

基于融合改进人工势场法的自适应 RRT * 路径规划算法

崔春雷, 李 锋, 罗权财, 冯 建

(广东交通职业技术学院 智慧交通工程学院, 广州 510650)

摘要: 为解决传统 RRT 类算法在路径规划中收敛速度慢冗余节点多, 而人工势场法又易陷入局部最优解的问题, 提出一种融合了改进人工势场法 (APF) 的自适应 RRT * 路径规划算法; 算法对传统 APF 进行改进, 引入障碍物切向力分量, 并采用自适应动态调整策略, 根据路径扩展难度动态调整切向力的大小, 增强了算法逃逸局部最优的能力; 设计出随机搜索树扩展的三模式机制, 即随机树以概率 p_1 进行 APF 模式引导的扩展、以概率 p_2 进行 RRT * 随机采样扩展, 以概率 p_3 进行目标偏向扩展, 并通过统计窗口内随机树扩展成功率动态调整各模式的概率, 确保在复杂环境中能高效收敛, 并引入路径节点优化策略, 得到相对最优路径; 仿真结果显示, 算法在简单环境中的性能显著高于 RRT 类、APF 类算法; 在复杂环境, 算法平均搜索时间、路径长度和转弯次数分别为 RRT * 算法的 62.7%、71.8% 和 10.5%; 算法的时间复杂度与 RRT * 类量级保持一致, 收敛路径长度的标准差显著降低且分布整体偏左侧, 呈现长尾特征, 表明了算法的高效性、高稳定性和最优路径的高可达性。

关键词: 移动机器人; 路径规划; 快速扩展随机树; 局部最优; 自适应权重

Adaptive RRT * Path Planning Algorithm Based on Fusion of Improved Artificial Potential Field Method

CUI Chunlei, LI Feng, LUO Quancai, FENG Jian

(School of Intelligent Transportation Engineering, Guangdong Communication Polytechnic, Guangzhou 510650, China)

Abstract: To address the issues of slow convergence and excessive redundant nodes in traditional RRT-based algorithms for path planning, as well as the tendency of the artificial potential field (APF) method to fall into local optima, this paper proposes an adaptive RRT * path planning algorithm fused with an improved APF approach. The algorithm enhances traditional APFs, introduces a tangential force component, employs an adaptive dynamic adjustment strategy, and dynamically modulates the magnitude of tangential force based on path expansion difficulty, thereby improving the ability of the algorithm to escape local optima. A three-mode mechanism for expanding the random search tree is designed, in which the tree performs APF-guided expansion with the probability p_1 , RRT * random sampling expansion with the probability p_2 , and goal-biased expansion with the probability p_3 . The probabilities of each mode are dynamically adjusted by statistically analyzing the success rates of tree expansions within a specified window, ensuring efficient convergence in complex environments. Additionally, a path node optimization strategy is incorporated to obtain the relatively optimal path. Simulation results demonstrate that the proposed algorithm significantly outperforms the RRT-based and APF-based algorithms in simple environments. In complex environments, the average search time, path length, and number of turns for this algorithm are 62.7%, 71.8%, and 10.5% of those for the RRT * one, respectively. The algorithm is consistent with the RRT * -based one in time complexity on the order of magnitude, thus significantly reducing the standard deviation of convergence path, with an overall distribution to the left, exhibiting a long-tailed distribution, and indicating that the algorithm has high effi-

收稿日期:2025-08-01; 修回日期:2025-09-01。

基金项目:广东省普通高校新一代电子信息重点领域专项(2022ZDZX1058);广东交通职业技术学院科研项目(GDCP-ZX-2023-003-N1);广东交通职业技术学院大学生科技创新项目(GDCP-ZX-2023-035-N6)。

作者简介:崔春雷(1978-),男,硕士,讲师。

引用格式:崔春雷,李 锋,罗权财,等.基于融合改进人工势场法的自适应 RRT * 路径规划算法[J].计算机测量与控制,2025,33(12):206-214.

ciency, stability, and accessibility to optimal paths.

Keywords: mobile robot; path planning; rapidly-exploring random tree; local optimum; adaptive weighting

0 引言

机器人路径规划是移动机器人导航技术的核心, 其根本任务是在一个包含障碍物的环境空间中, 为机器人寻找一条从起点到终点的无碰撞、可通行的最优或次优路径^[1-3]。在机器人路径规划领域, 根据对环境信息的认知程度, 主要分为全局路径规划和局部路径规划两大类^[4-5]。全局路径规划是一种离线规划方法, 它依赖于预先构建的、完整的全局环境地图信息(如栅格地图、拓扑图等)。该方法的重点在于利用全局搜索策略(如基于图的搜索或随机采样), 在整个已知环境空间中计算出一条连接起点与目标点的最优或近似最优路径。典型的算法包括: 基于图的搜索算法如 Dijkstra 算法、A* 算法^[6]、蚁群算法^[7], 基于采样的搜索算法如概率路线图法(PRM, probabilistic roadmap)、快速随机扩展树法^[8](RRT, rapidly-exploring random tree)及其变种等。局部路径规划则是一种在线规划方法。它主要依靠机器人搭载的传感器(如激光雷达、摄像头、超声波)实时感知机器人周围的局部、动态环境信息。该方法的侧重点在于使机器人具备实时避障能力和对环境动态变化(如移动障碍物)的快速响应能力。代表性算法包括人工势场法^[9](APF, artificial potential field)、动态窗口法(DWA, dynamic window approach)等。

快速扩展随机树(RRT)为代表的采样类算法和以人工势场法(APF)为代表的反应式算法, 因各自独特的优势在学术界得到了广泛的研究和应用。快速扩展随机树(RRT)作为一种基于采样的路径规划算法, 具有概率完备性和收敛速率较快、渐近最优性等显著优点, 而且算法避免了对复杂空间进行显式建模的难题, 尤其适合解决高维空间和复杂约束问题。但是, 单纯的 RRT 算法也具有明显缺陷, 如路径搜索效率低、耗时高、狭窄通道难以通过、路径不够平滑等问题。为克服这一缺陷, 一系列变种算法被提出, 如双向 RRT (Bi-RRT)^[10]、Informed RRT*^[11]、RRT* (RRT-Star)^[12] 算法等。传统人工势场法(APF)的原理直观, 计算量小, 路径平滑, 非常适合实时的局部避障。然而, 传统 APF 存在一些固有缺陷, 如局部最优问题, 即在某些障碍物布局下(如 U 型陷阱), 引力和斥力可能会在某个非目标点达到平衡, 导致机器人陷入局部极小值点而无法动弹。针对 APF 算法的缺陷, 国内外学者提出了多种改进策略。刘云平等^[13]对障碍物产生的势场进行重构, 并加入垂直于障碍物方向的辅助势场, 进一步降低了算法陷入局部最优的风险。杨彦新等人^[14]提出将 APF 算法与 RRT* 算法相融合并通过全局与局部规

划算法相融合的方法来提升 RRT* 算法的效率。Wang 等人^[15]通过引入对数形式的势场函数, 对传统 APF 进行了调整, 有效缓解了陷入局部极小值的现象。以上方法取得了一定的成效, 但在路径质量、搜索效率、算法稳定性以及应对 U 型障碍物和迷宫等复杂环境时仍旧表现不佳, 且算法时间复杂度普遍较高。

为此提出了一种融合了改进人工势场法的自适应 RRT* 算法, 算法的改进包括以下几方面: 1) 在人工势场法中引入障碍物切向力分量, 从而避免传统人工势场算法在某些障碍物环境中陷入局部最优无法前进的问题; 2) 对切向力的大小和方向采用自适应动态调整策略, 在路径扩展困难时自动强化切向力的作用, 从而跳出局部最优; 3) 随机树的扩展采用三模式进行, 即以一定概率 p_1 按照改进人工势场法指定的方向进行扩展, 以概率 p_2 按传统 RRT* 方式进行扩展, 以概率 p_3 朝目标点扩展, 其中 $p_1 + p_2 + p_3 = 1$ 。这样可以充分利用 3 种模式的优势, 大大加快搜索效率; 4) 设计了一种随机树扩展模式的自适应动态调整机制, 通过统计各种采样模式在窗口期内的“成功率”, 来动态调整某种扩展模式被选中的概率, 从而充分发挥各种扩展模式的优势; 5) 引入路径节点优化策略, 通过删除冗余节点保留关键节点, 得到了长度更短且节点数量更少更平滑更适合机器人行进的路径。

1 传统 RRT* 算法

传统 RRT 算法的核心思想是以起点为根节点, 通过随机采样生成一个“随机树”, 并逐步向未探索区域扩展, 直至树的某个节点到达目标区域^[16]。RRT 算法具有概率完备性, 即只要路径存在, 经过足够长的时间总能找到一条路径。

RRT* 算法是 RRT 算法的优化版本, 其核心目标是在保持 RRT 概率完备性的基础上, 增加路径的渐近最优性。RRT* 的改进策略在于它不再像 RRT 那样简单地将新节点连接到树上最近的节点, 而是引入了两个关键的优化步骤: 重新选择父节点和重新布线, 这两个步骤的核心目的是在一个邻域内, 寻找成本最低的连接方式。

重新选择父节点的原理如图 1 所示, 当通过随机采样点 X_{rand} 生成一个新节点 X_{new} 后, RRT* 算法不会立即将其连接到最近的节点 $X_{nearest}$, 相反, 算法会考察 X_{new} 一定半径范围内的所有邻近节点 (X_{near} 集合) 并遍历这个集合, 计算 X_{new} 通过其周边每个邻近节点到达 X_{int} 的总成本, 并选择其中成本最小且无碰撞的路径所对应的节点作为 X_{new} 的父节点。这确保了新节点以最优

的方式加入树中。




图 1 父节点重选过程

图 1 中,新产生的节点 X_{new} 原本父节点为节点 2 (X_{nearest}),但是考察给定半径范围后发现如果选节点 3 作为父节点,则从 X_{new} 回溯到根节点 X_{int} 的路径代价更小,那么算法即选定节点 3 作为更新后的父节点。

重布线 (Rewiring) 过程如图 2 所示,在将 X_{new} 添加到树中之后,RRT* 还会执行一个反向优化过程。它会再次考察 X_{new} 邻域内的所有节点。对于每一个邻近节点 X_{near} ,算法会检查是否“经由 X_{new} 到达 X_{int} ”的路径成本 $\text{cost}(X_{\text{new}}, X_{\text{int}}) + \text{distance}(X_{\text{near}}, X_{\text{new}})$,比 X_{near} 现有的路径成本 $\text{cost}(X_{\text{near}}, X_{\text{int}})$ 更低。如果成本更低且路径无碰撞,算法就会“重布线”,即断开 P_{near} 与其原父节点连接,转而将其父节点设置为 X_{new} 。这个过程会不断优化树的结构,使其逐渐拉直,趋向最优。图 2 中,当 X_{new} 把节点 3 作为父节点后,节点 4 发现通过 X_{new} 回溯到 X_{int} 的路径代价更小,于是节点 4 断开与节点 2 的连接,转而和 X_{new} (节点 7) 连接。




图 2 重布线过程

RRT* 算法相对于传统的 RRT 算法能依概率收敛到最优的路径^[16]。但其仍存在一定的缺陷,如生成的路径由大量折线段组成,不符合机器人的运动学约束,通常需要后处理平滑。另外,RRT* 算法的随机采样过程仍然是全图搜索,会产生很多不相关节点,从而增加了路径搜索时间,导致收敛速率缓慢。

2 传统人工势场 (APF) 算法

人工势场法 (APF) 的原理是将路径规划问题转化

为力学问题,通过构建虚拟势场引导机器人运动。目标点产生引力场,引导机器人向目标移动,障碍物产生斥力场,使机器人远离危险区域,机器人在合力作用下沿负梯度方向运动^[17]。

引力势场函数^[18]通常定义为:

$$U_{\text{att}}(X) = \frac{1}{2} \kappa_{\text{att}} \rho^2(X, X_{\text{goal}}) \quad (1)$$

其中: κ_{att} 为引力增益系数, X 为机器人当前位置, X_{goal} 为目标位置。

此时引力 $F_{\text{att}}(X)$ 为对应的引力势场函数的负梯度:

$$F_{\text{att}}(X) = -\nabla U_{\text{att}}(X) \quad (2)$$

斥力势场函数^[19]定义为:

$$U_{\text{rep}}(X) = \begin{cases} \frac{1}{2} \kappa_{\text{rep}} \left(\frac{1}{\rho(X, X_{\text{obs}})} - \frac{1}{\rho_0} \right)^2, & 0 < \rho(X, X_{\text{obs}}) \leq \rho_0 \\ 0, & \rho(X, X_{\text{obs}}) > \rho_0 \end{cases} \quad (3)$$

其中: κ_{rep} 斥力增益系数, $\rho(X, X_{\text{obs}})$ 为机器人到最近障碍物的欧式距离, ρ_0 为障碍物影响范围的阈值,代表当机器人距离障碍物大于该距离时,障碍物就不对机器人产生任何影响。

此时斥力为对应的斥力势场函数的负梯度:

$$F_{\text{rep}}(X) = -\nabla U_{\text{rep}}(X) \quad (4)$$

在整个地图中,将引力和所有障碍物形成的总斥力进行叠加就得到了机器人在当前位置所受到的合力:

$$F_{\text{total}}(X) = F_{\text{att}}(X) + \sum F_{\text{rep}}(X) \quad (5)$$

3 改进融合自适应算法原理

3.1 改进人工势场算法

传统 APF 算法在实际应用中存在如下缺陷,如容易陷入局部最优区域,特别是在 U 型陷阱或狭窄通道中,机器人受到的法向斥力(垂直于障碍物表面)与引力在一条直线上从而达到平衡。为解决传统人工势场法容易陷入局部极小值的问题,本算法引入切向力分量,当机器人接近障碍物时,除了产生远离障碍物的法向斥力外,还会产生沿障碍物边缘运动的切向力,且可以根据状态自适应调整切向力的大小和方向。

3.1.1 引入切向力的 APF 算法

假如当前机器人的位置为 X ,最近障碍点为 X_{obs} ,则两者之间的法向量和切向量定义为:法向量: $\vec{n} = \frac{(X - X_{\text{obs}})}{\|X - X_{\text{obs}}\|}$,切向量: $\vec{t} = \mathbf{R}_{90} \vec{n}$,其中 \mathbf{R}_{90} 为旋转 90° 的旋转矩阵。

如图 3 所示,在法向方向的斥力 $F_{\text{rep}}(X)$ 基础上,叠加一个切向方向的斥力 $F_{\text{rep}_t}(X)$ 。

此时总的斥力为:

$$F_{\text{rep_total}}(X) = F_{\text{rep}}(X) + F_{\text{rep}_t}(X) \quad (6)$$

切向方向的斥力具体为:




图 3 引入切向力的力场

$$F_{rep_t}(X) = \text{sign}(\nu_{desired}) k_{tan} \|F_{rep}(X)\| \vec{t} \quad (7)$$

式中, $\text{sign}(\nu_{desired})$ 是根据所期望的运动方向确定的数, 只能离散的取 $[1, -1]$ 中的一个数, k_{tan} 为切向力系数, 该系数可以根据当前运动情况自适应调整。此时切向方向的斥力 $F_{rep_t}(X)$ 由法向方向的斥力 $\|F_{rep}(X)\|$ 大小以及目标方向和当前运动状态共同决定。

3.1.2 切向力的智能决策

切向力 F_{rep_t} 的方向选择对算法性能至关重要, 本算法采用以下策略确定切向力:

1) 基于当前运动状态的切向力大小的决策: 由公式 (7) 可知, 切向力大小和系数 k_{tan} 密切相关。改进算法中设定 k_{tan} 的大小范围在 $0 \sim 1$ 之间, 初始值为 0, 迭代过程实时维护一个窗口 W , 如设窗口宽度为 $W=5$, 即以当前为节点逆推过去 5 次随机树扩展的情况, 统计窗口期内拓展失败的次数 $N_{failure}$, 通过公式 (8) 计算出 k_{tan} 的瞬时值。显然若持续拓展失败, 说明位于局部最优区域, 通过不断增大切向力系数 k_{tan} , 就可以增加跳出该区域的概率, 反之当窗口期内全部扩展成功则 k_{tan} 减少到 0, 即切向力暂时消失, 此时路径可以顺着势场指引方向快速前进:

$$k_{tan} = \begin{cases} \frac{N_{failure}}{W}, & 0 \leq N_{failure} \leq W \\ 1, & N_{failure} > W \end{cases} \quad (8)$$

式中, $N_{failure}$ 为当前统计窗口 W 内随机树拓展失败的次数。窗口 W 不宜设置过大, 这样可以快速响应环境情况, 使得切向力快速调整以适应情况。

2) 基于目标方向的切向力方向的决策: 切向力的方向也至关重要, 如图 3 中, 切向力可以在斥力方向的顺时针 90° 和逆时针 90° 这两个方向可选。为了朝期望方向前进, 算法分别计算从当前位置到目标的方向 \vec{n} 与两个可能的切向方向 \vec{t} 和 $-\vec{t}$ 之间的夹角, 并选择夹角较小的方向作为切向力方向, 并通过公式 (9) 得到方向系数 $\text{sign}(\nu_{desired})$ 的取值:

$$\text{sign}(\nu_{desired}) = \begin{cases} 1, & \text{dot}(\vec{n}, \vec{t}) \geq 0 \\ -1, & \text{dot}(\vec{n}, \vec{t}) < 0 \end{cases} \quad (9)$$

3.2 随机树基于概率的动态三模式扩展

3.2.1 改进随机树扩展策略

改进算法中, RRT* 的随机树的生长采用基于概

率的自适应三模式动态扩展策略。

如图 4 所示, 随机树在扩展时会根据概率选择一种模式进行扩展。




图 4 随机树扩展方向的模式选择示意图

模式 1: 改进的人工势场引导的扩展模式

以概率 p_1 根据上述改进的人工势场的合力方向进行采样。这是算法效率的核心, 充分利用 APF 提供的环境梯度信息, 引导随机树向着“有希望”的方向(即势能下降的方向)快速生长。这种方式使树的扩展不再盲目, 而是具有明确的局部导向性, 能够高效地绕过障碍物, 并快速逼近目标, 从而显著加快算法的收敛。在模式 1 中, 为了充分利用势场法的优势, 采样贪心策略, 启动连续扩展模式, 让随机树中被选中的节点沿着势场方向连续扩展 N 步(仿真时取 $N=5$), 且在扩展过程中由公式 (8) 和 (9) 动态调整切向力大小和方向以应对局部最优区域。

模式 2: 随机采样引导的扩展模式

以概率 p_2 采用传统 RRT* 的随机采样方式。这种模式保证了算法的探索能力和概率完备性, 当 APF 引导失效或陷入困境时, 纯随机的探索能够提供“破局”的可能, 特别是在复杂环境中能够发现新的可行区域。且 RRT* 算法还可以通过重选父节点和重新布线的操作, 把各类扩展模式得到的路径进行进一步的优化, 可以依概率收敛到最优的路径。

模式 3: 基于目标偏向策略的扩展模式

以概率 p_3 直接将目标点作为采样点。这种模式主要解决人工势场法在目标附近因附近的障碍物的斥力的影响导致无法到达目标的问题。通过以一定概率直接向目标点扩展, 可以强制随机树尝试连接到目标区域。这种贪心策略极大地加速了在接近目标区域时的收敛过程, 确保了算法的最终收敛性。

以上 3 种概率应满足约束: $p_1 + p_2 + p_3 = 1$ 。通过这 3 种模式的结合, 算法在局部高效扩展(模式一)、全局探索(模式二)和最终收敛(模式三)之间取得了很好的平衡。

3.2.2 三模式扩展的概率动态调整策略

为了使算法能够自适应不同的环境特征, 算法设计了动态概率调整机制。该机制根据算法的实时性能反馈调整 3 种采样模式的概率分配。为了方便分析, 算法先设 p_3 为一个固定值, 则 p_1 和 p_2 的值可以在 $1 - p_3$ 的

范围内动态调整。

首先定义随机树节点扩展成功率为：

$$\alpha_{\text{success}} = \frac{N_{\text{success}}}{N_{\text{attempt}}} \quad (10)$$

算法维护一个近期的历史记录窗口 H ，其中 N_{attempt} 为最近历史记录窗口 H 内尝试拓展的次数， N_{success} 为其中扩展成功的次数。若一段时间内扩展成功率 α_{success} 较高，则说明地图中障碍物较少环境较简单，此时即可充分发挥人工势场法的优势，动态的提高概率 p_1 的值，让随机树由引力场引导快速接近目标。若一段时间内扩展成功率 α_{success} 较低，则说明地图中障碍物较多环境较复杂，引力场引导随机树生长的优势减少，此时可以动态的提高概率 p_2 ，通过充分发挥随机采样能依概率收敛到目标点的特性来应对复杂环境。

根据上述原则，算法设置 p_1 的动态概率为：

$$p_1(t) = (p_{1_max} - p_{1_min}) * \alpha_{\text{success}}(t) + p_{1_min} \quad (11)$$

其中： p_{1_max} 为指定的采用人工势场引导模式的最大概率值， p_{1_min} 为相应的最小基础概率值，显然当前人工势场引导模式的动态概率 $p_1(t)$ 值总是介于 p_{1_min} 和 p_{1_max} 之间，且和当前的节点扩展成功率 $\alpha_{\text{success}}(t)$ 正相关，当 $\alpha_{\text{success}}(t) = 0$ 时 $p_1(t)$ 取到最小值为 p_{1_min} ，当 $\alpha_{\text{success}}(t) = 1$ 时 $p_1(t)$ 取到最大值为 p_{1_max} 。

又因 p_3 为给的定值，则此时基于随机采样引导的扩展概率 p_2 为：

$$p_2(t) = (1 - p_3) - p_1(t) \quad (12)$$

3.3 路径节点优化策略

RRT* 算法虽然可以一定程度地优化路径，但一般来说其生成的原始路径仍包含大量冗余节点，形成了崎岖的包含大量短折线的路径，这种路径包含的转弯过多，不符合机器人路径约束，为此需对生成的原始路径进行节点优化处理。算法首先采用贪心算法的思路，对路径进行关键节点的提取，去除非关键节点。算法从起点开始，尝试直接连接到路径上尽可能远的后续节点，只要两者之间的直线段不与障碍物发生碰撞，就将中间的所有节点舍弃。

如图 5 所示，首先把原始路径上的节点加入集合 $\{X_{\text{int}}, X_1, X_2, \dots, X_{\text{goal}}\}$ ，此集合成为原始节点集合，接着从第一个节点 X_{int} 开始依次连接后续的节点 X_i ，直到出现一种情况，即： X_{int} 与 X_i 之间的连线无障碍物，但是 X_{int} 与 X_{i+1} 之间的连线有障碍物。此时把 X_{int} 和 X_i 加入一个新的节点集合 $\{X_{\text{int}}, X_i, \dots\}$ ，并称这个新的集合为重要节点集合。接着在原始节点集合中把 X_i 作为一个重要节点，重复上述的过程，直到最终把终点 X_{goal} 加入重要节点集合中。当得到最终的重要节点集合 $\{X_{\text{int}}, X_i, \dots, X_{\text{goal}}\}$ 后，就可以通过该集合的节点生成最终的优化路径。通过这种方式，可以得到

一个节点数量大大减少且长度也瘦身的路径，并且整个路径仍保持原始路径的基本走向。如果想得到更平滑的路径，则可进一步采样 3 阶 B 样条曲线对重要节点集合 $\{X_{\text{int}}, X_i, \dots, X_{\text{goal}}\}$ 进行进一步处理。




图 5 节点优化策略

根据上述算法各部分的原理，最终得到改进算法的流程，如图 6 所示。

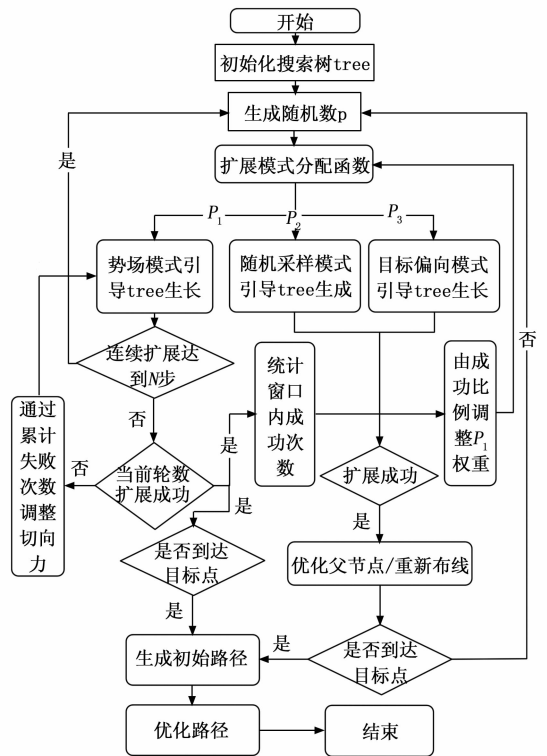


图 6 改进算法流程图

4 仿真实验与性能分析

为了验证改进算法的有效性和可靠性，将提出的融合改进人工势场法的自适应 RRT* 算法分别与传统的 RRT、RRT*、APF 等算法分别在不同应用场景下进行了仿真测试。仿真实验所用测试地图大小为 $500 \text{ cm} \times 500 \text{ cm}$ ，实验过程设置起点坐标为 $(10, 10)$ ，目标点坐标为 $(490, 490)$ ，算法的其他参数见表 1。

依据环境中障碍物的分布特征，可将测试场景划分为简单场景、中等场景、高复杂度场景以及陷阱类场景（如迷宫、U 型障碍物）等。场景复杂度的量化一般由以下几个参数决定：障碍物数量、形状、障碍物面积占

比以及障碍物归一化周长密度。

表 1 算法参数设置

参数名称	参数符合	初始值
引力增益系数	κ_{att}	1
斥力增益系数	κ_{rep}	100
障碍物影响范围	ρ_0	30
动态窗口维护范围	$N_{attempt}$	50
切向力系数初始值	k_{tan}	0
APF 模式概率下限	p_{l_min}	0.1
APF 模式概率上限	p_{l_max}	0.6
目标偏向模式概率	p_3	0.2
随机树扩展步长	d_0	10
父节点重选半径	R_0	30

这里障碍物面积占比定义为： $\varphi=\frac{A_{obs}}{A_{map}}$ ，其中 A_{map} 为地图面积， A_{obs} 为障碍物总面积。当 φ 越大时，可通行的自由空间越少，路径规划的难度相应增大。障碍物的归一化周长密度定义为： $\rho=\frac{P_{total}}{A_{map}}$ 。其中 $P_{total}=\sum_{i=1}^N P_i$ 为障碍物总周长， P_i 为第 i 个障碍物的周长， N 为障碍物个数。为了保证不同尺寸地图之间的可比性，计算 ρ 时需将地图面积 A_{map} 归一化为 1。显然 $\rho\in[0,\infty)$ ，其中 ρ 值越大表示障碍物边界越复杂、越曲折，对应的环境复杂度也越高。根据上述指标，可以对测试场景进行如下量化划分。

简单场景：障碍物数量较少，形状规则，且障碍物面积占比满足 $\varphi<20\%$ ，周长密度 $\rho<5$ 。

中等场景：存在多种几何形状混合，障碍物分布较密集，且满足 $20\%\leq\varphi\leq30\%$ ， $5\leq\rho\leq10$ 。

高复杂度场景：包含大量不规则多边形和狭窄通道，满足 $\varphi>30\%$ ， $\rho>10$ 。

陷阱类场景：以密布着迷宫或 U 型障碍物为典型特征，形成明显“陷阱”结构，通常满足 $\varphi>30\%$ ， $\rho>10$ ，其与高复杂度场景的区别在于障碍布局呈现特殊拓扑结构（如闭合环路或深陷凹槽），对路径规划算法提出更高挑战。

4.1 简单场景测试

图 7 为典型的简单场景，障碍物数量少且几何形状规则，非常适合测试不同算法的基础性能，该图的障碍物面积占比 $\varphi=13.4\%$ ，障碍物的归一化周长密度为 $\rho=2.7$ 。

图 7 中的 (a) ~ (d) 分别为 RRT、RRT*、APF 以及改进算法所得到的路径的对比图。如图 7 (a) 所示，对 RRT 算法，即使环境非常简单，算法的随机树也几乎要把整个地图的自由空间都“覆盖”后才找到可行路径，很明显该算法的效率非常低。如图 7 (b)，

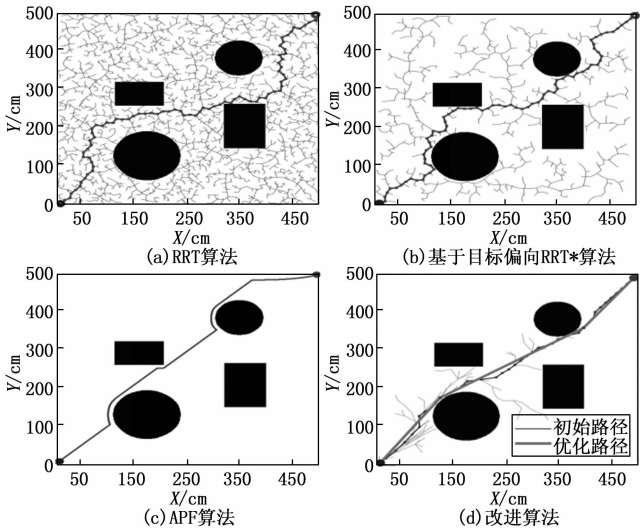


图 7 简单场景下各算法对比

对基于目标偏向的 RRT*，因为有了目标偏置策略，加上 RRT* 算法特有的重新布线策略，不管搜索效率还是路径长度，都有了明显的改进。对 APF 算法，如图 7 (c)，其路径受障碍物形状影响非常大，且算法不稳定性较高。本文提出的改进自适应算法，融合 RRT* 和 APF 的优势，并采用自适应的 3 种模式扩展策略，使得搜索效率有了显著的提升，且最终路径经过优化后也是几种算法中最优的。图 7 (d) 中较细的路径为改进算法产生的初始路径，较粗的路径为对初始路径进行优化后的最终路径，可以看出优化后的最终路径只剩下很少的几个关键控制节点，整个路径也以长直线为主，这样的路径非常适合机器人行进。

表 2 为简单环境下几种算法的性能对比，表中数据为各算法在地图中运行 100 次后取的均值。

表 2 简单环境下各算法仿真数据

平均值	RRT 算法	RRT* 算法	APF 算法	改进算法
搜索时间/s	0.063	0.024	0.015	0.012
迭代次数	2 452	485	582	345
路径长度	912	838	741	672
总节点数	1 988	345	582	267
路径节点数	77	71	582	5/39

分析表 2 可知，改进算法的性能明显优于其他算法，其中路径长度相对于 RRT 算法减少了 26%，相对于 RRT* 算法减少了 20%，相对于 APF 算法减少了 9%，总节点相对于这 3 个算法分别提升了 93.5%、92.9%、99.1%。注意，表 2 中路径节点数 39 为算法得到的初始路径的平均节点数，经过优化后的节点数为 5，即转弯次数为 4，转弯次数仅为原始路径的 10.5%。

4.2 高度复杂场景测试

为了测试改进算法在高度复杂环境中的表现，特选

取了包含高复杂度场景测试的测试地图，如图 8 所示，该地图包括密集障碍物、U 型障碍物、狭窄通道等多种情况，该图的障碍物面积占比 $\varphi=30.1\%$ ，周长密度为 $\rho=11.9$ 。




图 8 高度复杂场景下各算法对比

图 8 中的 (a) ~ (d) 分别是 4 种算法在该地图中的表现。图 8 (c) 明显可以看出传统 APF 算法遇到 U 型障碍物后极易陷入局部最优状态，导致路径规划失败。图 8 (a) 中，RRT 算法最终找到了路径，但是以遍历了整个搜索空间为代价，效率非常低下。图 8 (b) 中，基于目标偏向的 RRT* 算法因为有了目标点的引导，生成的路径长度相对于 RRT 算法的路径更优一些，但是仍存在搜索效率较低的问题。观察图 8 (d)，显然改进算法无论从搜索效率还是路径长度，都明显优于其他算法。

4.3 算法性能分析

4.3.1 算法稳定性分析

为了验证算法的稳定性，在测试地图 8 上，对 RRT* 算法和改进算法各进行 5 000 次运行。由于 RRT 算法效率过低，而 APF 算法又极易陷入局部最优，故这两种算法不参与性能稳定性对比实验。在性对比实验过程中，RRT* 算法的基本参数与改进算法的基本参数一致，最终得到实验结果如表 3 所示。

表 3 复杂环境下算法的数据稳定性

参数 算法	时间均值	时间标准差	路径长度均值	路径标准差	路径节点均值
RRT*	0.43	0.33	1052	97	88
改进算法	0.27	0.13	756	31	11/41

分析表 3 可知，改进自适应算法在复杂环境下的平均路径搜索时间为目标偏向 RRT* 算法的 62.7%，搜索时间的标准差仅为 RRT* 算法的 39.4%，平均可行

路径长度及其标准差分别为 RRT* 算法的 71.8% 和 31.9%，优化后的路径节点数量为 11 仅相当于 RRT* 算法的 12.5%。

图 9 为重复 5 000 次实验得到的两种算法的路径长度频次分布图，观察图 9 可发现基于目标偏向 RRT* 算法在足够复杂的环境中，其规划的路径长度的分布更接近正态分布，且方差较大，表明其规划的路径一致性和稳定性较差。




图 9 目标偏向 RRT* 算法路径频次分布图

而提出的改进自适应算法，在复杂环境中，如图 10 所示，其规划的路径长度的分布整体偏左侧，呈现长尾特征，即改进算法生成的路径长度分布在最左侧（即最优路径侧）的概率最大，且整体数据的期望值更小，意味着得到的路径更短更平直，而数据的方差更小，则意味着更高的算法稳定度。另外，分布图上的两个峰值显然对应于搜索过程中稳定出现的两条主要路径方向。




图 10 改进算法路径频次分布图

4.3.2 自适应切向力系数 k_{tan} 对算法性能影响

为了验证算法中自适应切向力系数 k_{tan} 的性能优势，设置了如图 11 的 500 * 500 测试地图，实验过程的其他参数与表 1 一致。

如图 11 的这类密集分布着 U 型障碍物和迷宫的环境属于典型的“陷阱类场景”，若采用常规 APF 算法或基于目标偏置的 RRT* 算法，则极易陷入局部陷阱从而导致路径规划失败。但如图 11 所示，改进算法不但很好




图 11 算法在迷宫+U 型障碍物环境表现

的完成了路径搜索任务, 且给出了近似最优的路径。

为了验证算法中自适应切向力系数 k_{tan} 的性能优势, 实验过程让 k_{tan} 分别处于自适应模式以及固定 k_{tan} 值分别为 0.2、0.5、0.8, 并把以上 4 种模式分别在图 11 中测试 30 次, 最终得到了自适应切向力系数 k_{tan} 在不同模式下的性能对比图。图 12 显示了切向力系数 k_{tan} 处于不同模式时, 各次实验搜索路径所消耗的时间。可以看出当切向力系数 k_{tan} 取固定值时, 因算法无法根据环境实时调整 k_{tan} 的值, 导致每次实验的路径搜索时间较长, 且各次搜索时间的波动较大, 即搜索时间的方差较大。而当切向力系数 k_{tan} 采用算法提出的自适应模式时, 每次搜索路径的所消耗的时间整体看更短, 且各次搜索时之间的波动也更小, 即时间方差也最小, 表明该模式下算法效率更高、更稳定。




图 12 切向力系数对算法性能的影响

4.3.3 算法时间复杂度分析

在路径规划算法的研究中, 时间复杂度是衡量算法可扩展性和运行效率的重要指标。传统 RRT* 算法在每次迭代中主要包含随机采样与最近邻搜索两个步骤。若当前搜索树包含 n 个节点, 则最近邻搜索的复杂度为 $O(n)$, 若采用空间划分结构 (如 k-D Tree)^[20], 可将复杂度降低至 $O(\log n)$ 。因此, RRT* 算法的整体复杂度一般可表示为: $T_{RRT} = O(n \log n)$ 。融合改进人工势场法的自适应 RRT* 算法在总体框架上保持了 RRT

* 的迭代扩展机制, 其渐进复杂度上界不会劣于 $O(n \log n)$ 。需要额外分析的部分如下:

1) 切向力计算: 在每次扩展时需计算引力、斥力及切向力分量。由于计算仅依赖于当前采样点与邻近障碍物, 操作量为常数级, 即: $T_{force} = O(1)$;

2) 三模式扩展与动态概率调整: 扩展过程中, 算法在 APF 模式、随机采样模式和目标偏向模式之间切换, 模式选择通过概率计算完成, 复杂度为常数时间。动态概率调整基于近期扩展成功率的统计更新, 每次迭代仅涉及简单运算, 故为: $T_{mode} = O(1)$;

3) 路径节点优化: 在得到初始路径后, 算法通过优化重要节点集合生成最终路径, 该过程对路径中节点数 m 呈线性复杂度: $T_{opt} = O(m)$, 这里 $m \ll n$ 。

综上, 改进算法的总体时间复杂度可表示为:

$$T_{proposed}(n) = O(n \log n) + O(m) \tag{13}$$

由于 $m \ll n$, 路径优化步骤对整体复杂度影响有限, 主要开销仍集中在搜索树的构建过程。由此可见, 改进算法在理论复杂度上与 RRT* 保持一致, 仅引入了少量常数级的额外计算, 并不会导致数量级上的增长。在不同规模地图和障碍物密度下, 新增操作的开销占比相对较小, 而实验结果表明这些改进显著提升了搜索效率和路径质量。因此, 可以认为该算法在保持相同复杂度上界的前提下, 实际运行时间较 RRT* 更优, 鲁棒性更强。

5 结束语

针对移动机器人路径规划中的关键技术难题, 提出了一种融合改进人工势场法的自适应 RRT* 算法。该算法通过巧妙地将 RRT* 的全局采样优势与 APF 的局部引导特性相结合, 充分利用两者的优势, 有效地克服了传统方法的固有缺陷。通过引入切向力改进 APF 并采用自适应调整机制, 很好地解决了局部最优陷阱问题; 设计的三模式扩展策略及其基于成功率的动态概率调节, 显著提高了搜索效率和收敛速度; 路径节点优化策略进一步保证了生成路径的实用性和平滑性。仿真实验结果充分验证了算法的优越性能。在多种复杂环境下, 算法在搜索时间、路径长度、节点数量等关键指标上均表现出显著优势, 特别是在处理狭窄通道、U 型陷阱等困难场景时展现出良好的鲁棒性和稳定性, 为移动机器人在复杂场景中的应用提供了可靠的解决方案。当前算法主要基于二维静态环境, 未来工作可将该算法扩展至三维空间并研究其对动态障碍物的实时规避能力。

参考文献:

[1] RASHID A T, ALI A A, FRASCA M, et al. Path plan-

- ning with obstacle avoidance based on visibility binary tree algorithm [J]. *Robotics & Autonomous Systems*, 2013, 61 (12): 1440–1449.
- [2] MEMON K R, MEMON S, MEMON B, et al. Real time implementation of path planning algorithm with obstacle avoidance for autonomous vehicle [C] //2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), New Delhi, India, 2016: 2048–2053.
- [3] LUO Y, DING W, ZHANG B, et al. Optimization of bits allocation and path planning with trajectory constraint in UAV-enabled mobile edge computing system [J]. *Chinese Journal of Aeronautics*, 2020, 33 (10): 2716–2727.
- [4] 王 旭, 朱其新, 朱永红. 面向二维移动机器人的路径规划算法综述 [J]. *计算机工程与应用*, 2023, 59 (20): 51–66.
- [5] 郑 维, 王 昊, 王洪斌. 动态环境下基于自适应步长 Informed-RRT* 和人工势场法的机器人混合路径规划 [J]. *计量学报*, 2023, 44 (1): 26–34.
- [6] 何 雨, 张志安, 韩明明, 等. 基于全向移动机器人路径规划的蚁群算法研究 [J]. *测试技术学报*, 2018, 32 (5): 374–380.
- [7] 郭聚刚, 于军琪, 冯春勇, 等. 基于改进 A* 算法的机器人不平坦地形全局路径规划 [J]. *计算机工程与应用*, 2025, 61 (5): 309–322.
- [8] 仇 新, 孙崇健, 朱文辉. 煤矿环境下改进 Informed-RRT* 路径规划算法研究 [J]. *煤矿机械*, 2024, 45 (8): 191–193.
- [9] 王 磊, 刘晶晶, 齐俊艳, 等. 基于改进人工势场法的 AUV 全局路径规划 [J]. *河南理工大学学报 (自然科学版)*, 2024, 43 (1): 132–139.
- [10] 崔春雷, 陈诗豪, 沈超航, 等. 基于改进 Bi-RRT 的移动机器人路径规划算法 [J]. *计算机测量与控制*, 2022, 30 (5): 181–185.
- [11] 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 [J]. *IEEE*, 2014.
- [12] PU H, WAN X, SONG T, et al. A 3D-RRT-star algorithm for optimizing constrained mountain railway alignments [J]. *Engineering Applications of Artificial Intelligence*, 2024, 130: 12.
- [13] 刘云平, 蒋长胜, 张婷婷, 等. 考虑内部避碰的多无人机有限时间环形编队控制 [J]. *机械工程学报*, 2022, 58 (1): 61–68.
- [14] 杨彦新, 姜香菊. 优化改进 RRT* 和 APF 的无人机航迹规划算法 [J/OL]. *电光与控制*, 1–9 [2025–08–28]. <https://link.cnki.net/urlid/41.1227.TN.20250604.0904.004>.
- [15] WANG Z, IM N. Enhanced artificial potential field for MASSs path planning navigation in restricted waterways [J]. *Applied Ocean Research*, 2024, 149: 18.
- [16] 张喜超, 尹 勇. 基于改进 RRT* 算法的无人船路径规划 [J]. *中国航海*, 2023, 46 (1): 143–147.
- [17] CHEN Y, BAI G, ZHAN Y, et al. Pathplanning and obstacle avoiding of the USV based on improved ACO-APF hybrid algorithm with adaptive early-warning [J]. *IEEE Access*, 2021 (99): 1.
- [18] 黄月英, 罗文广. 改进人工势场法的移动机器人路径规划研究 [J]. *柳州: 广西科技大学学报*, 2025.
- [19] 张国胜, 李彩虹, 张耀玉, 等. 基于改进人工势场法的机器人局部路径规划 [J]. *计算机工程*, 2025, 51 (1): 88–97.
- [20] 齐成龙. 基于三维激光扫描的矿山法隧道超欠挖及平整度智能化检测 [J]. *铁路技术创新*, 2024 (2): 99–105.
- [21] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2014, 37 (9): 1904–1916.
- [22] ZOU Z, TEO P, YALAMANCHILI A, et al. Optimizing deep learning models: CNN-RNN augmentation with grad-CAM analysis for predicting pneumonitis from pre-treatment CT images [J]. *International Journal of Radiation Oncology, Biology, Physics*, 2024, 120 (s2): e670.
- [23] TAILANIANM, PARDO L, PABLO M. U-Flow: a U-shaped normalizing flow for anomaly detection with unsupervised threshold [J]. *Journal of Mathematical Imaging and Vision*, 2024, 66 (4): 678–696.
- [24] YU J, ZHENG Y, WANG X, et al. Fastflow: Unsupervised anomaly detection and localization via 2d normalizing flows [J]. *Arxiv Preprint Arxiv*: 211107677, 2021.

(上接第 195 页)