扩展效率; 最后, 构建轨迹质量评估函数, 分别对无人车在不同时刻下生成轨迹的安全程度、偏移程度以及平滑性进行代价评估并选取代价函数值最小的轨迹来引导无人车行驶。将所提改进算法与传统双向快速扩展随机树算法在不同测试环境下进行仿真, 仿真结果表明, 相比传统算法, 所提算法在简单障碍物环境下规划出来的平均路径长度缩短了 9.83%, 平均规划时间缩短了 85.40%, 在狭窄通道环境下, 所提算法规划出来的平均路径长度和平均规划时间缩短了 10.56% 和 64.63%, 在 U 形障碍物环境下本文算法规划出来的平均路径长度和平均规划时间缩短了 22.82% 和 66.92%。此外, 所提算法在复杂环境下的规划成功率得到了显著提升, 更适用于无人车的路径规划。

关键词: 无人车; 双向快速扩展随机树算法; 目标动态概率采样; 人工势场; 轨迹质量评估函数

中图分类号: TH112; TP242.6

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2026.02.016

随着智能交通与自动驾驶技术的不断发展, 无人车作为未来汽车发展的重要方向, 正逐步在智能驾驶、城市配送、自动巡检等多个实际场景中得到广泛应用。在无人车的众多关键技术中, 自主导航技术无疑是实现其智能化与实用化的重要一环, 其核心在于利用车载传感器实现对车辆自身的精准定位以及对环境地图的实时构建, 结合导航算法和位姿信息, 实现自主的避障控制与路径规划^[1]。其中, 路径规划技术作为无人车智能决策的前提与基础, 是实现高效安全导航的关键^[2]。

目前, 常用的路径规划方法主要包括传统的 Dijkstra 算法^[3]、A* 算法^[4] 以及基于智能优化思想的遗传算法^[5]、粒子群算法^[6] 等, 同时也包括适用于高维空间的基于采样的方法, 如概率路线图法 (Probabilistic Roadmap Method, PRM)^[7] 以及快速扩展随机树算法 (Rapidly-exploring Random Tree, RRT)^[8]。其中, RRT 算法凭借采样逻辑简单、无需先验全局信息、能够快速构建可行路径等优势, 在自

动驾驶领域得到了广泛应用。然而, 传统 RRT 算法在实际应用中仍存在许多不足, 比如路径冗余较多、节点扩展效率较低等^[9]。

为了提升路径搜索效率, Kuffner 等人提出了双向快速扩展随机树算法 (Rapidly-exploring Random Tree Connect, RRT-Connect)^[10], 通过从起点与终点同时生成搜索树, 大幅提高路径规划效率。然而, 在实际应用中, RRT-Connect 算法仍面临很多局限, 还需要做进一步优化。首先, RRT-Connect 算法生成的路径往往存在较多冗余节点, 路径曲折且转弯频繁^[11], 仅注重快速生成可行路径, 缺乏对路径质量的评估与优化, 难以满足无人车对于平滑性与行驶安全性的实际要求^[12]。其次, 当存在狭窄通道、凹形障碍物等复杂环境时, RRT-Connect 算法的两支扩展树极易受到环境影响, 搜索效率急剧下降, 甚至陷入局部最优, 最终无法成功生成有效路径^[13]。

为此, 众多研究者 RRT-Connect 算法的基础上提出了不同的改进策略。Jordan 等^[14] 提出的 Bi-

收稿日期: 2026-02-03; 修订日期: 2026-04-14

基金项目: 国家自然科学基金资助项目 (61973278); 河南省杰出青年基金资助项目 (222300420019)

作者简介: 姚利娜 (1977—), 女, 河南开封人, 郑州大学教授, 博士, 博士生导师, 主要从事故障诊断与容错控制研究, E-mail: michelle_lnx@126.com。

RRT(Bidirectional-RRT)算法通过改进的双向搜索策略加速了路径生成过程;刘建宇等^[15]在RRT-Connect算法中引入目标偏向采样机制,显著增强了收敛速度,但是路径弯曲度较大,不适于实际应用;韩邵龙等^[16]在RRT-Connect算法的基础上引入了约束采样区域和目标导向生长两种策略,以减少算法的采样次数和随机性,缩短规划时间,但在复杂环境中容易陷入局部最优的困境,导致路径扩展失败;周恒旭等^[17]在RRT*算法基础上进行改进,提出了Informed-RRT*算法,引入新的状态子集简化算法本身的采样空间以提高搜索效率;Suwoyo等^[18]在RRT*-Connect中引入智能采样的思想提升了算法的收敛速度,但在面对形状复杂的U形障碍物时仍存在路径搜索失败的问题。

基于上述研究成果以及现有算法的不足,本文提出一种改进的AEF-RRT-Connect算法,通过引入目标动态概率采样策略以及基于出逃力的人工势场引导机制,确保无人车在存在狭窄通道或U形障碍物的复杂环境中不会陷入局部最优的同时,提升节点扩展时的目标搜索能力与路径扩展效率,另外,构建轨迹质量评估函数,对无人车在不同时刻的轨迹进行代价评估与优化,从中选取最优路径作为导航的最终轨迹。最后分别在简单障碍物环境、存在狭窄通道的环境以及存在U形障碍物的环境下进行了仿真实验,以验证无人车在路径规划效率与环境适应性方面的优势。

1 RRT-Connect 算法原理

在传统RRT-Connect算法中,首先以起始点和目标点为根节点,在搜索空间中同步构建两棵随机树,并通过交替扩展与贪婪步进策略,迭代生成连接起点与目标点的可行路径。其具体的节点扩展过程如图1所示,主要步骤如下:

(1)首先以起点 q_{star} 和目标点 q_{goal} 为根节点同时生成搜索树,记为 T_{star} 和 T_{goal} 。

(2)在搜索空间中随机采样一个点 q_{rand1} ,遍历随机树 T_{star} 上的所有节点,找到 T_{star} 中距离 q_{rand1} 最近的节点 q_{near1} 。

(3)从 q_{rand1} 向 q_{near1} 方向按照固定步长扩展,生成新结点 q_{new1} ,若 q_{new1} 无碰撞且有效,将其加入 T_{star} ,若发生碰撞,则舍弃该节点。回到步骤(1)进行重新采样。

(4)遍历随机树 T_{goal} 上的所有节点,找到 T_{goal} 中距离 q_{new1} 最近的节点 q_{near2} 。

(5)以 q_{new1} 为目标,让随机树 T_{goal} 上的点 q_{near2}

朝着 q_{new1} 的方向按照固定步长扩展,生成新结点 q_{new2} ,若 q_{new2} 无碰撞,采用贪婪搜索策略^[19]继续扩展,直至遇见障碍物或者两树最近点之间的距离小于设定的阈值后停止,若发生碰撞,则舍弃该节点。回到步骤(4)进行重新采样。

(6)交换两棵树 T_{star} 和 T_{goal} 的角色,使得两棵树的扩展方式相互交换,重复上述过程,不断生成新结点,最终使 T_{star} 和 T_{goal} 的最前端节点相连。得到一条无碰撞的安全路径,路径规划完成。




图1 RRT-Connect 节点扩展示意图

Figure 1 Illustration of node extension in RRT-Connect

2 改进 RRT-Connect 算法规划方法

2.1 目标动态概率采样策略

在传统RRT-Connect算法中,采样点的生成具有较大的随机性,且有相当一部分采样点远离目标区域或落入障碍物附近,造成扩展过程中产生大量的无效尝试,导致无人车路径规划效率较低。为此,本节引入了一种目标动态概率采样策略,可以根据当前随机树的扩展状态和目标点的位置,动态地调整目标采样点的采样概率。目标动态概率采样策略的优势在于,在算法采样运行初期,能够保持较高的随机性以探索更大空间;随着随机树的探索,逐步增加目标偏向采样的权重,引导采样点向目标方向集中,从而提高路径收敛速度与扩展效率。具体操作如下:

首先,定义目标区域。计算目标区域的采样概率。目标采样概率阈值 p 可根据当前已经生成的有效节点个数 a 和当前的迭代次数 b 的比值动态调整,如式(1)所示:

$$p = k \cdot \frac{a}{b}. \quad (1)$$

式中: k 为最大目标概率采样阈值系数; a 与 b 的比值越大代表当前生成的有效节点越多。

其次,生成采样点。假设 p 的取值范围为 $(0, 1)$ 。在每次采样前,随机生成一个 $[0, 1]$ 之间的值 r ,在采样时,如果随机数 r 小于阈值 p ,则可将该目标点视为下一个采样点,否则随机产生采样点,如式(2)所示:

$$q_{rand} = \begin{cases} q'_{goal}, & (r < p); \\ q_{rand}, & (r > p). \end{cases} \quad (2)$$

最后,按照 RRT-Connect 算法流程重复采样,直到生成所需数量的采样点为止。

2.2 基于出逃力的人工势场引导机制

本节在 RRT-Connect 算法的节点扩展过程中引入了一种基于出逃力的人工势场引导机制。传统人工势场法主要依赖目标点产生的吸引力与障碍物产生的斥力来规划路径。但是,在实际应用场景中,特别是遇到凹形障碍、狭窄通道等复杂环境,仅凭传统人工势场的引力与斥力难以有效引导无人车跳出当前困境,甚至可能陷入局部最优,导致路径搜索失败。为增强无人车在路径扩展时的环境适应性,本节在传统人工势场基础上引入一种出逃力机制,该出逃力并非来源于目标点的引力或障碍物的斥力,而是通过对路径历史状态与扩展方向的动态分析,判断是否陷入局部困境,并在必要时施加的能够帮助无人车逃出当前困境的一个矫正力,从而实现无人车在遇到狭窄路况或凹形障碍物等复杂环境时的主动脱困。

在人工势场中,当前节点的运动方向主要取决于两种力的合力方向。一种是目标点对当前节点的吸引力,另一种是障碍物对当前节点的排斥力。目标点对当前扩展节点产生的吸引力可定义为^[20]

$$\mathbf{F}_{\text{aat}} = k_{\text{aat}} \cdot (\mathbf{q}_{\text{curr}} - \mathbf{q}_{\text{goal}}). \quad (3)$$

式中: k_{aat} 为引力场系数; \mathbf{q}_{goal} 和 \mathbf{q}_{curr} 分别为目标点和当前节点。根据当前节点与目标点的坐标,可以计算出两者间的距离。

障碍物对节点产生斥力,用于保持避障能力:

$$\mathbf{F}_{\text{rep}} = \begin{cases} k_{\text{rep}} \left(\frac{1}{\|d_1\|} - \frac{1}{d_0} \right) \cdot \frac{1}{\|d_1\|^2} \cdot \frac{d_1}{\|d_1\|}, & \|d_1\| < d_0; \\ 0, & \|d_1\| > d_0. \end{cases} \quad (4)$$

式中: d_1 为当前节点到障碍物的距离; k_{rep} 为斥力系数; d_0 为斥力有效距离阈值。

当某节点连续扩展失败(如扩展方向无效或频繁碰撞)次数超过阈值 N_{fail} , 则判定该扩展节点处于“局部困境”区域。本文将阈值 N_{fail} 设定为 10, 该值是在结合本研究中存在狭窄通道以及 U 形障碍物的复杂环境下的多组仿真实验结果进行调优所得。经检验,当 N_{fail} 设置过小时,容易导致路径震荡和误触发,影响扩展稳定性;当其值过大时,则可能导致算法在局部陷阱中停留时间过长,降低整体规划效率。

当节点扩展失败达到阈值时,激活出逃力 \mathbf{F}_{esc} , 强制调整扩展方向,引导无人车跳出当前困境区域:

$$\mathbf{F}_{\text{esc}} = k_{\text{esc}} \cdot \sum_{i=1}^n \left(\frac{\mathbf{q}_{\text{curr}} - \mathbf{q}_{\text{fair},i}}{\|\mathbf{q}_{\text{curr}} - \mathbf{q}_{\text{fair},i}\|^2} \right). \quad (5)$$

式中: k_{esc} 为出逃力系数; $\mathbf{q}_{\text{fair},i}$ 表示历史扩展失败的位置。该出逃力引导当前节点远离失败高发区域,形成逃逸趋势,提升搜索多样性与脱困能力。

综上所述,节点的最终扩展方向由三力合成:

$$\mathbf{F}_{\text{total}} = \mathbf{F}_{\text{aat}} + \mathbf{F}_{\text{rep}} + \mathbf{F}_{\text{esc}}. \quad (6)$$

新扩展点方向向量为

$$\mathbf{q}_{\text{new}} = \mathbf{q}_{\text{near}} + \delta \cdot \left(\omega_r \frac{\mathbf{q}_{\text{rand}} - \mathbf{q}_{\text{near}}}{\|\mathbf{q}_{\text{rand}} - \mathbf{q}_{\text{near}}\|} + (1 - \omega_r) \frac{\mathbf{F}_{\text{total}}}{\|\mathbf{F}_{\text{total}}\|} \right). \quad (7)$$

式中: δ 为步长因子; \mathbf{q}_{near} 为距离最近当前节点的一个节点; \mathbf{q}_{rand} 为随机采样的点; ω_r 为随机点的扩展偏向权重。

\mathbf{q}_{new} 的扩展示意图如图 2 所示。




图 2 改进节点扩展示意图

Figure 2 Schematic diagram of improved node expansion

2.3 构建轨迹质量评估函数

传统 RRT-Connect 算法通常以首次连接两棵扩展树所得路径作为最终路径,未对路径质量进行评价与筛选,易导致路径冗长、不平滑等问题。为提高导航路径的实用性,本节设计了一种用于衡量路径质量的评估函数,综合考虑无人车当前的危险程度、车辆轨迹与全局路径的偏离程度、轨迹的光滑程度等因素,对生成的路径进行多维度代价计算,从中选取代价最小的路径作为无人车的导航轨迹。无人车轨迹质量评估函数如下:

$$\mathbf{F}_{\text{total}}(s) = \lambda_1 \mathbf{F}_o(s) + \lambda_2 \mathbf{F}_d(s) + \lambda_3 \mathbf{F}_s(s). \quad (8)$$

式中: $\mathbf{F}_o(s)$ 用来评估在道路环境下无人车轨迹的危险程度; $\mathbf{F}_d(s)$ 用来评估无人车轨迹偏离程度; $\mathbf{F}_s(s)$ 用于评估无人车轨迹的平滑性。路径的安全性、平滑性与目标偏移程度,分别对应代价函数中的三项子指标。为合理平衡各评价维度对总体代价的影响,引入权重惩罚系数 $\lambda_1, \lambda_2, \lambda_3$, 参考相关文献中常用的路径规划权重范围,并结合人工势场法在不同场景下的特性,设定其值分别为 0.60、0.30 和 0.10,以突出对安全性的优先考虑。

2.3.1 危险程度评估

计算当前行驶过程中危险程度的意义在于对行驶过程的安全性能进行一个有效评估,传统碰撞检

测方法认为如果无人车行驶轨迹与障碍物所在区域没有重合即为安全无碰撞。但是当同时生成多条轨迹时,无法通过比较筛选出性能最好的轨迹以供无人车行驶。

因此,本文构建的轨迹碰撞模型如下式:

$$F_o(d) = \begin{cases} 0, & d > d_s; \\ kv\left(\frac{1}{\sqrt{(d-d_s)^2} - \frac{1}{d_c}}\right), & d_s < d < d_c; \\ +\infty, & d < d_c. \end{cases} \quad (9)$$

式中: d_s 和 d_c 分别表示安全距离阈值和碰撞距离阈值; d 表示无人车路径轨迹到障碍物的距离; k 为当前车速与距离影响因子的比例系数。出于实际考虑,将安全距离阈值 d_s 设为车辆宽度的 1.5 倍。

无人车轨迹碰撞风险评估示意图如图 3 所示,红色轨迹 1、2、3 表示当前时刻该无人车会与前方车辆发生碰撞,绿色轨迹 4、5、6 为安全轨迹,能明显看出,相比于轨迹 4,轨迹 5 和轨迹 6 具有更优的避障性能。




图 3 车辆轨迹碰撞示意图

Figure 3 Schematic diagram of vehicle trajectory collision

2.3.2 轨迹偏移程度评估

受车辆机械特性、路面状况以及各种复杂道路环境干扰等因素的影响,无人车实际行驶轨迹往往会相对期望轨迹产生一定程度的偏移。为了控制这种偏移,本节设置了偏移代价函数来将车辆行驶轨迹限制在预设的偏移阈值范围内。

本文定义的轨迹偏移代价函数如下式所示:

$$F_d(s) = \int (s - S_0)^2 ds. \quad (10)$$

式中: $F_d(s)$ 为轨迹偏移代价函数; $s - S_0$ 表示无人车轨迹与参考线的距离,其值越大,无人车轨迹偏移程度越大,其值越小,无人车轨迹偏移程度越小。无人车轨迹生成测试结果如图 4 所示。由图 4 可知,在局部路径规划过程中,无人车基于当前道路环境信息和车辆实时状态同时生成了多条轨迹,通过实时计算轨迹评估模块函数的代价值,可以看出图 4 中黑色加粗实线所代表的轨迹与参考线的偏移最小,在实际行驶中也最能保证车辆沿道路中心线平稳行驶。




图 4 无人车轨迹生成测试结果

Figure 4 Trajectory generation for the unmanned vehicle

2.3.3 轨迹平滑性评估

对无人车来说,优化轨迹平滑性的目的是保证规划出来的轨迹更加平滑和自然,更符合实际行驶需求。从运动学角度分析,无人车轨迹的一阶导数反映了轨迹的速度特性,二阶导数反映了轨迹的加速度特性,三阶导数反映了轨迹的跃度特性。因此为了保证轨迹的平滑性,需要综合考虑这三个参数。

本文设计的轨迹平滑性代价函数为了避免式中轨迹点导数之和相互抵消,采用各轨迹点导数的平方和形式,如式(11)所示:

$$F_{s1}(s) = \omega_1 \int (\dot{s})^2 ds + \omega_2 \int (\ddot{s})^2 ds + \omega_3 \int (\dddot{s})^2 ds. \quad (11)$$

式中: ω_1 、 ω_2 、 ω_3 分别为轨迹一阶导数、二阶导数以及三阶导数平方和的权重系数;考虑到实际运行中轨迹平滑性主要受曲率影响,故赋予 ω_1 、 ω_2 较高权重,强调转弯处的圆滑过渡。经过多轮仿真验证, ω_1 、 ω_2 、 ω_3 分别设置为 0.20、0.30 和 0.02。

另外,为进一步优化轨迹性能,通过限制轨迹斜率的变化幅度,可有效避免车辆转向角过大,提升行驶稳定性。优化后的轨迹平滑性代价函数如下式所示:

$$F_s(s) = \eta (\Delta\beta_{t+1} - \Delta\beta_t) + F_{s1}(s). \quad (12)$$

式中, η 表示 t 时刻前后斜率变化量的影响因子; $\Delta\beta_t$ 、 $\Delta\beta_{t+1}$ 分别表示在 t 时刻和下一时刻规划轨迹相对于坐标原点的斜率。同时,为了确保无人车规划出来的轨迹符合最小转弯半径要求,规划轨迹的曲率应小于最大转弯曲率,如下式所示:

$$y'' \cdot \frac{1}{(1 + (y'')^2)^{\frac{3}{2}}} < k_{max}. \quad (13)$$

式中: y 为路径函数; y' 和 y'' 分别是路径函数的一阶导数和二阶导数,通常分别表示路径的切线斜率和弯曲程度; k_{max} 为路径的最大允许曲率。为了保证路径的平滑性并避免急剧转弯带来的不稳定性和不适感,结合实际车辆的转弯半径以及不同地图场景中的仿真数据,将最大曲率 k_{max} 设置为 0.15,该

值既能严格将路径曲率控制在合理范围内,有效控制路径的弯曲程度,又能满足常见道路环境中无人车行驶的安全性与舒适性要求,适用于大部分仿真环境下的无人车路径规划。

3 改进 RRT-Connect 算法仿真验证

本文仿真实验在 Windows 11 操作系统上进行,硬件配置为 Intel Core i5-13500H CPU、NVIDIA GeForce RTX 4060 Laptop GPU 以及 32GB DDR5 运行内存,软件方面本文基于 MATLAB 2021a 搭建了三种典型仿真环境,分别为简单障碍物地图、狭窄通道地图以及 U 形障碍物地图。具体工况如下:地图设置为 1 000 mm×1 000 mm,简单环境地图中的障碍物由形状规则的矩形组成,可扩展区域较多,用于测试算法的基本性能。狭窄通道地图中两个障碍物之间的可通行空间不足总地图宽度的 10%,用于测试算法在狭窄环境中的规划性能;U 型障碍物地图中的障碍物为两个 U 形障碍物拼接而成,用于测试算法在复杂转弯情况下的规划效果。

仿真实验以无人车 500 次迭代后的平均路径长度、平均规划时间以及规划成功率作为主要性能评价指标,验证传统 RRT-Connect 算法、RRT*-Connect 算法、由人工势场引导的 APF-RRT-Connect 算法以及本文提出的 AEF-RRT-Connect 算法在不同环境下的路径规划效果。具体参数设置已在第二章进行详细说明,此处不再赘述。

3.1 简单障碍物环境下的性能验证

本节设置简单障碍物地图,路径规划仿真对比结果如图 5 所示。图 5(a)为传统 RRT-Connect 算法的规划效果;图 5(b)为 RRT*-Connect 算法的规划效果;图 5(c)为 APF-RRT-Connect 算法的规划效果;图 5(d)为 AEF-RRT-Connect 算法的规划效果,其中红色路径为无人车引入目标动态概率采样策略以及基于出逃力的人工势场引导机制后规划出来的路径,黑色曲线为优化后

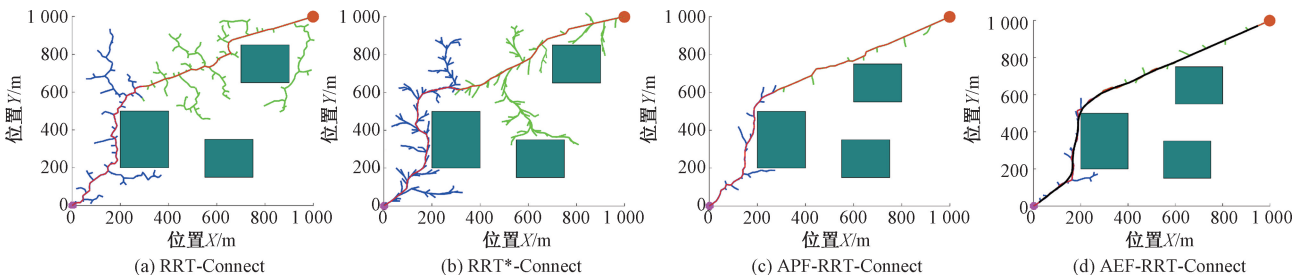


图 5 简单障碍物地图路径规划效果

Figure 5 Path planning results in a simple obstacle map

的最终轨迹。

取 500 次仿真后数据的平均值作为路径长度和算法耗时的最终数据,如表 1 所示:

表 1 简单障碍物地图下各算法性能对比

Table 1 Performance comparison of different algorithms in a simple obstacle map

算法	长度/mm	时间/s	成功率/%
RRT-Connect	1 803.62	9.03	100
RRT*-Connect	1 765.88	13.53	100
APF-RRT-Connect	1 629.22	1.37	100
AEF-RRT-Connect	1 626.37	1.32	100

由表 1 可知,在简单障碍物地图中,四种算法均能成功找到路径,AEF-RRT-Connect 算法规划出来的平均路径长度为 1 626.37 mm,平均规划时间为 1.32 s,与传统 RRT-Connect 算法和 RRT*-Connect 算法相比,规划出的平均路径长度减少了 9.83% 和 7.90%,平均规划时间减少了 85.40% 和 90.26%。因此可以得出本文 AEF-RRT-Connect 算法规划出来的路径更优,所需时间更短。此外,由图 5(d)可知,在引入轨迹质量评估函数以后,优化后的路径曲线(黑色)明显比原始路径(红色)连续性更好,更符合无人车的实际行驶需求。

3.2 狭窄路径环境下的性能验证

本节在狭窄通道地图中进行仿真分析,仿真结果如图 6 所示,其中红色路径为无人车引入目标动态概率采样以及基于出逃力的人工势场引导后规划出来的路径,黑色曲线为在以上两点改进的基础上根据轨迹质量评估函数代价值优化后的最终轨迹。

由图 6 可知,狭窄路径环境下,RRT-Connect 算法与 RRT*-Connect 算法虽然能找到路径,但是路径长度较大,APF-RRT-Connect 算法虽能在一定程度上对路径长度以及规划时间进行优化,但在狭窄环境中容易陷入局部最优,导致路径规划失败。

取 500 次仿真数据的平均值作为路径长度和算法耗时的最终数据,如表 2 所示。




图6 狭窄通道地图路径规划效果

Figure 6 Path planning results in a narrow passage map

表2 狭窄通道地图下各算法性能对比

Table 2 Performance comparison of different algorithms in a narrow passage map

算法	长度/mm	时间/s	成功率/%
RRT-Connect	2 097.04	18.11	56
RRT*-Connect	1 992.74	23.64	46
APF-RRT-Connect	1 882.90	6.99	12
AEF-RRT-Connect	1 875.63	6.41	92

由表2可知,在存在狭窄通道的地图中,本文改进的 AEF-RRT-Connect 算法规划出来的平均路径长度为 1 875.63 mm,平均规划时间为 6.41 s,与传统 RRT-Connect 算法和 RRT*-Connect 相比,规划出来的平均路径长度分别减少了 10.56% 和 5.88%,平均规划时间减少了 64.63% 和 72.89%。另外,相较于由人工势场引力与斥力引导的 APF-RRT-Connect 算法,本文 AEF-RRT-Connect 算法由于出逃力的引入,具有了跳出局部最优的能力,在存在狭窄通道的复杂环境中的路径规划成功率具有了明显提升。此外,轨迹质量评估函数的引入进一步优化了路径的安全性、偏移控制和平滑性,使生成的轨迹更贴合无人车的实际行驶需求。

3.3 U形障碍物环境下的性能验证

本节在存在 U 形障碍物的地图中进行仿真分析,取 500 次仿真数据的平均值作为路径长度和算法耗时的最终数据,如表3所示,仿真结果如图7所示。其中,图7(a)为传统 RRT-Connect 算法的规划效果;图7(b)为 RRT*-Connect 算法的规划效果;图

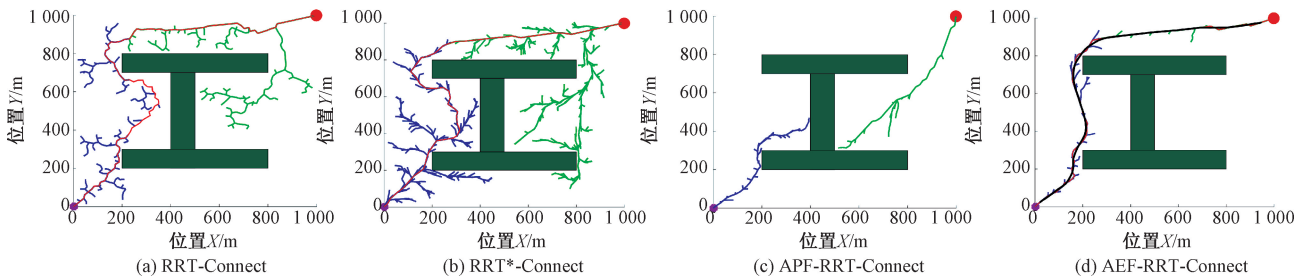


图7 U形障碍物地图路径规划效果

Figure 7 Path planning results in a U-shaped obstacle map

7(c)为 APF-RRT-Connect 算法的规划效果;图7(d)为 AEF-RRT-Connect 算法的规划效果,其中红色路径为无人车引入目标动态概率采样策略以及基于出逃力的人工势场引导机制后规划出来的路径,黑色曲线为在以上两点改进的基础上根据轨迹质量评估函数代价值优化后的最终轨迹。

表3 U形障碍物地图下各算法性能对比

Table 3 Performance comparison of different algorithms in a U-shaped obstacle map

算法	长度/mm	时间/s	成功率/%
RRT-Connect	2 326.71	13.46	56
RRT*-Connect	2 196.83	19.58	52
APF-RRT-Connect	1 799.34	4.43	14
AEF-RRT-Connect	1 795.78	4.45	94

由图7可知,在存在 U 形障碍物的环境中,传统 RRT-Connect 算法与 RRT*-Connect 算法规划出的路径长度较长,且算法运行耗时过多,另外,APF-RRT-Connect 算法规划路径时容易陷入局部最优解的困境,进而导致路径规划任务失败,如图7(c)所示。而经过改进的 AEF-RRT-Connect 算法,由于出逃力机制的引入,其在面对存在 U 形障碍物的复杂环境时,出逃力机制触发后能够引导无人车跳出当前困境并成功规划路径。此外,轨迹质量评估函数的引入有效减少了轨迹偏移与急转弯的情况,使得最终生成的轨迹更加平顺,并更符合无人车的运动学特性和实际行驶需求。

由表3可知,在存在 U 形障碍物的地图中,

AEF-RRT-Connect 算法规划出来的平均路径长度为 1 795.78 mm,平均规划时间为 4.45 s,与传统 RRT-Connect 算法和 RRT*-Connect 算法相比,规划的平均路径长度减少了 22.82%和 18.25%,平均规划时间减少了 66.92%和 77.27%,在规划的路径长度以及规划所需时间上有了明显提升。此外,相较于 APF-RRT-Connect 算法,AEF-RRT-Connect 算法通过引入出逃力,增强了跳出局部最优解的能力,在存在 U 形障碍物等复杂环境中显著提高了路径规划的成功率。同时,轨迹质量评估函数的引入进一步优化了路径的安全性、偏移控制与平滑性,使生成的轨迹更符合无人车的实际行驶需求。

4 结论

(1) 路径规划效率与质量提升显著。在本文 3 种测试环境下,本文提出的 AEF-RRT-Connect 算法规划出的路径在平均长度和平均规划时间方面均展现出了明显优势。

(2) 在复杂环境中表现出更强的适应性与更高的成功率。通过对目标采样策略与节点扩展策略的改进,无人车可以在保证生成路径的质量与扩展效率较高的前提下,提升对不同场景的适应性,特别是无人车在处理复杂环境比如遇到狭窄通道或 U 形障碍物时表现出色,规划成功率得到大幅提高。

(3) 规划出的路径更符合无人车的实际行驶需求。通过对初始路径进行轨迹优化处理,最终生成路径在安全性、偏移量以及平滑度等方面得到有效改善,使其更加贴合无人车的实际行驶需求。

参考文献:

[1] Luo Zhongkai, Zhang Libo. Learning path planning methods[J]. Journal of University of Chinese Academy of Sciences, 2024, 41(1): 11-27. [罗中凯, 张立波. 学习路径规划方法[J]. 中国科学院大学学报(中英文), 2024, 41(1): 11-27.]

[2] Liu Yaqiu, Zhao Hanchen, Liu Xun, et al. An improved RRT based obstacle avoidance path planning algorithm for industrial robot[J]. Information and Control, 2021, 50(2): 235-246. [刘亚秋, 赵汉琛, 刘勋, 等. 一种基于改进的快速扩展随机树的工业机器人路径避障规划算法[J]. 信息与控制, 2021, 50(2): 235-246.]

[3] Song Jiangyi, Li Dan, Chen Wenbo. Local path planning of indoor mobile robot based on dijkstra and PID algorithm[J]. Journal of Anhui University of Technology (Natural Science), 2023, 40(1): 59-64. [宋江一, 李丹, 陈文博. 融合 Dijkstra 和 PID 算法的室内移动

机器人局部路径规划[J]. 安徽工业大学学报(自然科学版), 2023, 40(1): 59-64.]

- [4] Feng Laichun, Liang Huawei, Du Mingbo, et al. Guiding-area RRT path planning algorithm based on a* for intelligent vehicle[J]. Computer Systems & Applications, 2017, 26(8): 127-133. [冯来春, 梁华为, 杜明博, 等. 基于 A* 引导域的 RRT 智能车辆路径规划算法[J]. 计算机系统应用, 2017, 26(8): 127-133.]
- [5] Li Yansheng, Wan Yong, Zhang Yi, et al. Path planning for warehouse robot based on the artificial bee colony-adaptive genetic algorithm[J]. Chinese Journal of Scientific Instrument, 2022, 43(4): 282-290. [李艳生, 万勇, 张毅, 等. 基于人工蜂群-自适应遗传算法的仓储机器人路径规划[J]. 仪器仪表学报, 2022, 43(4): 282-290.]
- [6] Liang Kai, Mao Jianlin. Path planning of indoor mobile robot based on improved ant colony algorithm[J]. Electronic Measurement Technology, 2019, 42(11): 65-69. [梁凯, 毛剑琳. 基于改进蚁群算法的室内移动机器人路径规划[J]. 电子测量技术, 2019, 42(11): 65-69.]
- [7] Lucas S, Portillo E. Application of the optimised pulse width modulation (PWM) based encoding-decoding algorithm for forecasting with spiking neural networks (SNNs) [C]//Proceedings of the ITISE 2024. MDPI, 2024: 41.
- [8] Yin Feng, Xie Qingsong. Research on mobile robot path planning based on improved RRT* algorithm[J]. Journal of Xiangtan University (Natural Science Edition), 2022, 44(4): 22-31. [印峰, 谢青松. 基于改进 RRT* 算法的移动机器人路径规划研究[J]. 湘潭大学学报(自然科学版), 2022, 44(4): 22-31.]
- [9] Becerra I, Suomalainen M, Lozano E, et al. Human perception-optimized planning for comfortable VR-based telepresence[J]. IEEE Robotics and Automation Letters, 2020, 5(4): 6489-6496.
- [10] Sun Yuhao, Zhu Huazhong, Liang Zhaocheng, et al. A phase search-enhanced Bi-RRT path planning algorithm for mobile robots[J]. Intelligence & Robotics, 2025, 5(2): 404-418.
- [11] Wang Kun, Huang Bo, Zeng Guohui, et al. Faster path planning based on improved RRT-connect algorithm[J]. Journal of Wuhan University (Natural Science Edition), 2019, 65(3): 283-289. [王坤, 黄勃, 曾国辉, 等. 基于改进 RRT-Connect 的快速路径规划算法[J]. 武汉大学学报(理学版), 2019, 65(3): 283-289.]
- [12] Ge Chao, Zhang Xinyuan, Wang Hong, et al. Path planning based on improved RRT-connect algorithm[J]. Electronics Optics & Control, 2025, 32(3): 21-26. [葛超, 张鑫源, 王红, 等. 一种改进 RRT-Connect 算法的路径规划研究[J]. 电光与控制, 2025, 32(3): 21-26.]

- [13] Chen Zhilan, Tang Haoyang. 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. [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.]
- [14] Song Maocan, Cheng Lin, Lu Bin. Solving the multi-compartment vehicle routing problem by an augmented Lagrangian relaxation method[J]. Expert Systems with Applications, 2024, 237: 121511.
- [15] Liu Jianyu, Fan Pingqing. Path planning of manipulator based on improved RRT* -connect algorithm[J]. Computer Engineering and Applications, 2021, 57(6): 274–278. [刘建宇, 范平清. 基于改进的 RRT* -connect 算法机械臂路径规划[J]. 计算机工程与应用, 2021, 57(6): 274–278.]
- [16] Han Shaolong, Liu Wenqi, Liu Yuanshang, et al. Research on path planning of manipulator based on the improved RRT-connect algorithm[J]. IEEE Access, 2025, 13: 135165–135178.
- [17] Zhou Hengxu, Cheng Yong, Liu Weicai. Manipulator motion planning based on dubins-informed RRT* Algorithm[J]. Techniques of Automation and Applications, 2020, 39(10): 67–74. [周恒旭, 程勇, 刘伟才. Dubins-Informed RRT* 算法规划的机械臂运动[J]. 自动化技术与应用, 2020, 39(10): 67–74.]
- [18] Suwoyo H, Hastomi Y, Andika J. A Bidirectional-RRT* -Connect-Assisted RRT* -Smart for a path planning algorithm[J]. Sinergi, 2025, 29(2): 473.
- [19] Zheng Zhuan, Xie Shuangjian, Ye Zimo, et al. Research on path smoothing optimisation based on improved RRT-Connect algorithm and third-order Bezier curve[J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2025, 239(7): 2544–2561.
- [20] Chen Jiangyi, Yin Xiaoyong, Wang Tingting, et al. Local path planning of artificial potential field based on improved repulsive model[J]. Journal of Zhengzhou University (Engineering Science), 2023, 44(3): 83–87. [陈江义, 殷笑勇, 王婷婷, 等. 基于改进斥力模型的人工势场局部路径规划[J]. 郑州大学学报(工学版), 2023, 44(3): 83–87.]

Path Planning for Unmanned Vehicles Based on Improved RRT-Connect Algorithm

YAO Lina, LI Jinlong

(School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: To address the issues of blind searching, redundant nodes, and non-smooth paths inherent in the traditional Rapidly-exploring Random Tree Connect (RRT-Connect) algorithm, a series of improvements have been proposed in goal sampling, node expansion and trajectory optimization. Firstly, a goal-guided dynamic probability sampling strategy is introduced to filter the randomly selected points, thereby improving sampling efficiency and accelerating convergence. Next, an improved artificial potential field component based on the escape force is incorporated into the node expansion process. This helps the unmanned vehicle avoid getting trapped in local minima while enhancing its target-searching capability and node expansion efficiency. Finally, a trajectory quality evaluation function is constructed to assess the safety, deviation, and smoothness of the trajectories generated by the unmanned vehicle at different time steps. The trajectory with the minimum cost value is then selected to guide the vehicle's motion. The enhanced algorithm is simulated and compared with the traditional RRT-Connect algorithm under different testing environments. The simulation results show that, compared to the traditional algorithm, the proposed algorithm reduces the average path length by 9.83% and the average planning time by 85.40% in simple obstacle environments. In narrow passage environments, the average path length and planning time are reduced by 10.56% and 64.63%, respectively. In U-shaped obstacle environments, the average path length and planning time are reduced by 22.82% and 66.92%, respectively. Furthermore, the proposed algorithm significantly improves the path planning success rate in complex environments, making it more suitable for autonomous vehicle path planning.

Keywords: unmanned vehicle; rapidly-exploring random tree connect algorithm; goal-guided dynamic probability sampling; artificial potential field; trajectory quality evaluation function