

DOI: 10.19650/j.cnki.cjsi.J2514668

融合碰撞脱困机制与动态高斯采样的 机械臂路径规划算法^{*}

孙明晓, 李 强, 栾添添, 贵 放, 张秋雨
(哈尔滨理工大学自动化学院 哈尔滨 150080)

摘 要:针对传统路径规划算法存在采样效率低、环境适应性差、收敛速度慢的问题,提出了一种融合碰撞脱困机制与动态高斯采样的机械臂路径规划算法。首先,通过引入动态调节的混合高斯采样策略,融合碰撞脱困、障碍物规避、目标导向及均匀探索 4 种高斯采样分量,通过实时评估连续碰撞次数、与目标的距离等状态,自适应地调整各分量权重,将采样点集中于合适的区域,从而在全局探索与局部脱困之间取得动态平衡,显著提升复杂环境下的采样效率。其中,碰撞脱困分量根据碰撞次数和位置,缩小采样范围至可行空间,提高脱困效率。其次,针对不同的局部环境,提出多级自适应步长扩展机制,该机制综合考虑连续碰撞反馈、局部障碍物密度及全局规划进程,有效减少狭窄空间中的反复碰撞与在开阔区域的低效探索。最后,通过融合 K 维树(KD-Tree)索引机制、去冗余机制与早停机制的联合优化策略,显著提升算法的计算效率与收敛速度。仿真实验表明,与动态变采样区域 RRT 路径规划算法(DVSA-RRT)相比,本算法在狭窄通道地图中规划时间减少了 87.41%,采样点数减少了 91.01%,路径长度缩短了 7.46%,能够高效地规划出安全、平滑且渐近最优的路径。此外,基于机械臂实物平台的实验验证了该算法在实际场景中的有效性,所规划的路径能够满足机械臂表面粗糙度测量的任务需求。

关键词: 路径规划;碰撞脱困;高斯采样;机械臂;最优快速扩展随机树

中图分类号: TP242 TH862 **文献标识码:** A **国家标准学科分类代码:** 460.40

Robotic arm path planning based on dynamic Gaussian sampling and collision recovery

Sun Mingxiao, Li Qiang, Luan Tiantian, Ben Fang, Zhang Qiuyu

(School of Automation, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: To address the low efficiency, poor adaptability, and slow convergence of traditional path planning algorithms, this paper proposes a robotic arm path planning method integrating collision recovery with dynamic Gaussian sampling. The method employs a mixed Gaussian sampling strategy that dynamically adjusts weights for four components: Collision recovery, obstacle avoidance, goal-biasing, and uniform exploration. By evaluating real-time states such as consecutive collisions and goal proximity, it strikes a dynamic balance between global exploration and local recovery, significantly enhancing sampling efficiency in complex environments. The collision recovery component further enhances performance by narrowing the sampling range to the feasible space based on collision frequency and position. Furthermore, a multi-level adaptive step-size extension mechanism is introduced, which adjusts to local environments by considering collision feedback, obstacle density, and global planning progress. This reduces repeated collisions in narrow passages and inefficient exploration in open areas. Finally, a joint optimization strategy combining a K-dimensional tree (KD-Tree), redundancy removal, and an early-stopping mechanism boosts computational speed and convergence. Simulation results indicate that compared with dynamic variable sampling area RRT (DVSA-RRT), the proposed method reduces planning time by 87.41%, sampling nodes by 91.01%, and path length by 7.46% in narrow passages, while generating safe, smooth, and asymptotically optimal paths. Moreover, physical experiments verify its effectiveness in actual scenarios, ensuring the planned paths meet surface roughness measurement requirements.

Keywords: path planning; collision recovery; Gaussian sampling; robotic arm; optimal rapidly-exploring random tree

收稿日期: 2025-11-10 Received Date: 2025-11-10

^{*} 基金项目: 黑龙江省自然科学基金项目(YQ2024E047)、黑龙江省优秀青年教师基础研究支持计划项目(YQJH2024067)资助

0 引言

在现代精密制造与质量控制领域,工件表面粗糙度的精确测量是评估产品性能以及确保装配精度的关键环节。随着工业自动化水平的提升,采用多自由度机械臂搭载各类传感器进行自动化测量已成为一种高效的技术手段。路径规划作为机械臂自主运行的关键技术^[1],其效率和质量决定生产线的生产效率与产品的品质。特别是在狭窄空间场景中,设计能够快速生成较短且平滑的无碰撞的路径规划算法,已成为一个持续的研究热点与重大挑战。在使用机械臂测量工件表面粗糙度的过程中,测量仪器需按压在工件表面,且由于测量仪器对压力有较高的精度要求,抬起测量仪器的过程将产生巨大误差,所以评估表面粗糙度的过程需要持续接触工件表面,即限定机械臂末端运动高度。因此,需要将机械臂的运行场景从传统的3D场景更换为2D场景。

目前,路径规划算法主要包括以Dijkstra算法^[2]、A*算法^[3]为代表的图搜索算法,以蚁群算法(ant colony optimization, ACO)^[4]、遗传算法(genetic algorithm, GA)^[5]、粒子群算法(particle swarm optimization, PSO)^[6]为代表的启发式算法,以深度Q网络(deep Q-network, DQN)^[7]为代表的机器学习算法,以概率路图算法^[8](probabilistic roadmap, PRM)、快速扩展随机树(rapidly-exploring random tree, RRT)^[9-10]为代表的采样算法以及人工势场算法(artificial potential field, APF)^[11]。Dijkstra算法因其搜索过程的盲目性而效率低下;A*算法的性能严重依赖于启发函数;ACO收敛速度慢,参数敏感;PSO易发生震荡;GA面临早熟收敛、编码复杂问题;DQN依赖特定环境的离线训练,泛化能力受限;PRM难以适应狭窄通道环境。相较之下,RRT算法因其具备全局探索能力、概率完备性好,能够有效避免局部最优。尽管如此,RRT算法仍存在采样效率低、收敛速度慢、环境适应性差等问题。

为解决RRT算法的不足,相关学者进行了一系列改进研究。栾添添等^[12]提出动态变采样区域RRT路径规划算法(dynamic variable sampling area RRT, DVSA-RRT),旨在减少搜索的盲目性。然而该方法无法有效应对凹形障碍物。陈丹等^[13-14]将RRT与APF结合,但势场引导会使算法陷入局部最小值。陈正升等^[15]提出了一种结合图搜索与批量采样的多知情集策略,以提高在狭窄环境下的搜索效率。但初始路径不佳时,知情集的有效性将受影响。刘小松等^[16]提出重定义采样区域与变引力策略,以缩小无效搜索空间并减少采样点。但无法有效应对长条形或凹形等特殊形状的障碍物。Kim等^[17]在知情最优快速扩展随机树(informed optimal

rapidly-exploring random tree, Informed-RRT*)^[18]基础上对非相邻节点进行插值,构建新的无碰撞连接,优化了局部连接,从而加速收敛。然而此算法对初始解具有依赖性,可能陷入局部最优。龙厚云等^[19]将最优快速扩展随机树(optimal rapidly-exploring random tree, RRT*)^[20-21]与A*算法结合,依据改进的A*代价函数选择序列中的最优点进行扩展。但是,该算法的性能严重依赖于A*启发函数,批量采样会产生大量计算开销,且最优点的选择仍具贪婪属性,陷阱环境中可能引导随机树过早进入死胡同。

在上述研究基础上,针对RRT算法存在的采样效率低、收敛速度慢、环境适应性差等问题,本文提出一种改进的RRT*算法,即融合碰撞脱困机制与动态高斯采样的RRT*路径规划算法(dynamic Gaussian sampling and collision recovery RRT*, DGCR-RRT*)。DGCR-RRT*算法一方面引入碰撞脱困机制,实现狭窄通道的快速脱困,提出动态调节的混合高斯采样策略,将采样集中于合适区域,提高采样效率。另一方面,引入多级自适应步长扩展机制,显著提升算法对不同局部环境的适应性。此外,针对收敛速度慢的问题,提出联合优化策略,降低索引时间、减少冗余分支、避免不必要迭代,实现快速收敛。

1 算法描述和分析

1.1 算法框架

DGCR-RRT*算法主要由扩展新节点、局部重写重连、联合优化策略、路径简化与平滑构成,算法流程如图1所示。

1.2 动态调节的混合高斯采样

DGCR-RRT*算法的采样策略能够在狭窄通道环境下,将采样范围集中在通道内部,在多障碍物环境下,能够在有效方向上的障碍物周围增加采样,此外,采样过程能够保持一定的随机性,避免陷入局部最优困境,DGCR-RRT*算法扩展新节点流程如图2所示。

DGCR-RRT*算法根据不同环境的需要,设计4种类型的高斯采样函数,包含碰撞脱困高斯分量、目标导向高斯分量、障碍物避免高斯分量以及均匀探索高斯分量,通过自适应系数加权融合,实现混合高斯采样,可以在复杂环境中高效率地完成采样任务。DGCR-RRT*的采样表达式如式(1)~(2)所示。

$$P(x) = \sum_{i=1}^k w_i \times N(x | \mu_i, \Sigma_i) \quad (1)$$

$$\sum_{i=1}^k w_i = 1 \quad (2)$$

式中: k 是分量的数量; x 是坐标采样点; w_i 是第 i 个分量的权重。 $N(x | \mu_i, \Sigma_i)$ 是第 i 个高斯分布的概率密度函




图1 算法流程

Fig. 1 Algorithm flow

数; μ_i 是第 i 个分量的均值; Σ_i 是第 i 个分量的协方差矩阵。

碰撞脱困分量旨在实现脱困策略,在因连续碰撞而陷入受困状态时激活。此时,维护一个记录最近碰撞点的队列 P_{coll} 。该分量均值 μ_{coll} 的表达式如式(3)~(4)所示。

$$P_{coll} = \{p_1, p_2, \dots, p_k\} \quad (3)$$

$$\mu_{coll} = \text{RandomChoice}(P_{coll}) \quad (4)$$

式中: p_1, p_2 和 p_k 为记录的碰撞点;RandomChoice 为随机函数。该分量的标准差 σ_{coll} 设为较小固定值,确保采样点围绕碰撞中心,提供局部规避引导。

目标导向分量旨在将探索过程引向目标点,以加速规划进程。该分量均值 μ_{goal} 固定为目标坐标,标准差 σ_{goal} 根据目标距离变化采用自适应设计,从而在全局探索与局部优化之间取得平衡。 σ_{goal} 的表达式如式(5)所示。

$$\sigma_{goal} = \sigma_{init_goal} \times \max\left(\frac{d_{target}}{d_{overall}}, \gamma_{goal_sigma}\right) \quad (5)$$




图2 扩展节点流程

Fig. 2 Expanding node flow

式中: d_{target} 为当前随机树中离目标最近的节点到目标点的距离; $d_{overall}$ 为规划任务的起点与目标点之间的总直线距离; $d_{target}/d_{overall}$ 反映当前进展的归一化度量; σ_{init_goal} 为初始标准差; γ_{goal_sigma} 为最小缩放因子,以防止标准差过小导致采样过度收敛。

障碍物规避分量旨在引导树在探索过程中主动绕开障碍物,该分量标准差 $\sigma_{obs_dynamic_val}$ 设为固定值,表达式如式(6)所示。

$$\sigma_{obs_dynamic_val} = grid \times \beta_{obs_sigma} \quad (6)$$

式中: $grid$ 为网格分辨率; β_{obs_sigma} 为缩放因子。

障碍物规避分量的 μ_{obs} 的选择需要识别出与当前规划任务最相关的障碍物,遵循两阶段的筛选逻辑,首先,筛选预设半径内的障碍物形成候选集;其次,根据目标方向向量与候选障碍物向量的点积进行方向筛选;最后,从集合 O_{final} 中随机选择一个障碍物的中心点设置为 μ_{obs} ,若 O_{final} 为空,则选择全局中距离 X_{latest} 最近的障碍物。半径筛选过程如式(7)所示,方向筛选过程如式(8)~(9)所示。

$$O_{radius} = \{o_i \in O_{all} \mid d(X_{latest}, o_i) \leq R_{filter}\} \quad (7)$$

$$O_{final} = \left\{ o_i \in O_{radius} \mid \frac{\vec{v}_{goal} \cdot \vec{v}_{obs_i}}{\|\vec{v}_{goal}\| \cdot \|\vec{v}_{obs_i}\|} > T_{dot} \right\} \quad (8)$$

$$\mu_{obs} = \begin{cases} \text{RandomChoice}(O_{final}), & O_{final} \neq \emptyset \\ \{o_j \in O_{all} \mid \argmin d(X_{latest}, o_j)\}, & O_{final} = \emptyset \end{cases} \quad (9)$$

式中: O_{all} 是所有障碍物中心的集合; o_i 为其中一个障碍物; X_{latest} 是当前树中最新添加的节点; $d(X_{latest}, o_i)$ 用于计算 X_{latest} 和 o_i 直线距离; R_{filter} 为用于初步筛选的半径阈值; O_{final} 为经过半径和方向筛选的候选集; $\vec{v}_{goal}$ 为从最新节点到目标的方向向量; $\vec{v}_{obs_i}$ 为最新节点到障碍物 o_i 的方向向量; T_{dot} 为两个方向夹角的余弦值的阈值; μ_{obs} 是该高斯分量最终的均值; $\text{RandomChoice}(O_{final})$ 表示从候选集 O_{final} 中随机选择一个元素作为 μ_{obs} ; $\text{argmin } d(X_{latest}, o_j)$ 为构成 $d(X_{latest}, o_j)$ 最小值的 o_j 。

均匀探索分量旨在提供必要的全局探索能力,防止算法因依赖其他分量的引导策略而陷入局部最优。为实现大范围的无偏采样,该高斯分量的均值,该分量均值 $\mu_{uniform}$ 固定为区域的中心,标准差 $\sigma_{uniform}$ 设为较大固定值,以确保采样点能广泛地覆盖整个规划空间。

混合高斯采样的核心在于其权重的动态调整,调整过程依次判断当前规划是否处于受困状态、优化状态和探索状态,并启用相应的权重调整策略。

设置受困状态旨在从局部困境中脱离,当连续碰撞次数 collision_{count} 超过预设阈值 collision_{boost} , 且记录最近碰撞点的队列 RCP 不为空时,算法即判定进入受困状态。该状态的判断条件如式(10)~(11)所示。

$$\text{collision}_{count} \geq \text{collision}_{boost} \quad (10)$$

$$RCP \neq \emptyset \quad (11)$$

式中: collision_{count} 记录树在扩展时,因碰撞而连续失败的次数; collision_{boost} 为次数阈值; RCP 为存储近期碰撞点坐标的队列。

此状态下,使用碰撞脱困机制。碰撞脱困分量被赋予一个主导性权重,以强制采样集中在近期发生碰撞的区域进行高精度探索。目标导向分量的权重显著降低,减少盲目朝向目标的指引带来高频次碰撞。均匀探索与障碍物规避分量的权重也被大幅削弱,以避免将计算资源浪费在与当前困境无关的区域。权重调整如式(12)所示。

$$\begin{cases} w'_{coll} = w_{coll} \times \gamma_{coll} \\ w'_{goal} = w_{goal} \times \gamma_{goal} \\ w'_{obs} = w_{obs} \times \gamma_{obs} \\ w'_{uniform} = w_{uniform} \times \gamma_{uniform} \end{cases} \quad (12)$$

式中: w' 代表更新后的权重; w 代表更新前的权重; γ_{coll} 为放大因子; γ_{goal} 为极小缩放因子; γ_{obs} 和 $\gamma_{uniform}$ 为一般缩放因子。

其次判断是否为优化状态。当已找到一条完整路径,或当前树到目标的距离 d_{target} 已小于距离阈值时,该状态触发。其判断条件如式(13)~(14)所示。

$$d_{target} < (d_{overall} \times TO_GOAL_{threshold} \times 2) \quad (13)$$

$$\text{path_found} = \text{True} \quad (14)$$

式中: path_found 为布尔标志; 当找到完整路径时为 True ; $TO_GOAL_{threshold}$ 用于判断是否接近目标的距离阈值; d_{target} 和 $d_{overall}$ 分别为当前最近节点到目标的距离和总距离。

在此阶段,采样策略将转向路径优化,提升目标导向和障碍物规避分量的权重,以加速收敛,降低均匀探索分量权重,将计算资源集中于对现有路径的优化,减少不必要的全局搜索,提升路径质量并加速收敛,其过程如式(15)所示。

$$\begin{cases} w'_{goal} = w_{goal} \times \lambda_{goal} \\ w'_{obs} = w_{obs} \times \lambda_{obs} \\ w'_{uniform} = w_{uniform} \times \lambda_{uniform} \\ w'_{coll} = w_{coll} \end{cases} \quad (15)$$

式中: w' 代表更新后的权重; w 代表更新前的权重; λ_{goal} 和 λ_{obs} 均为大于1的放大因子; $\lambda_{uniform}$ 为一个极小的缩放因子; w_{coll} 为碰撞脱困分量的权重。

在不满足以上两种特殊情况时,算法将默认处于探索状态。此阶段通常在规划初期,随机树距离目标较远,其判断条件如式(16)所示。

$$d_{target} > (d_{overall} \times FAR_GOAL_{threshold} \times 1.5) \quad (16)$$

式中: $FAR_GOAL_{threshold}$ 为距离阈值。

此状态下,所有分量的权重均保持其初始值。确保算法在探索初期既有目标导向分量提供的宏观方向,也有障碍物规避分量提供的局部感知,同时保留了必要的均匀探索,能有效防止算法过早地收敛至局部最优路径。权重构成如式(17)所示。

$$\begin{cases} w'_{goal} = w_{goal} \\ w'_{obs} = w_{obs} \\ w'_{uniform} = w_{uniform} \\ w'_{coll} = w_{coll} \end{cases} \quad (17)$$

式中: w' 代表更新后的权重; w 代表更新前的权重。

1.3 多级自适应步长扩展机制

RRT* 算法采用固定的步长难以适应复杂环境,狭窄通道中,过大步长将导致反复碰撞;接近目标时,过大的步长会越过目标,增加连接难度并降低收敛速度;开阔区域的过小步长会产生大量冗余节点,降低探索效率。本算法提出一种多级自适应步长扩展机制。该机制基于具有优先级的多级框架:连续碰撞而进入受困状态时根据碰撞程度采用高频碰撞脱困步长或中频碰撞脱困步长、接近目标时采用精细连接步长、其他常规局部环境,步长大小与环境系数 η 正相关。环境系数表达式如式(18)所示,扩展步长如式(19)~(21)所示。

$$\eta = \eta_{min} + (\eta_{max} - \eta_{min}) \times (1 - \text{Density}_{obs}) \quad (18)$$

$$\text{Step}_{dynamic} = \begin{cases} \text{Step}_0 \times F_{refine}, & d_{norm} < T_{goal_prox} \\ \text{Step}_0 \times \eta, & d_{norm} \geq T_{goal_prox} \end{cases} \quad (19)$$

$$Step_1 = \begin{cases} Step_0 \times F_{crit}, & N_{coll} \geq T_{coll_high} \\ Step_0 \times F_{mod}, & T_{coll_mod} \leq N_{coll} < T_{coll_high} \\ Step_{dynamic}, & N_{coll} < T_{coll_mod} \end{cases} \quad (20)$$

$$Step_{final} = \max(Step, Step_1) \quad (21)$$

式中： $Step_0$ 基础步长值； $Step$ 为步长上限； $Density_{obs}$ 为局部障碍物密度； η 为环境系数，其值介于 η_{max} 和 η_{min} 之间； η 值与障碍物密度成反比，即在开阔区域 η 值较大，步长大；在密集区域 η 值较小，步长小； d_{norm} 为当前节点到目标的距离； T_{goal_prox} 为其阈值； $Step_{dynamic}$ 综合考虑环境系数 η 和全局进度的动态步长； N_{coll} 为连续碰撞次数； T_{coll_mod} 和 T_{coll_high} 分别是中频碰撞阈值和高频碰撞阈值； F_{crit} 、 F_{mod} 、 F_{refine} 分别为大量碰撞时的步长缩放因子、较多碰撞时的步长缩放因子和精细连接时的步长缩放因子。

1.4 联合优化策略-KD-Tree 索引机制

DGCR-RRT* 算法引入基于坐标轴的递归空间划分的 K 维树 (K-dimensional tree, KD-Tree) 索引机制。不采用 KD-Tree 索引的总时间复杂度为 $O(n^2)$ ，引入 KD-Tree 索引机制，最近邻搜索和邻域搜索的时间复杂度降至 $O(\log n)$ ，总时间复杂度 $O(n \log n)$ 。

1.5 联合加速策略-早停机制

针对 RRT* 算法在已收敛的解上浪费计算资源问题，DGCR-RRT* 算法引入早停机制，在路径质量与规划效率间取得平衡，算法流程如图 3 所示。




图 3 早停机制流程

Fig. 3 Early stopping mechanism flowchart

1.6 联合优化策略-去冗余机制

针对 RRT* 算法在探索后期产生大量冗余分支问题，DGCR-RRT* 算法引入去冗余机制，将计算资源集中在当前最优路径周围区域，算法流程如图 4 所示。

1.7 路径简化与平滑

路径简化通过贪心策略连接非相邻节点，以消除冗余、缩短路径。随后采用三次 B 样条曲线进行平滑处理，确保曲率连续，满足机械臂平稳运动的要求。对平滑后的路径进行采样与碰撞校验，若发生干涉，则回退至之前的简化路径，从而在保证平滑性的同时，确保最终路径的安全无碰撞。




图 4 去冗余机制流程

Fig. 4 Redundancy removal mechanism flowchart

2 仿真与实验

2.1 实验环境

为验证 DGCR-RRT* 算法的有效性与可行性，本研究开展仿真实验对比与实物平台验证。仿真实验环境：操作系统为 Windows 11，处理器为 AMD Ryzen7 5800H，内存为 16 GB，仿真软件为 PyCharm，仿真语言为 Python。实物验证环境：主体为机械臂，操作系统为 Ubuntu20.04。由于粗糙度测量过程需要在限定高度下进行，所以设置仿真环境为二维空间地图，搭建实物验证平台时，限制夹爪末端距离平面高度为 6.0 ± 0.5 cm。该措施符合实际运行情景，简化了操作复杂度，且能够全面评估算法的实际部署性能与可靠性。

2.2 实验设置

本实验设置不同地图并对比 DVSA-RRT 算法、Informed-RRT* 算法以及双向最优快速扩展随机树 (bidirectional optimal rapidly-exploring random tree, BI-RRT*)^[22] 算法。狭窄通道地图 map1 分别设置 30 和 15 mm 宽度通道，以验证不同算法在狭窄环境中脱困效率，常规地图 map2 用来验证是否使用去冗余机制和早停机制对算法的影响，实物实验地图 map3 包含狭窄通道区域以及开阔区域，用来验证算法落地效果。仿真地图尺寸固定为 640 mm×480 mm，均进行二值化处理，浅色为可通行区域，深色为障碍物区域。算法参数设置如表 1 所示。

表 1 参数设置

Table 1 Parameter settings

参数	名称	值	单位
w	初始权重	{0.4, 0.3, 0.3}	
σ	初始标准差	{100.0, 25.0, 15.0}	
$Step$	步长	{15, 20, 25}	mm
$C_{threshold}$	碰撞次数阈值	{2, 5, 3}	次
$TO_GOAL_{threshold}$	距离阈值	{0.1, 0.2, 0.3}	

如表 2 所示,DGCR-RRT* 算法在规划时间上有显著优势,对比 DVSA-RRT 算法、Informed-RRT* 算法和 BI-RRT* 算法在规划时间上分别减少 87.41%、79.08%、29.90%。这是由于 DGCR-RRT* 算法在应对狭窄通道区域,能够依靠均匀高斯分量和障碍物规避高斯分量快速接近狭窄通道入口,通过碰撞脱困高斯分量将采样区域集中在通道内,避免无效采样导致的时间消耗,动态调整步长至高频碰撞脱困步长,减少扩展失败带来的时间消耗,从而快速通过狭窄通道。脱离狭窄通道后,依据环境系数再次调整步长,以较大扩展步长通过开阔区域后,从而提高整体规划效率,达到大幅度节省规划时间的目标。采样点数上对比其余 3 种算法分别减少 91.01%、75.12%、44.19%,路径长度上对比其余 3 种算法分别缩短 7.46%、20.11%、5.22%。图 5 为 4 种算法在地图 map3 中的仿真结果。

表 2 map1 仿真结果
Table 2 Simulation results of a map1

算法名称	规划时间/s	采样点数/个	路径长度/mm
DVSA-RRT	5.40	167.71	996.18
Informed-RRT*	3.25	60.60	1 153.98
BI-RRT*	0.97	27.02	972.61
DGCR-RRT*	0.68	15.08	921.88




图 5 map1 仿真结果
Fig. 5 map1 simulation results

2.3 去冗余优化分析

如表 3 所示,本算法对比未使用去冗余机制的算法在规划时间上减少了 15.32%,采样个数显著减少了 42.99%,路径长度缩短了 1.10%。DGCR-RRT* 算法在采样点数有

显著的减少,这是由于去冗余机制减少了冗余分支上的无效采样和扩展,去冗余对照结果如图 6 所示。

表 3 去冗余对照仿真结果
Table 3 Ablation study: Redundancy removal

算法名称	规划时间/s	采样点数/个	路径长度/mm
未去冗余	1.11	45.36	931.34
DGCR-RRT*	0.94	25.86	921.12




图 6 去冗余对照仿真结果
Fig. 6 Ablation study: Redundancy removal

2.4 早停机制优化分析

由表 4 可知,DGCR-RRT* 算法对比未使用早停机制的算法,在规划时间上减少 38.96%,采样点数减少 3.51%,路径长度上增加 0.15%,早停对照仿照结果如图 7 所示。

表 4 早停对照仿真结果
Table 4 Ablation study: Early stopping

算法	规划时间/s	采样点数/个	路径长度/mm
未使用早停	1.54	26.80	919.78
DGCR-RRT*	0.94	25.86	921.12




图 7 早停对照仿真结果
Fig. 7 Ablation study: Early stopping

2.5 实物实验

1) 机械臂路径规划实验平台搭建
机械臂系统搭建如图 8 所示,主体为 FR5 机械臂,其

余由 D435i 双目摄像头、控制箱、易爪机器人的柔性机械爪、便携式显示屏和急停按钮盒构成。



图 8 机械臂系统
Fig. 8 The robotic arm system

2) 实验地图

路径规划结果如图 9 所示。验证平台运行结果如图 10 所示。结果表明,实物验证结果基本符合路径规划结果,简化平滑后的路线平滑,没有明显抖动,可以较好的满足表面粗糙度测量的实际需求。




图 9 路径规划结果
Fig. 9 Path planning results




图 10 验证平台运行结果
Fig. 10 Results from the validation platform

3 结 论

本文针对传统机械臂路径规划算法存在的采样效率低、环境适应性差及收敛速度慢的问题,提出 DGCR-

RRT* 算法。通过理论分析、仿真对比及实物实验,得出的结论为:

1) 提出的动态调节混合高斯采样策略,有效平衡了全局探索与局部开发。其中,碰撞脱困机制显著提升狭窄通道环境下的脱困效率。对比 DVSA-RRT,本算法规划时间减少了 87.41%,采样点数减少了 91.01%,路径长度缩短了 7.46%。

2) 提出的多级自适应步长扩展机制有效避免了狭窄空间的反复碰撞与开阔区域的低效搜索,提高了不同局部环境的适应性。

3) 结合 KD-Tree 索引、去冗余机制与早停机制的联合优化策略,将最近邻搜索时间复杂度降至 $O(\log n)$,使采样个数减少 42.99%,规划时间减少 38.96%,显著加速了算法收敛。

参考文献

[1] YANG Q, QU W W, WANG Y ZH, et al. Smooth joint motion planning for redundant fiber placement manipulator based on improved RRT* [J]. Robotics and Computer-Integrated Manufacturing, 2025, 91: 102851.

[2] AHMAD J, AB WAHAB M N. Enhancing the safety and smoothness of path planning through an integration of Dijkstra's algorithm and piecewise cubic Bezier optimization [J]. Expert Systems with Applications, 2025, 289: 128315.

[3] 迟旭, 李花, 费继友. 基于改进 A* 算法与动态窗口法融合的机器人随机避障方法研究 [J]. 仪器仪表学报, 2021, 42 (3): 132-140.

CHI X, LI H, FEI J Y. Research on robot random obstacle avoidance method based on fusion of improved A* algorithm and dynamic window method [J]. Chinese Journal of Scientific Instrument, 2021, 42 (3): 132-140.

[4] 张彪, 李永强. 基于动态寻优蚁群算法的移动机器人路径规划 [J]. 仪器仪表学报, 2025, 46 (3): 74-85.

ZHANG B, LI Y Q. Path planning of mobile robot based on the dynamic optimization ant colony algorithm [J]. Chinese Journal of Scientific Instrument, 2025, 46 (3): 74-85.

[5] 李二超, 张智钊. 改进遗传算法搜索动态订单下车辆路径最优问题 [J]. 计算机工程与应用, 2024, 60 (10): 353-364.

LI ER CH, ZHANG ZH ZH. Improved genetic algorithm for searching vehicle routing optimization under dynamic order [J]. Computer Engineering and Applications,

- 2024, 60(10): 353-364.
- [6] 朱霞, 陈仁文, 徐栋霞, 等. 基于改进粒子群的焊点检测路径规划方法[J]. 仪器仪表学报, 2014, 35(11): 2484-2493.
- ZHU X, CHEN R W, XU D X, et al. Welding spot detection path planning method based on a novel particle swarm algorithm[J]. Chinese Journal of Scientific Instrument, 2014, 35(11): 2484-2493.
- [7] 许振阳, 陈谋, 韩增亮, 等. 复杂环境下基于 TCP-DQN 算法的低空飞行器动态航路规划[J]. 机器人, 2025, 47(3): 383-393.
- XU ZH Y, CHEN M, HAN Z L, et al. Dynamic path planning of low-altitude aircraft based on TCP-DQN algorithm in complex environment[J]. Robot, 2025, 47(3): 383-393.
- [8] ZHENG X CH, CAO J J, ZHANG B, et al. Path planning of PRM based on artificial potential field in radiation environments[J]. Annals of Nuclear Energy, 2024, 208: 110776.
- [9] 郭俊锋, 袁俊平, 朱红霞. 基于改进 RRT 算法的双臂服务机器人运动规划研究[J]. 仪器仪表学报, 2024, 45(12): 210-220.
- GUO J F, YUAN J P, ZHU H X. Research on motion planning of dual-arm service robot based on improved RRT algorithm[J]. Chinese Journal of Scientific Instrument, 2024, 45(12): 210-220.
- [10] ZHOU Y, ZHANG EN D, GUO H L, et al. Lifting path planning of mobile cranes based on an improved RRT algorithm[J]. Advanced Engineering Informatics, 2021, 50: 101376.
- [11] 黄锋, 张志慧, 姜静, 等. 基于改进人工势场算法的移动机器人路径规划方法[J]. 机器人, 2025, 47(5): 696-707.
- HUANG F, ZHANG ZH H, JIANG J, et al. A path planning method for mobile robots based on the improved artificial potential field algorithm[J]. Robot, 2025, 47(5): 696-707.
- [12] 栾添添, 王皓, 孙明晓, 等. 基于动态变采样区域 RRT 的无人车路径规划[J]. 控制与决策, 2023, 38(6): 1721-1729.
- LUAN T T, WANG H, SUN M X, et al. Path planning of unmanned vehicle based on dynamic variable sampling area RRT[J]. Control and Decision, 2023, 38(6): 1721-1729.
- [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 ZH ZH. Robotic arm path planning based on sampling point optimization RRT algorithm[J]. Control and Decision, 2024, 39(8): 2597-2604.
- [14] 孙明晓, 张允曦, 栾添添, 等. 基于局部地图复杂度动态势场引导的无人船路径规划算法[J]. 仪器仪表学报, 2025, 46(8): 321-329.
- SUN M X, ZHANG Y X, LUAN T T, et al. Path planning algorithm for unmanned surface vehicle based on local map complexity and dynamic potential field guidance[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 321-329.
- [15] 陈正升, 田楚开, 刘凯旋, 等. 基于 MBIT* 的移动机器人渐进最优路径规划[J]. 仪器仪表学报, 2025, 46(5): 352-364.
- CHEN ZH SH, TIAN CH K, LIU K X, et al. MBIT* for asymptotically optimal path planning of mobile robot[J]. Chinese Journal of Scientific Instrument, 2025, 46(5): 352-364.
- [16] 刘小松, 康磊, 单泽彪, 等. 基于 RTSR-RRT* 算法的机械臂路径规划[J]. 仪器仪表学报, 2025, 46(3): 65-73.
- LIU X S, KANG L, SHAN Z B, et al. Path planning of robotic arm based on RTSR-RRT* algorithm[J]. Chinese Journal of Scientific Instrument, 2025, 46(3): 65-73.
- [17] KIM M C, SONG J B. Informed RRT* with improved converging rate by adopting wrapping procedure[J]. Intelligent Service Robotics, 2018, 11: 53-60.
- [18] KANG SH, LI D F, LONG S F, et al. Time-optimal and path-optimal motion planning for selective broccoli harvesting manipulator[J]. Computers and Electronics in Agriculture, 2025, 239: 111007.
- [19] 龙厚云, 李光, 谭薪兴, 等. 融合 A* 的改进 RRT 机械臂路径规划[J]. 计算机工程与应用, 2024, 60(4): 366-374.
- LONG H Y, LI G, TAN X X, et al. Path planning of robotic arm based on improved RRT algorithm combined with A* [J]. Computer Engineering and Applications,

2024, 60(4): 366-374.

[20] WANG X W, GAO J, ZHOU X, et al. Path planning for the gantry welding robot system based on improved RRT* [J]. Robotics and Computer-Integrated Manufacturing, 2024, 85: 102643.

[21] GANESAN S, RAMALINGAM B, MOHAN R E. A hybrid sampling-based RRT* path planning algorithm for autonomous mobile robot navigation[J]. Expert Systems with Applications, 2024, 258: 125206.

[22] ZHANG M Y, CHEN Y F, LUO SH, et al. Path planning of the robotic manipulator based on an improved Bi-RRT[J]. IEEE Sensors Journal, 2024, 24(19): 31245-31261.

作者简介



孙明晓,2010 年、2018 年于哈尔滨工程大学分别获得工学学士学位、博士学位,现为哈尔滨理工大学副教授,主要研究方向为无人系统和机器人理论研究与技术应用。

E-mail:sunmingxiao@hrbust.edu.cn

Sun Mingxiao received his B.Sc. and Ph.D. degrees both from Harbin Engineering University in 2010 and 2018, respectively. He is currently an associate professor at Harbin University of Science and Technology. His main research

direction is theoretical research and technological applications of unmanned systems and robotics.



李强,2023 年于常州工学院获得学士学位,现于哈尔滨理工大学攻读硕士研究生,主要研究方向为机械臂路径规划。

E-mail:2412068622@qq.com

Li Qiang received his B.Sc. degree from Changzhou Institute of Technology in 2023. He is currently pursuing a master's degree at Harbin University of Science and Technology. His main research direction is robotic arm path planning.



栾添添(通信作者),2011 年、2018 年于哈尔滨工程大学分别获得工学学士学位、博士学位,现为哈尔滨理工大学副教授,主要研究方向为无人系统和机器人理论研究与技术应用。

E-mail:luantiantian@hrbust.edu.cn

Luan Tiantian (Corresponding author) received her B.Sc. and Ph.D. degrees both from Harbin Engineering University in 2011 and 2018, respectively. She is currently an associate professor at Harbin University of Science and Technology. Her main research interests include theoretical research and technological applications of unmanned systems and robotics.