

适用于三维环境快速收敛的路径规划算法研究

郭云舒¹
GUO Yunshu

摘要

RRT* 算法因适应高维、渐近最优的特性成为运动规划领域的重要标准算法,但因全局随机采样易导致早期搜索方向偏差、复杂环境易陷局部困境等问题。基于此,文章提出一种改进 RRT* 算法在全局随机采样基础上引入限制区域启发式采样,按启发偏向值概率选择采样方式以缩减搜索空间;同时单次启发式采样迭代生成多个候选点并计算代价,动态调整代价函数权值优化采样选择,提升采样效率并减少冗余路径。Python 仿真实验表明,改进算法在不同环境下性能更优,复杂场景中较 RRT* 算法平均速度提升 94.53%、路径成本降低 17.39%,验证了其有效性与优越性。

关键词

路径规划; RRT*; 六自由度机械臂; 启发式概率采样

doi: 10.3969/j.issn.1672-9528.2026.02.005

0 引言

路径规划是智能体自主作业的核心技术,其性能直接决定智能体在复杂场景中的作业安全性、效率与精度。随着智能装备应用场景的不断拓展,路径规划已从传统二维平面任务全面转向三维空间作业,对三维路径规划提出刚性需求。三维环境的特殊性显著增加了规划难度,智能体需应对空间通道狭窄、多障碍物交叉遮挡等问题。

当前路径规划算法主要分为基于搜索^[1]、基于采样^[2]和基于启发式智能^[3]三类:基于搜索的算法实时性较好,但路径连续性不足,在高维空间中由于扩展节点数量剧增导致计算量过大,且高度依赖精细地图建模^[4];基于启发式智能的算法虽适配复杂障碍环境,却难以保证全局最优,性能受参数设置与初始值影响显著^[5];基于采样的算法凭借适配高维空间、无需精细地图的优势,有效弥补了前两类算法的缺陷^[6],其中 RRT 算法因搜索速度快、探索能力强且具备概率完备性,成为三维路径规划的主流选择,但仍存在初始路径质量差、规划效率低、复杂环境下可行路径难寻等问题^[7]。

为优化 RRT 算法性能,学者们提出了诸多改进方案:RRT-connect 通过双向扩展提升路径生成成功率与速度^[8];RRT* 引入父节点重连机制实现渐近最优^[9];informed-RRT* 通过限制采样区间减少无效采样^[10];F-RRT* 算法采用二分法创建节点替代固定步长扩展,优化初始路径质量^[11];FC-RRT* 算法在其基础上引入 RRT-Connect 双向交替连接策略,加速初始路径搜索^[12];FFC-RRT* 算法进一步加入启发式概率采样,根据扩展失败次数动态调整采样方式,兼顾路径质

量与初始规划收敛速度^[13]。然而,它们并未完全考虑到相应算法在三维环境中的适用性和有效性。为此,本文提出一种改进 RRT* 路径规划算法,适用于三维环境且快速收敛。

1 路径规划算法设计

FFC-RRT*^[13] 的启发式概率采样虽在一定程度上解决了 RRT* 采样随机性导致的节点质量问题,但本质是“先采样后筛选”的妥协式随机采样,且其路径优化仅依赖 RRT* 重连接与 F-RRT*^[11] 的“findreacheast”机制,缺乏对采样点最优选择的考量。为提升采样质量与效率、减少冗余路径,本文提出的算法包含两项改进:一是通过更优约束采样进一步缩小区间并在限定范围内采样;二是引入采样点最优化策略,设计自适应权值成本函数,通过逐一计算采样候选点成本筛选最优采样点。

1.1 更优约束采样

更优约束采样即进一步限制采样区间,将 FFC-RRT* 中先采样再进行限制区域筛选的过程优化为直接在限制区间内采样,舍弃 FFC-RRT* 中的妥协随机采样,仅通过启发式概率函数计算数值大小选用随机采样或限制区域采样的方法得到采样点,使限制区域采样成为路径扩展中更大可能选择的采样方法,FFC-RRT* 算法和改进算法的采样区间对比如图 1 所示,白色区域表示随机采样的范围,灰色区域表示约束采样的范围。图 1(a)和(b)中, a 、 b 分别为随机树 TreeA、TreeB 最新添加节点。FFC-RRT* 在二维空间中,以 a 、 b 为圆心, ab 连线为半径画圆,两圆交集为采样限制区间;本文算法移植至三维空间,将该逻辑复现为以 ab 线段为直径生成球形采样区域。本文算法更优约束采样连接 ab 并将该线段作为直径生成一个球形空间,将采样区域限制在该球形区

1. 武汉轻工大学电气与电子工程学院 湖北武汉 430023

域内,如图1(b)所示,同时,优化近采样逻辑,减少无效节点,提升算法效率,显然,更优约束采样通过进一步缩小采样范围并优化近采样逻辑减少了无效节点产生,提高了算法的效率。




图1 FFC-RRT* 算法和改进算法的采样区间对比

1.2 采样点最优化

通过对 FFC-RRT* 算法的分析得知该算法对于采样点的最优选择缺乏考虑,本文的算法在采样过程中进一步增加了采样点最优化的机制,具体实现过程为:在限制区间中进行 n 次采样,将采样到的 n 个点进行非障碍物区间筛选得到候选点,然后对候选点逐一进行成本计算,并从中选出成本最低的候选点作为限制区域采样最优点返回,如图2所示。




图2 采样最优点选取示意图

在图2中,点 a 和 b 分别为随机树 TreeA 和 TreeB 中最近添加的节点,图中灰色的点代表执行一次限制区间采样函数得到的候选点,数量为 n ,黑色点 p 为最佳候选点也是最终选用的采样点, D_1 表示点 p 到 ab 连线的最短距离, D_2 表示点 p 到非当前扩展树的末端点的距离。

参数 n 控制限制区间内采样的覆盖范围与密度: n 越大,探索越充分但计算代价越高, n 过小,则采样点成本对比缺乏参考性。为此,本文选取多个 n 值 ($n=5,10,15,20,25,30$) 在多地图中各开展 15 次对比实验,评估路径规划成功率、路径长度与计算时间三项指标,最终数据以保留两位小数四舍五入的方式记录,因未出现规划失败情况,所以在图表中默认规划成功率为 100%,实验均值统计于表1中。结果显示:地图1中, $n=20$ 时以极小时间代价换取更短路径;地图2、3中, $n=20$ 或 $n=25$ 时时间消耗与路径成本表现更优。综合

参数普适性,最终选定 $n=20$ 作为默认配置,兼顾采样密度与算法运行效率。

表1 多个地图不同采样次数设置结果

指标 (平均值)	$n=5$	$n=10$	$n=15$	$n=20$	$n=25$	$n=30$
地图1						
时间消耗	1.00	1.02	1.15	1.16	1.29	1.83
路径成本	37.33	38.72	38.67	36.41	38.39	40.94
地图2						
时间消耗	1.34	1.17	1.30	1.03	0.98	1.32
路径成本	31.77	31.00	31.13	30.39	30.18	31.64
地图3						
时间消耗	1.52	1.43	1.33	1.35	1.28	1.59
路径成本	35.81	35.95	36.98	34.82	35.54	37.34

1.2.1 成本函数设计

成本函数用于全面评估从当前候选点到目标点的最短路径成本,同时考虑了候选点到最短路径的距离以及到目标点的距离,该函数可表示为:

$$\text{cost}(p) = w_1 \times D_1 + w_2 \times D_2 \quad (1)$$

式中: p 为候选点; D_1 为点 p 到 ab 连线的最短距离,该值越近,越容易生成光滑路径; D_2 为点 p 到非当前扩展树的末端点的距离,该值越近越容易使双树连接; w_1 为 D_1 的权值,表示点 p 到 ab 连线的最短距离对成本的影响程度; w_2 为 D_2 的权值,表示从点 b 到候选点 p 的距离对成本的影响程度; $\text{cost}(p)$ 值越大说明该点越远离目标点和中心连线,则经过该点生成的路径越曲折且靠近目标点的速度越慢,反之,则路径更平滑且能更快速靠近目标点。经此前介绍的更优约束采样并进行非障碍物区间筛选得到候选点后,对所有候选点逐一进行成本计算,选取 $\text{cost}(p)$ 成本函数计算值最小的点作为最优采样点。

1.2.2 成本函数权值自适应

成本函数固定权重难以适配复杂动态场景,易导致路径质量下降甚至规划失败。本文引入自适应权值调整机制,根据环境状态动态调节子目标项权重,提升路径鲁棒性与整体性能。该机制将路径规划分为4种情况并针对性调整权重:

(1) 收敛阶段。两树临近未连接,增大靠近另一树的权重以加速连接,权值 w_1 应减小, w_2 应增大;

(2) 探索阶段。两树距离较远增大向双树末端连线靠拢的权重以推进收敛,权值 w_1 应增大, w_2 应减小;

(3) 绕行阶段。障碍物密集或扩展失败多,增大探索权重以扩大搜索范围,权值 w_1 应增大, w_2 应保持或略减;


(4) 路径质量不佳时增大向中线靠拢权重以优化路径,权值 w_1 应增大, w_2 应略增。

阶段判定依据借助扩展成功次数、失败次数、失败率与双树当前末端点的连线长度对完整空间对角线长度的占比(这里称为空间比 dist_ratio)来进行判定。具体计算方式是:

$fail_ratio = \text{失败次数} / \text{成功次数} + 1$ 。 $dist_ratio < 0.2$ 为收敛阶段， $dist_ratio > 0.5$ 为探索阶段， $fail_ratio > 1$ 为绕行阶段，成功次数大于失败次数为路径质量不佳。

2 实验与分析

为全面验证本文算法的优越性，在 $20 \times 20 \times 20$ 三维固定空间中设置三种分别含球形、柱体、立方体静态障碍物的地图，如图 3 所示，将本文算法与 RRT*、FFC-RRT* 进行对比实验。实验参数设定：步长为 2，本文算法限制区域采样候选点数量 20，最大迭代次数 4 000 次；实验平台为 Windows 11 系统（Intel Core i7-14650HX 处理器、16 GB 内存），三种算法均成功规划出初始点到目标点的无碰撞有效路径。




(a) 球形障碍物地图 (b) 柱体障碍物地图 (c) 复杂障碍物地图

图 3 障碍物地图

2.1 球形障碍物地图

场景 1 中，起始点 (2.0, 2.0, 2.0) 终点 (16.0, 16.0, 16.0)，图 4 展示三种算法路径扩展结果，实验重复 50 次，数据汇总于表 2 中。



(a) RRT* (b) FFC-RRT* (c) 本文算法

图 4 场景 1 中不同算法生成的路径

表 2 场景 1 中不同算法路径规划数据

算法	时间消耗	路径成本	采样点数	成功率 / %
RRT*	22.134	36.522	4 000	84
FFC-RRT*	1.226	31.344	60	100
本文算法	0.993	30.421	49	100


结果显示：FFC-RRT* 与本文算法的旁支显著少于 RRT*，因 RRT* 需迭代至最大次数筛选最优路径，而前两者采用双树扩展，连接后即停止，且二者通过三角不等式优化策略，减少低质量节点与冗余路径，路径成本优于 RRT*。对比可知，本文算法扩展初期分支更聚集，源于其采样区域限制更严格，后续实验亦有类似体现。

表 2 实验数据表明，本文算法平均时间消耗最低，仅为 0.993 s，平均路径成本上相较于其他两种算法也更低，

为 30.421 m，该算法平均采样点数为 46，对比 FFC-RRT* 在平均时间消耗方面降低了 19.05%，平均路径成本上降低了 2.95%，在效率和路径优化上有明显优势。此外，本文算法和 FFC-RRT* 表现出 100% 的路径规划成功率，反观原始 RRT* 算法成功率仅为 84%，可以得出由于本文算法和 FFC-RRT* 算法采用启发式概率采样和双树扩展策略表现出在复杂空间中具有较强的鲁棒性。

2.2 柱体障碍物地图

场景 2 中，起始点 (2.0, 2.0, 2.0) 终点 (16.0, 16.0, 2.0)，以不同高度、粗细、位置的柱体为障碍物，柱体底部 $z=0$ ，其余设置同场景 1。该场景需算法在柱体间穿行或向 z 值较高区域拓展路径，复杂度高于场景 1。图 5 为三种算法的规划结果，多次实验平均数据汇总于表 3。



(a) RRT* (b) FFC-RRT* (c) 本文算法

图 5 场景 2 中不同算法生成的路径


表 3 场景 2 中不同算法路径规划数据

算法	时间消耗	路径成本	采样点数	成功率 / %
RRT*	21.907	41.648	4000	94
FFC-RRT*	1.245	36.016	60	100
本文算法	1.215	33.185	58	100

该实验结果与场景 1 类似，本文算法在时间消耗、路径成本、采样点数和成功率上均能表现出三者间最优的性能，对比 FFC-RRT* 在平均时间消耗方面降低了 2.43%，平均路径成本上降低了 7.86%。

2.3 复杂障碍物地图

场景 3 中，起始点和终点分别设置为 (2.0, 2.0, 2.0) 和 (16.0, 16.0, 16.0)，障碍物为高度等于空间高度的立方体，仅立方体间存在狭窄路径，该场景更能体现算法的路径探索与寻优能力。三种算法表现如图 6 所示，实验数据汇总于表 4 中。



(a) RRT* (b) FFC-RRT* (c) 本文算法

图 6 场景 3 中不同算法生成的路径

结果与前述场景类似：FFC-RRT* 扩展过程中旁支较多，

在障碍物大、可行区间狭窄的环境中需花费更多时间探索路径，本文算法凭借更优采样策略，可快速发现可行区间，以更少采样次数完成路径扩展。本文算法对比 FFC-RRT* 在平均时间消耗方面降低了 22.25%，平均路径成本降低了 3.19%，在保证效率提升的情况下有效减少了路径成本。

表 4 场景 3 中不同算法路径规划数据

算法	时间消耗	路径成本	采样点数	成功率 /%
RRT*	19.829	44.731	4 000	96
FFC-RRT*	1.396	38.170	76	100
本文算法	1.085	36.952	60	100

3 总结与展望

本文针对路径规划问题，提出改进算法，以提升复杂场景下算法的实用性、稳定性与规划效率。该算法引入限制区域采样，在起止点连线的球形空间内采样并计算候选点成本，结合自适应权值调整与最佳候选点数量定义，降低原始算法随机性，提升路径质量，将算法移植至三维空间，适配智能体执行需求。通过与 RRT*、FFC-RRT* 算法的仿真实验对比，验证了本文算法在路径质量、避障安全性与三维适应性上的优势，且运行速度与规划效率显著提升。同时，研究也存在不足：物理实验场景较简单，未涉及动态障碍物实时规划；成本函数权值调整参数依赖人工设定。未来将优化采样策略与权值机制，探索动态环境应用，推动算法在工业自动化领域的深度融合。

参考文献：

[1]BHATTACHARYA S, LIKHACHEV M , KUMAR V .Topological constraints in search-based robot path planning[J]. Autonomous robots, 2012, 33(3):273-290.

[2]ELBANHAWI M , SIMIC M .Sampling-based robot motion planning: a review[J].IEEE access, 2014, 2(1):56-77.

[3]KALA R , SHUKLA A , TIWARI R .Fusion of evolutionary algorithms and multi-neuron heuristic search for robotic path planning[C]//2009 World Congress on Nature & Biologically Inspired Computing (NaBIC). Piscataway:IEEE,2009:684-689.

[4]ZHANG L D, CAI K Q, SUN Z W , et al. Motion planning for robotics: a review for sampling-based planners[J].Biomimetic intelligence and robotics,2025,5(1):100207.

[5] HERNÁNDEZ D S, GARCIA J, GUTIÉRREZ A I B. Evaluation of metaheuristic optimization algorithms applied to path planning[J/OL]. International journal of advanced robotic systems, 2024[2025-12-31].https://www.researchgate.net/publication/385106408_Evaluation_of_metaheuristic_

optimization_algorithms_applied_to_path_planning. DOI:10.1177/17298806241285302.

[6]KYAW P T , LE A V , MOHAN R E, et al. Greedy heuristics for sampling-based motion planning in high-dimensional state spaces[EB/OL].(2025-11-14)[2025-12-22].https://doi.org/10.48550/arXiv.2405.03411.

[7]HUANG H L , TAN G, JIANG L L.Robot path planning using improved ant colony algorithm in the environment of internet of things[J/OL].Journal of robotics, 2022[2025-12-23]. https://doi.org/10.1155/2022/1739884.

[8]LIN Y S, WU D, WANG X,et al.Improving rrt-connect approach for optimal path planning by utilizing prior information[J].International journal of robotics & automation, 2013, 28(2):146-153.

[9]NOREEN I , KHAN A , HABIB Z .Optimal Path planning using RRT* based approaches: a survey and future directions[J/OL].International journal of advanced computer science and applications,2016[2025-12-22].https://thesai.org/Publications/ViewPaper?Volume=7&Issue=11&Code=IJACSA&SerialNo=14.

[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/OL]//2014 IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway:IEEE,2014[2025-12-25]. https://ieeexplore.ieee.org/abstract/document/6942976.DOI: 10.1109/IROS.2014.6942976.

[11]LIAO B, WAN F Y, HUA Y, et al.F-RRT*: an improved path planning algorithm with improved initial solution and convergence rate[J].Expert systems with applications,2021,184:115457.

[12]WANG J , LI J Y, SONG Y K,et al.FC-RRT*: a modified RRT* with rapid convergence in complex environments[J]. Journal of computational science,2024,77:102239.

[13]SU Z, LÜ Q, HUANG Z, et al. FFC-RRT*: an adaptive hybrid sampling path planning algorithm with rapid initial solution convergence[J].Intelligent service robotics,2025,18(3):499-512.

【作者简介】

郭云舒（2000—），女，湖南郴州人，硕士研究生，研究方向：机械臂的路径规划。
(收稿日期：2025-12-17 修回日期：2026-02-05)