

狭窄空间下基于高维构型快速碰撞检测的机械臂路径规划

赖希睿^{1,2} 王润花^{1,2} 王耀南³ 张雪波^{1,2} 杨磊⁴ 李帅^{5,6}

摘 要 针对机械臂在狭窄空间中路径规划效率与成功率低、碰撞检测耗时占比高的问题,提出一种基于高维构型空间快速碰撞检测的狭窄空间在线路径规划算法。该算法以 RRT-Connect 为基线路径搜索框架,并行运行基于高维构型在线聚类的快速碰撞检测模块。其中,后者包括高维构型数据集均衡采样与快速碰撞检测模型在线训练两个阶段。具体而言,数据集在线构建阶段通过引入启发式策略以充分挖掘狭窄通道内的自由构型,克服仅通过均匀采样获取的数据集中碰撞构型、自由构型数量不均衡的问题,为后续快速碰撞检测模型训练提供可靠的数据支撑;数据集构建完成后,通过对碰撞、自由构型在线聚类,以簇的形式表征高维构型空间下两类构型的分布;基于训练得到的簇模型,将基线算法中基于包围盒的碰撞检测转化为采样构型与聚类簇间的距离计算,极大降低单次碰撞检测耗时,进而有效提升算法整体搜索效率。通过在简单、开放、封闭三类狭窄环境下的仿真测试与实验验证,表明所提算法在路径搜索效率和成功率方面具有显著优势。

关键词 狭窄空间;机械臂路径规划;快速碰撞检测;在线聚类;混合采样

引用格式 赖希睿,王润花,王耀南,张雪波,杨磊,李帅.狭窄空间下基于高维构型快速碰撞检测的机械臂路径规划.自动化学报,2026,52(9):1964–1978

DOI 10.16383/j.aas.c250408

CSTR 32138.14.j.aas.c250408

Robotic Arm Path Planning in Narrow Spaces Using Fast Collision Detection of High-dimensional Configurations

LAI Xi-Rui^{1,2} WANG Run-Hua^{1,2} WANG Yao-Nan³ ZHANG Xue-Bo^{1,2} YANG Lei⁴ LI Shuai^{5,6}

Abstract Aiming at the problems of low efficiency and success rate, high percentage of time-consuming collision detection in robotic arm path planning within narrow spaces, this paper proposes a path planning algorithm for narrow spaces utilizing online fast collision detection in high-dimensional configuration space. The algorithm takes RRT-Connect as the baseline path search framework, and runs the fast collision detection module based on high-dimensional configurations online clustering in parallel. The module includes two stages: Balanced sampling of the high-dimensional configuration dataset and online training of the fast collision detection model. Specifically, in the phase of dataset online construction, a heuristic strategy is introduced to fully explore the free configurations in narrow space, overcoming the problem that uniform sampling leads to an uneven number of collision and free configurations in the dataset, and to provide reliable data support for the subsequent fast collision detection model training; After the dataset construction, the distribution of the two types of configurations in the high-dimensional space is characterized in the form of clusters by online clustering of collision and free configurations; Using the trained cluster model, the collision detection based on bounding box in the baseline algorithm can be transformed into the calculation of the distance between the sampled configuration and the cluster, which greatly reduces the time consuming for a single collision detection and effectively improves the overall search efficiency of proposed algorithm. Through simulation tests and experimental verification in simple, opened and closed three types of narrow environments, the results show that the proposed algorithm has significant advantages in terms of path searching efficiency and success rate.

Keywords narrow spaces; robotic arm path planning; fast collision detection; online clustering; hybrid sampling

Citation Lai Xi-Rui, Wang Run-Hua, Wang Yao-Nan, Zhang Xue-Bo, Yang Lei, Li Shuai. Robotic arm path planning in narrow spaces using fast collision detection of high-dimensional configurations. *Acta Automatica Sinica*, 2026, 52(9): 1964–1978

收稿日期 2025-08-26 录用日期 2026-01-29

Manuscript received August 26, 2025; accepted January 29, 2026

国家自然科学基金(62293513),天津市自然科学基金(22JCZD JC00810)资助

Supported by National Natural Science Foundation of China (62293513) and Natural Science Foundation of Tianjin Municipality (22JCZD JC00810)

本文责任编辑 贺威

Recommended by Associate Editor HE Wei

1. 南开大学人工智能学院 天津 300350 2. 南开大学机器人与信息自动化研究所 天津 300350 3. 湖南大学电气与信息工程学

院 长沙 410082 4. 国网天津市电力公司电力科学研究院 天津 300450 5. 国网瑞嘉(天津)智能机器人有限公司 天津 300480 6. 浙江大学机械工程学院 杭州 310030

1. College of Artificial Intelligence, Nankai University, Tianjin 300350 2. Institute of Robotics and Automatic Information System, Nankai University, Tianjin 300350 3. College of Electrical and Information Engineering, Hunan University, Changsha 410082 4. Electric Power Research Institute, State Grid Tianjin Electric Power Company, Tianjin 300450 5. State Grid Ruijia (Tianjin) Intelligent Robot Co., Ltd., Tianjin 300480 6. School of Mechanical Engineering, Zhejiang University, Hangzhou 310030

随着制造强国战略的全面实施与智能制造的纵深发展^[1], 机械臂作为自动化系统核心载体, 在以飞机零部件加工为代表的重大装备制造场景^[2]、以配网带电为代表的高风险作业场景^[3-4]与以抓取-分拣为代表的精细操作场景^[5]中得到广泛应用. 其中, 机械臂通常需从初始构型运动至目标构型以完成搬运、码垛、喷涂、焊接等作业任务, 而机械臂路径规划正是实现这些任务的关键基础. 然而, 如配网带电作业中密集的电线网、重大装备制造中受限的作业舱体等狭窄复杂空间, 均对机械臂在路径规划效率与成功率方面提出更高的技术要求. 在此类环境中, 工作空间障碍物占比大、无碰构型采样成本高, 导致传统路径规划算法搜索耗时长且成功率低, 极大限制其在复杂场景中的应用^[6]. 因此, 针对狭窄空间下机械臂路径规划所面临的挑战, 如何设计一个高效的路径规划算法, 是亟待解决的关键问题.

机械臂的路径规划方法主要可分为人工势场法、智能优化与学习法、采样法三类:

1) 人工势场法通过设置引力与斥力函数, 在合力作用下引导机械臂搜索可行路径. 然而, 在目标附近存在障碍物、机器人位于障碍物与目标连线或狭窄通道等挑战性场景中, 该方法易存在目标不可达或徘徊抖动的问题^[6].

2) 在基于智能优化与学习的方法中, 智能优化方法包括以蚁群、粒子群等为代表的智能仿生算法, 与以 CHOMP (covariant Hamiltonian optimization for motion planning)^[7]、STOMP (stochastic trajectory optimization for motion planning)^[8]为代表的轨迹优化算法. 尽管这类方法在规划过程中具有较好的鲁棒性, 但普遍存在计算代价大、依赖初始值等问题; 而学习类方法则直接从数据中学习规划模型, 生成路径或规划策略, 或为传统规划器提供启发信息. 该类方法作为新兴研究方向展现出巨大潜力, 但仍面临模型泛化能力不足、离线训练成本高及数据采集困难等挑战.

3) 基于采样的方法以 RRT (rapidly exploring random tree) 单查询方法^[9]与 PRM (probabilistic roadmaps) 多查询方法^[10]为代表. 该类方法通过不断在构型空间中采样并构建树或图进行搜索, 从而能有效处理机械臂高维构型空间的规划问题及各类约束条件. 因此, 采样类算法在当前的机械臂路径规划研究中占据主流地位.

采样类方法虽然在机械臂路径规划中应用广泛并具有概率完备性, 但仍存在一定的局限性. 首先, 由于狭窄环境中的自由构型空间占比低, 随机生成的采样构型落入障碍物区域概率较高, 从而导致路径规划耗时显著增加; 其次, 机械臂路径规划涉及

多类碰撞检测, 不仅包括各连杆与障碍物间的检测, 还需判断连杆间是否相交. 进一步地, 由于机械臂构型空间维度高且作业环境复杂, 包围盒、凸包等传统碰撞检测方法计算开销大, 其耗时通常占总规划时间的 90% 以上^[11]. 因此, 狭窄环境中机械臂路径规划算法仍有较大的研究空间.

由于传统算法中全局均匀采样在狭窄空间中效果不佳, 许多研究者以启发式采样为研究切入点, 探究更贴合障碍物分布的采样策略以获取更多有效采样点. 如 Boor 等^[12]提出的高斯采样策略、Hsu 等^[13]提出的桥测试、Xun 等^[14]提出的在模拟光线反射生成引导路径后偏置采样的 LRH-RRT* (light reflection heuristic RRT*) 等. 这些采样策略虽适应狭窄空间的环境特性, 但依赖于简单逻辑规则, 信息搜索盲目且不充分, 在更为复杂的环境中表现不佳. 因此, 本文提出以合理逻辑顺序组合的采样策略, 充分挖掘体现狭窄空间特性的构型, 从而兼顾环境的全局随机探索与局部狭窄特征利用. 此外, 不少研究者也将学习类策略应用于采样引导中, 如 Ichter 等^[15]通过离线训练模型, 基于条件变分自编码器将障碍物等外部因素作为条件变量进而生成可行采样点. Qureshi 等^[16]提出的 MPNet (motion planning network) 与 Wang 等^[17]提出的 MNP (multimodal neuron planner) 均由 ENet 与 PNet 构成, 但侧重点不同: 前者在 ENet 中利用多层感知机将点云映射至隐空间, 在 PNet 中对环境与机器人状态编码以生成提升规划效率的样本; 而后者则针对规划中多模态可行解的问题, 在 ENet 中使用 PointNet 压缩点云为隐向量并输入至 PNet 中, 结合机器人当前与目标构型, 利用混合密度网络学习高斯混合模型 (Gaussian mixture model, GMM) 参数, 进而预测下一个构型以迭代生成路径. 另外, Wang 等^[18]提出的 CDMNet (confidence driven motion planning network) 框架通过引入多元深度证据回归与闭式连续时间网络, 输出机器人下一状态的多元 t 分布参数. Li 等^[19]提出一种学习构型空间连通性与引导采样点通过狭窄通道的算法——SDCL (sample-driven connectivity learning), 该算法在双向规划器中通过支持向量机 (support vector machine, SVM) 对与起点联通、与终点联通的节点进行分类, 将分类超平面视为障碍物分布的近似, 在该超平面流形采样以改善算法在狭窄环境中的搜索效率. 这些将学习类方法与采样结合的研究虽然能提升路径搜索效率, 但存在适用环境单一、训练时间长等问题.

许多研究通过改进碰撞检测的方法以提升狭窄空间中算法的规划效率. 如延迟碰撞检测思想, 即

将碰撞检测推迟至算法真正需要时执行,减小不必要的实时开销.该思想可与多种规划算法结合,进一步提升规划效率,如 Lazy-PRM^[20]等.不少学者借鉴计算机图形学中符号距离场 (signed distance function, SDF) 的概念,为碰撞检测模型的设计提供了新思路.如 Koptev 等^[21]采用多层感知机学习关节空间中的隐式 SDF,高效计算机机械臂与障碍物之间的精确距离;Liu 等^[22]提出一种复合 SDF 网络用于学习机械臂的 SDF,能够快速准确地计算机机械臂与障碍物间的最小距离;Joho 等^[23]提出一种基于隐式神经网络的扫掠体积 (swept volume) 模型,以深度神经网络计算扫掠体积的方式替代传统离散化的检测方法,进而加速对路径边的碰撞检测.同时, Lee 等^[24]提出基于碰撞约束插值的优化方法,通过将环境凸分解并构造叶集序列,利用 SDF 的平滑插值实现碰撞约束的渐进强化.这类基于学习与优化 SDF 的方法通常依赖于大规模数据集,且其碰撞检测范围主要局限于机械臂连杆与外部障碍物,忽略了机械臂自身的碰撞检测需求;而本文方法通过在线刻画机械臂的自由空间与障碍物空间,以距离度量的高效方式实现快速且全面的碰撞检测.此外, Huh 等^[25]基于 GMM 对 RRT 中得到的自由构型、碰撞构型分别进行聚类,提出一种新的碰撞检测方法以提高检测速度.该方法虽然能够实时更新参数以适应环境的细微变化,但当工作环境发生较大变化时,算法规划效率下降,需重复运行规划算法积累足够数据以完成聚类. Yu 等^[26]利用图神经网络生成一组构成路径可能性的边概率,并依据概率优先级执行边的碰撞检测以搜索可行路径.这类基于神经网络的方法通常需要对环境障碍物进行表示与输入,且依赖离线训练.而本文方法于每次规划中在线构建与训练快速碰撞检测模型,能针对不同环境生成相应的检测机制.

此外,不少研究也聚焦于端到端学习的运动规划算法,如 Xu 等^[27]提出的 GRPMP (Gaussian random paths motion planner) 不依赖于构型采样,而是利用高斯过程直接生成一系列随机路径,进而从中选择出可执行且低成本的路径;Huang 等^[28]提出的 SceneDiffuser 则将场景条件、物理优化和运动规划统一于一个框架中,以点云为条件在训练与推理过程中进行成本引导.然而该方法对不同的约束条件需重新训练模型,难以灵活地添加约束条件;Carvalho 等^[29]构建一种运动规划扩散模型,以轨迹生成的扩散模型为先验,利用逆去噪过程从以任务目标为条件的后验轨迹分布中采样,从而生成满足设定约束的轨迹;Zhang 等^[30]提出的 FlowPolicy 以部分 3D 视觉图像表示为条件,采用推理速度更

快、更稳定的流匹配方法,实现从噪声分布到动作分布的高效直接映射,在少量示例中即可实时生成鲁棒的机器人动作,保证生成的速度与质量;Das 等^[31]针对传统运动规划器每次在新环境中需重新规划的问题,提出一种运动记忆 (motion memory) 的方法,通过经验增强和表征学习,利用历史经验以加速未来规划.相较于上述端到端的学习类方法,本文算法无需进行复杂的环境表示,而是在每次规划时重新在线构建均衡数据集、训练快速碰撞检测模型,同时并行搜索路径,从而兼顾算法的规划效率与环境适应能力.

综上,针对现有启发式采样策略中环境信息利用不充分、搜索盲目性高、代价大的问题,以及现有碰撞检测方法的改进中存在泛化性差、离线训练耗时等问题,本文提出一种狭窄空间下基于高维构型空间快速碰撞检测的在线路径规划算法.该算法流程如图 1 所示,其并行运行基线路径规划、基于高维构型在线聚类的快速碰撞检测两部分,将得到的训练模型替换基线路径规划中的传统碰撞检测部分,并继续搜索狭窄空间中的可行路径,提升算法整体的搜索效率.同时,为降低模型误判样本对规划结果的影响,算法引入重规划部分以保证最终路径的可行性.本文的主要贡献如下:

1) 兼顾全局构型空间探索与局部狭窄特征利用的数据集在线构建方法.为克服单一均匀采样在狭窄空间内自由构型采集效率低的问题,本文引入高斯采样、桥测试等启发式采样策略,并对通过桥测试的构型周围进行贪婪搜索,从而充分利用狭窄空间内的碰撞检测信息挖掘自由构型.该方法有效保证了自由与碰撞构型数据集的均衡快速构建,为后续模型的在线训练提供可靠的数据支撑.

2) 基于高维构型空间在线聚类的快速碰撞检测方法.该碰撞检测方法利用上述采样获得的数据集,在线聚类碰撞构型簇和自由构型簇.基于训练完成的构型簇模型,将传统基于包围盒的碰撞检测方法转化为构型与簇间的距离判断,从而缩短单次碰撞检测时间,提升路径搜索效率.该方法无需离线训练数据,对不同环境均有良好的适应性.

3) 面向狭窄空间的通用采样类路径规划框架.该框架并行运行基于高维构型空间在线聚类的快速碰撞检测与基线路径规划模块,适用于各类采样类规划算法,并能在线或离线地适应不同环境.

1 问题定义与采样算法概述

1.1 机械臂路径规划问题定义

机械臂路径规划不同于移动机器人,其搜索通




图 1 狭窄空间下基于高维构型空间快速碰撞检测的机械臂在线路径规划算法框图

Fig.1 Block diagram of online robotic arm path planning algorithm in narrow spaces using fast collision detection in high-dimensional configuration space

常在构型空间 C 中完成, 兼具计算高效、运动约束易嵌入及能直接生成可执行关节指令的优势. 对于自由度为 n 的机械臂, 其构型 q 是 n 维构型空间 C 的一个向量. 若某一构型 q 不与障碍物或自身发生碰撞, 则称该构型是自由的. 构型空间 C 由障碍物空间 C_{obs} 与自由空间 C_{free} 构成, 即 $C = C_{free} \cup C_{obs}$. 定义 q_{init} 为机械臂在 C_{free} 中的起始构型, q_{goal} 为机械臂在 C_{free} 中的目标构型. 因此, 机械臂路径规划问题可定义为在 C_{free} 中找到一条由起点 q_{init} 至终点 q_{goal} 的无碰路径 τ :

$$\tau = F(q_{init}, q_{goal}, C) \quad (1)$$

式中, τ 为规划得到的路径, F 为所选的规划器.

1.2 基于采样的路径规划方法

基于采样的路径规划方法如图 2 所示. 首先, 将机械臂的初始与目标构型数值输入规划器后, 随机采样得到由各关节角度组成的构型向量; 其次, 对采样所得的构型向量进行碰撞检测, 即完成连杆与障碍物、连杆与连杆之间的检测; 然后, 将已有构型集合向最新采样的构型方向拓展, 通过对连接边进行插值离散化以完成静态或连续碰撞检测: 若无碰撞, 则将该采样构型加入集合. 重复上述过程, 直




图 2 基于采样的路径规划框图

Fig.2 Block diagram of sampling-based path planning

至构建出连接起点与终点的构型集合, 完成路径搜索. 最后, 对搜索得到的路径进行冗余点剔除、局部优化与平滑处理, 生成最终可执行的无碰路径.

2 基于高维构型空间快速碰撞检测的在线路径规划算法设计

狭窄空间下基于高维构型空间快速碰撞检测的在线规划算法分为三部分: 1) 兼顾全局构型空间探索与局部狭窄特征利用的数据集在线构建; 2) 基于高维构型在线聚类的快速碰撞检测模型; 3) 基线路径规划. 首先, 数据集在线构建部分在保证采样随

机性的同时,引入高斯采样、桥测试等启发式采样策略,并在难以获得的、高质量的有效构型周围进行贪婪拓展,加速构建自由构型与碰撞构型数量均衡的数据集.同时,规划过程中产生的自由构型与因碰撞而被丢弃的构型均被保存为训练数据,以完整刻画构型空间的障碍与自由区域.其次,快速碰撞检测模型的训练与测试部分,在完成第一部分数据预处理与映射后,分别对碰撞构型与自由构型进行聚类,将聚类信息用于快速碰撞检测模型测试.若模型精度未达到所设阈值,则重复上述流程,直至模型满足替换基线规划算法中传统检测模型的精度要求或训练数据集达到预设上限.最后,基线路径规划部分旨在高精度、快速碰撞检测模型训练完成前,并行执行部分路径搜索,避免算法单线程等待.当训练模型满足所需精度时,便由其执行后续的碰撞检测,继续完成路径搜索.为保证算法在狭窄环境中的规划效率,本文选择应用广泛且速度较快的 RRT-Connect^[32] 作为该部分的基线算法.此外,本文算法引入局部重规划机制,以保证最终路径的可行性.

2.1 兼顾全局构型空间探索与局部狭窄特征利用的数据集在线构建

针对均匀采样盲目性大、狭窄环境下自由构型与碰撞构型数量占比不均衡的问题,本文提出一种兼顾全局构型空间探索与局部狭窄特征利用的数据集在线构建策略,引入高斯采样、桥测试,探索狭窄通道中、障碍物附近的可行构型.如图3所示.




图3 兼顾全局性与狭窄特性的数据集在线构建策略图解
Fig.3 Diagram of the online dataset construction strategy that balances the global and narrow characteristics

该数据集在线构建策略通过高斯采样策略可获得障碍物边缘的自由构型 q_3 , 通过桥测试可获得狭窄通道间的自由构型 q_6 . 尽管高斯采样与桥测试能在一定程度上捕捉障碍物分布,但其获取表征狭窄环境特征的节点代价高昂,且利用效率不足.因此,本文所提策略选择将均匀采样、高斯采样、桥

测试以先后逻辑顺序组合,并对通过桥测试的自由构型进行贪婪探索,如图3的 q_7 、 q_8 、 q_9 均为在 q_6 附近贪婪搜索得到的、反映狭窄几何结构的自由构型.该数据集构建策略如算法1所示, q_{bridge} 为已存储且通过桥测试的构型, q_{mid} 为新探索的桥测试构型, q_{narrow} 为基于 q_{bridge} 贪婪探索得到的构型, $U_{\text{collision}}$ 与 U_{free} 分别为后续模型训练所需的碰撞构型数据集与自由构型数据集.

算法1. 兼顾全局性与狭窄特性的数据集在线构建策略

输入. 环境 $\mathcal{M}$.

输出. 碰撞构型集合 $U_{\text{collision}}$, 自由构型集合 U_{free} .

```

1: if 存在桥测试节点  $q_{\text{bridge}}$  并满足偏置 then
2:    $q_{\text{bridge}}$  为中心, 标准差  $\sigma_0$  采样得  $q_{\text{narrow}}$ 
3:    $q_{\text{narrow}}$  碰撞检测, 存储入对应集合
4: else
5:   全局均匀采样得到构型  $q_1$  //执行采样过程 Basicsample()
6:   判断  $q_1$  是否位于  $\mathcal{M}$  的障碍物中
7:   if  $q_1$  未碰撞 then
8:      $U_{\text{free}} \cup q_1$ 
9:   else
10:     $U_{\text{collision}} \cup q_1$ 
11:    以  $q_1$  为中心, 标准差  $\sigma_1$  采样得  $q_2$ 
12:    判断  $q_2$  是否位于  $\mathcal{M}$  的障碍物中
13:    if  $q_2$  未碰撞 then
14:       $U_{\text{free}} \cup q_2$ 
15:    else
16:       $U_{\text{collision}} \cup q_2$ 
17:       $q_1$  和  $q_2$  取中点  $q_{\text{mid}}$ 
18:      判断  $q_{\text{mid}}$  是否位于  $\mathcal{M}$  的障碍物中
19:      if  $q_{\text{mid}}$  未碰撞 then
20:         $U_{\text{free}} \cup q_{\text{mid}}$ 
21:         $q_{\text{bridge}} \leftarrow q_{\text{mid}}$ 
22:      else
23:         $U_{\text{collision}} \cup q_{\text{mid}}$ 
24:      end if //结束采样过程 Basicsample()
25:    end if
26:  end if
27: end if

```

运行流程具体说明如下:

1) 检查是否存储已搜索到的桥测试节点 q_{bridge} . 若存在, 且未达到探索次数上限, 则以该节点为中心进行正态分布采样, 将采样得到的自由构型更新为 q_{bridge} , 从而在体现环境特征的关键构型 (表征狭窄受限空间中自由通道的构型) 周围进行精细化贪

婪探索. 此外, 通过设置贪婪搜索次数上限, 避免策略因凹型障碍物特征而陷入无效搜索.

2) 若不满足桥测试构型的贪婪探索条件, 则执行基础采样过程 Basicsample() (算法 1 中的 5 ~ 24 行). 即在构型空间中均匀采样得到构型 q_1 , 对 q_1 进行碰撞检测. 若 q_1 位于自由空间中, 则将其作为有效采样构型保存, 并结束本次采样. 若 q_1 处于障碍物空间, 则以 q_1 为中心进行正态分布采样, 得到新构型 q_2 . 若 q_2 位于 C_{free} 中, 保存 q_2 为有效构型并返回; 否则, 对 q_1 与 q_2 的中点进行采样得到 q_{mid} . 若 q_{mid} 属于自由构型, 则将其作为有效采样构型, 并赋值给 q_{bridge} , 结束 Basicsample().

上述为单次均衡数据集构建流程, 该策略每次优先对 q_{bridge} 进行贪婪扩展, 同时兼顾全局环境的探索. 此外, 该策略将所有碰撞构型与自由构型分别存入 $U_{\text{collision}}$ 与 U_{free} 中, 并重复执行上述流程直至达到预设数据规模上限, 为后续模型训练提供均衡有效的数据支持.

综上, 该数据集的在线构建策略在保证全局采样随机性的同时, 充分挖掘狭窄通道自由构型所蕴含的关键环境信息, 从而加快自由构型的采样速度. 该策略与基线路径规划并行运行, 独立于基线规划器的均匀采样环节, 因而不影响 RRT-Connect 算法的概率完备性.

2.2 基于高维构型在线聚类的快速碰撞检测模型

针对机械臂采样规划算法中传统碰撞检测方法耗时高的问题, 受文献 [21–23, 25] 的启发, 本文提出一种在线的快速碰撞检测模型, 该模型训练流程如算法 2 所示. 该数据驱动模型在通过上节所提策略积累数据后, 对数据集进行划分与映射, 进而利用球形 K-means (spherical K-means)^[33] 分别对训练集中的碰撞构型与自由构型进行在线聚类. 通过计算采样构型与聚类簇之间的马氏距离, 直观判断该构型的碰撞状态. 若模型精度达到预设阈值, 则将其替换基线路径规划中的碰撞检测方法, 执行后续规划; 若模型未达到精度要求, 则重复前序步骤直至达到数据集容量上限, 此时可选择当次在线规划中历史最优模型或离线预存模型, 替换传统检测方法.

算法 2. 快速碰撞检测 (FastCollisionCheck ())

输入. 数据集 U_{free} 、 $U_{\text{collision}}$.

输出. 碰撞检测模型 $CCModel$.

```

1: while 未得到  $CCModel$  或时间上限内 do
2:    $U_{\text{collision}}$ 、 $U_{\text{free}}$  训练集、测试集划分
3:   训练集、测试集数据映射与归一化
4:   自由、碰撞训练集数据聚类, 得到模型  $\mathcal{I}$ 
5:   for 测试集中的构型  $q_i$  do

```

```

6:     计算  $q_i$  至自由、碰撞每个聚类簇的马氏距离
7:     选择  $q_i$  与碰撞、自由聚类簇中最小马氏距离作差
8:      $q_i$  快速碰撞检测判断
9:   end for
10:  if 测试集成功率 > 阈值 then
11:     $CCModel \leftarrow$  在线模型  $\mathcal{I}$ 
12:    Break
13:  else
14:    if 训练集大小超过上限 then
15:      if 存在离线模型  $\mathcal{O}$  then
16:         $CCModel \leftarrow \mathcal{O}$ 
17:      else
18:        选择出训练中最优模型  $\mathcal{H}$ 
19:         $CCModel \leftarrow \mathcal{H}$ 
20:      end if
21:    end if
22:  end if
23: end while

```

2.2.1 构型空间采样数据预处理

为保证模型的精确性, 需将得到的数据划分为训练集与测试集. 训练集与测试集均由等额的自由构型与碰撞构型组成, 二者相互独立. 训练集规模与环境复杂程度呈正相关.

机械臂采样构型是一系列 n 维的关节角度向量. 关节角以 2π 为周期, 属于周期性的方向敏感数据, 存在空间构型相近但数值差异较大的问题. 以 0 与 2π 为例, 二者角度在关节空间中代表同一构型, 但数值距离较大, 可能导致相似构型被误判为不相似. 因此, 需将数据映射为空间与数值相统一的表示形式, 即

$$p(\mathbf{x}) = (\cos(\mathbf{x}), \sin(\mathbf{x})) \quad (2)$$

式中, $\mathbf{x}$ 为输入的构型, $p(\mathbf{x})$ 为映射后的结果. 通过该映射, n 维的关节值向量转化成 $2n$ 维的超球平面数据, 从而消除周期性的影响. 后续即可对映射后的向量聚类, 避免周期性数据对聚类效果产生干扰.

2.2.2 基于球形 K-means 的高维构型聚类

兼顾聚类质量与生成效率的球形 K-means 最初用于处理和分析高维稀疏的文本数据, 其通过余弦相似度对文档术语权重进行划分^[34–35]. 由于构型空间采样的关节角数据同样具有高维稀疏且方向敏感的特性, 与文本数据具有一定相似性. 因此, 快速碰撞检测模型中选用球形 K-means 作为聚类方法, 实现高维数据的快速聚类, 从而获取自由空间与障碍物空间的分布信息. 球形 K-means 的核心思想为

最大化以下目标函数:

$$\max J = \sum_{i=0}^k \sum_{\mathbf{x} \in C_i} \mathbf{x} \cdot \boldsymbol{\mu}_i \quad (3)$$

式中, C_i 为第 i 个簇, $\mathbf{x}$ 为划定簇中的向量, $\boldsymbol{\mu}_i$ 为簇中心向量. 由于 $\mathbf{x}$ 与 $\boldsymbol{\mu}_i$ 均为单位向量, 点积结果近似为两者间余弦值的最大化, 即球形 K-means 通过最大化簇内数据的余弦相似度^[34-35]完成聚类, 而非最小化欧氏距离. 该方法关注向量的方向, 通过迭代寻找使簇内数据方向最一致的簇中心. 由于余弦相似度 ξ 范围为 $[-1, 1]$, 不便于最大化或最小化, 因此, 将球形 K-means 最大化余弦相似度转化为最小化 $1 - \xi$, 使目标函数取值位于 $[0, 2]$ 之间. 球形 K-means 步骤如下:

1) 初始化模型, 对聚类数据进行归一化, 随机生成 k 个不同的 n 维数据作为初始聚类中心.

2) 对每个构型数据, 计算其与所有簇中心的 $1 - \xi$, 并将其分配到值最小的簇中.

3) 对每个簇中心, 归一化为单位向量, 确保结果位于超球面上.

4) 重复执行分配和更新步骤, 直到簇中心不再变化或达到最大迭代次数.

综上, 球形 K-means 能够对高维度、大规模、方向敏感的数据实现高质量快速聚类, 是在线快速碰撞检测模型的重要组成部分. 通过球形 K-means 得到自由构型与碰撞构型的聚类模型, 间接刻画出机械臂的自由空间与障碍物空间, 为后续快速碰撞检测模型的构建奠定基础.

2.2.3 基于马氏距离计算的快速碰撞检测

在获得自由构型与碰撞构型的聚类模型后, 分别计算待检测构型与自由聚类簇、碰撞聚类簇各 k 个聚类中心的最小距离, 以距离计算的形式判断构型是否碰撞. 因此, 点与簇间距离度量类型的选择对快速碰撞检测结果有较大影响. 本文采用马氏距离而非欧氏距离进行距离计算, 如图 4 所示. 红色虚线圆表示与聚类簇中心欧氏距离相等的点集, 两个蓝色虚线椭圆与簇分布方向一致, 分别表示与聚类簇马氏距离相等的点集. 构型 1 与构型 2 位于同一红色圆上, 按欧氏距离衡量, 认为二者属于同一构型属性. 而在马氏距离的度量下, 构型 2 所处的椭圆相较构型 1 所处的椭圆距离簇更近, 马氏距离更小, 更符合构型 1 位于簇外与簇距离较大而构型 2 位于簇内与簇距离较小的情况, 从而更科学地刻画了点与簇之间的距离关系.

综上, 由于欧氏距离忽略数据的分布特性, 难以有效刻画点与聚类簇之间的关系, 因此本文选用马氏距离作为构型与聚类簇间距离的度量标准, 在




图 4 构型与聚类簇之间距离计算图示

Fig. 4 Diagram of distance calculation between configurations and clustering clusters

计算中对协方差矩阵进行归一化, 克服欧氏距离对特征尺度差异敏感的问题, 使检测方法更符合数据的分布特征. 马氏距离的计算式为

$$D_m(\mathbf{x}) = \sqrt{(\mathbf{x} - \boldsymbol{\mu})^T S^{-1} (\mathbf{x} - \boldsymbol{\mu})} \quad (4)$$

式中, $\mathbf{x}$ 为待判断的构型向量, $\boldsymbol{\mu}$ 为簇中心, S 为该簇的协方差矩阵. 因此, 在对待检测构型进行判断时, 需要分别计算其与碰撞、自由各 k 个聚类簇的最小马氏距离 $D_{\text{collision}}$ 与 D_{free} , 并设定碰撞与自由状态阈值 $\rho_{\text{collision}}$ 、 ρ_{free} , 构型的碰撞状态可通过下式判定:

$$\begin{cases} D = D_{\text{collision}} - D_{\text{free}} \\ \text{Collision} : D < \rho_{\text{collision}} \\ \text{Free} : D > \rho_{\text{free}} \\ \text{Kinematics} : \rho_{\text{collision}} \leq D \leq \rho_{\text{free}} \end{cases} \quad (5)$$

快速碰撞检测方法如图 5 所示, 其计算待检测构型与每个簇之间的马氏距离, 若距碰撞聚类簇的最小马氏距离与距自由聚类簇的最小马氏距离之差 D 小于阈值 $\rho_{\text{collision}}$, 则判定待检测构型为碰撞构型; 若 D 大于 ρ_{free} , 则判定为自由构型. 此外, 若 D 处于 2 个阈值之间, 表明待检测构型至自由簇与碰撞簇距离相近, D 难以明确反映待检测构型的类别信息, 容易出现构型误判的问题. 因此, 模型对这类距离关系模糊的待检测构型调用精确的基于包围盒的层次碰撞检测方法, 保证快速碰撞检测方法决策的准确性.

在线快速碰撞检测模型与基线路径规划算法并行运行. 在基线算法规划时, 在线训练快速碰撞检测模型以替代传统检测模型. 如图 6 所示, 该模型通过聚类间接拟合自由构型区域与障碍物区域, 并最终将采样构型的碰撞检测转换为点与簇的距离计算, 从而极大缩短单次碰撞检测时间, 提升算法在狭窄空间中的搜索效率. 算法不断迭代, 直至模型




图 5 在线快速碰撞检测图解

Fig.5 Online fast collision detection illustration




图 6 在线快速碰撞检测在路径规划中的应用

Fig.6 Application of online fast collision detection in path planning

精度满足要求, 输出快速检测模型; 或当数据集达到容量上限时, 选择历史训练中的最优模型或预存离线模型进行输出。其中, 通过设置数据集容量上限, 可避免大规模数据聚类耗时过长导致规划效率下降的问题, 而离线与在线检测模型的混合使用机制则兼顾了算法的效率与精度。

2.2.4 重规划

由于在线快速碰撞检测模型阈值设置可能导致

部分误判结果, 一旦出现假阳性与假阴性样本, 将对路径规划结果产生影响。假阳性指将实际碰撞构型检测为自由构型; 反之, 假阴性则指将实际自由构型检测为碰撞构型, 二者数量均可通过碰撞与自由阈值的合理设定而减少。假阳性结果对路径规划问题而言, 易导致其过早生成不可行路径; 而假阴性结果中的自由构型在障碍物附近, 具有较高的碰撞风险, 其对算法整体规划效率的影响相对有限。然而, 一旦出现假阳性结果即意味着不可行路径生成, 进而影响规划算法的成功率。因此, 为避免假阳性样本的影响, 算法在规划获得初步路径后引入重规划部分。

该重规划机制首先检测构成路径的各节点是否可行, 筛查快速碰撞检测中可能误判的假阳性节点。若发现不可行节点, 则分别向前与向后回溯至路径上最近的可行节点处, 并以这 2 个节点为起止点进行局部重规划。若所有节点均可行, 则进一步检测节点间连线是否发生碰撞, 对发生碰撞的边执行局部重规划, 如图 7 所示。

3 仿真与实验验证

本文设计 3 种典型狭窄环境进行仿真测试: 简单狭窄环境模拟物体抓取, 由较为杂乱的桌子与置物桶构成, 机械臂需从桌面上方运动至桌面下方的置物桶处, 机械臂高度受限但仍具有较大的工作空间; 开放式狭窄环境聚焦高压配网带电作业任务, 由多条交错高压电线、多个直线塔与耐张塔构成, 机械臂需在电线间穿梭作业; 封闭式狭窄环境则面向重大装备制造任务, 封闭舱体中存在控制台、加工材料、置物架、桌子等物体, 机械臂需在置物架中完成对角线取物与置物任务, 工作空间被严重压缩。三类实验场景由易到难, 均来源于实际任务场景。

本文以 Franka Emika Panda 机械臂为仿真载体, 基于 Ubuntu20.04 操作系统, 在开源运动规划框架 MoveIt^[36] 中构建仿真场景。本文所提算法与对比算法均基于 OMPL1.6.0 (open motion plan-




图 7 重规划图解


Fig.7 Replanning illustration

ning library) 库^[37]实现. 在快速碰撞检测模型中, 数据的映射与预处理基于 Armadillo9.800.4 线性代数库, 聚类算法则依托 mpack4.3.0 机器学习库实现. 本文选择部分经典规划算法如 RRT、RRT-Connect、Lazy-RRT、PRM、Lazy-PRM、KPIECE (kinodynamic planning by interior-exterior cell exploration)^[38]、BKPIECE、TRRT (transition-based RRT)^[39]、EST (expansive space trees)^[40] 及最新发表的样本学习类算法 SDCL^[19] 作为对比方法. 本文仿真测试与实机实验均在统一的硬件平台上完成, 配置为 Intel Core(TM) i9-14900HX 处理器与 NVIDIA GeForce RTX 4060 显卡.

实验中将均衡数据集在线构建策略的贪婪搜索标准差设置为 0.3, 高斯采样标准差设置为 0.2. 而球形 K-means 聚类中, 当迭代间簇中心变化小于 1×10^{-4} 或迭代次数达到 1 000 时, 即视为算法收敛. 每种算法在三类典型环境中均独立运行 30 次, 规划时间上限根据环境难易程度设置: 在简单狭窄环境中设置为 10 s, 在开放狭窄环境中设置为 100 s, 在封闭狭窄环境中设置为 300 s. 若算法在时间上限内未搜索到路径, 则视为规划失败, 不计入成功率、平均时间、平均碰撞检测次数等指标的统计.

3.1 简单狭窄环境下仿真结果与分析

简单狭窄环境下放置 1 张长 1.08 m、宽 1.5 m、高 0.56 m 的桌子, 如图 8 所示, 桌子高度远低于机械臂直立高度. 实验中机械臂初始构型位于桌面上, 关节向量为 $[-20.86^\circ, -11.92^\circ, 48.47^\circ, -137.62^\circ, -42.63^\circ, 166.51^\circ, 91.44^\circ]$; 其目标构型位于桌子下的置物桶上, 关节向量为 $[89.33^\circ, -96.94^\circ, -132.18^\circ, -124.51^\circ, 83.54^\circ, 136.71^\circ, 19.65^\circ]$. 图中蓝色表示机械臂起始构型, 橙色表示机械臂目标构型. 由于环境复杂程度较低, 训练集容量设置为 25 000, 快速碰撞检测模型的聚类数 k 设置为 7, 检测阈值 $\rho_{\text{collision}}$ 与 ρ_{free} 分别设置为 -0.04 与 0.01 . 仿真结果如表 1 所示.



(a) 环境侧视图 (b) 环境俯视图
(a) Environment side view (b) Environment vertical view

图 8 简单狭窄环境仿真测试: 物体抓取与分拣
Fig.8 Simple narrow environment simulation test:
Object grasping and sorting

表 1 简单狭窄环境下算法性能对比

Table 1 Algorithm performance comparison in simple narrow environment


采样方法	成功率	规划时间均值 (s)	平均碰撞检测次数
本文方法	0.90	0.94 ± 0.18	14336
RRT-Connect	0.90	1.24 ± 0.68	23759
SDCL	0.90	1.79 ± 0.42	23830
RRT	0.10	1.87 ± 0.01	31543
Lazy-RRT	0.17	2.17 ± 5.93	314
TRRT	—	—	—
PRM	0.17	4.27 ± 4.64	62357
Lazy-PRM	—	—	—
KPIECE	0.13	4.42 ± 6.03	76696
BKPIECE	0.87	3.54 ± 3.33	60330
EST	—	—	—

注: 加粗字体表示各列最优结果 (由于 Lazy-RRT 算法成功率极低, 故未参与比较).

较简单的采样方法如 RRT、PRM、TRRT、EST、KPIECE 等在该狭窄程度较低的环境中规划成功率低且速度慢, 而本文所提方法成功率达到 90%. 相较于 RRT-Connect、SDCL、BKPIECE, 本文算法在成功率与之相当的情况下, 其规划效率分别提升 24.19%、47.49%、73.45%, 平均碰撞检测次数明显降低. 本文算法通过狭窄环境下构型空间的针对性探索与碰撞检测模块的替换, 使其规划效率相较于 RRT-Connect 算法得到提升. 另外, 算法通过采用轻量级球形 K-means 聚类、多线程并行及模型训练不干扰基线规划等设计, 与通过求解非线性最优问题进行流形采样的 SDCL 相比, 在复杂程度较低的环境中避免了高昂的计算开销, 规划效率更高.

3.2 开放式狭窄环境下仿真结果与分析

开放环境主要由 25 条长度不一、半径为 0.05 m 的电线以及 8 个直线塔、5 个耐张塔和 1 个升降台组成. 电线纵横交错, 最小间距为 0.47 m, 如图 9 所示. 交错的电线将机械臂工作空间分割为若干狭窄



(a) 环境侧视图 (b) 环境俯视图
(a) Environment side view (b) Environment vertical view

图 9 开放式狭窄环境仿真测试: 配网带电作业
Fig.9 Opened narrow environment simulation test:
Live-line working in distribution networks

离散的子空间, 机械臂工作空间受到限制, 但整体仍然处在开放环境中. 实验中机械臂初始构型位于耐张塔内, 关节向量为 $[-39.76^\circ, -52.31^\circ, 135.44^\circ, -24.12^\circ, -139.69^\circ, 170.22^\circ, 142.28^\circ]$; 其目标构型位于两直角塔输电线段间, 关节向量为 $[-2.64^\circ, 73.51^\circ, 43.54^\circ, -39.07^\circ, -14.21^\circ, 194.75^\circ, -132.58^\circ]$. 图中蓝色为机械臂起始构型, 橙色为机械臂目标构型. 由于环境具有明显的狭窄特性, 故将算法中训练集容量上限设置为 50 000, 快速碰撞检测模型的聚类数 k 设置为 14, 检测阈值 $\rho_{\text{collision}}$ 与 ρ_{free} 分别设置为 -0.01 与 0.04 .

仿真结果如表 2 所示. 由于开放式狭窄环境较简单环境的狭窄程度进一步提高, 交错电线较大幅度限制了机械臂的工作空间, 故 RRT、PRM 等基础算法在该环境下规划成功率基本为 0. 而本文所提算法将传统基于包围盒的碰撞检测转化为构型与聚类簇之间的马氏距离计算, 从而在规划成功率相近的情况下, 规划效率较 RRT-Connect 提升 58.30%, 平均碰撞检测次数降低 62.39%. 同时, 所提算法与基于连通性学习的 SDCL 算法性能相当. 此外, 该环境存在大量由密集障碍物分割形成的狭窄通道, 其宽度窄于 BKPIECE 算法的固定网格分辨率, 导致 BKPIECE 难以有效识别和探索关键连通区域, 规划效率与成功率较低.

表 2 开放式狭窄环境下算法性能对比
Table 2 Algorithm performance comparison in opened narrow environments

采样方法	成功率	平均时间均值 (s)	平均碰撞检测次数
本文方法	0.83	19.50 ± 5.01	83319
RRT-Connect	0.83	46.76 ± 37.10	221 551
SDCL	0.80	19.09 ± 1.22	78 357
RRT	—	—	—
Lazy-RRT	—	—	—
TRRT	—	—	—
PRM	0.03	30.99 ± 0	90 170
Lazy-PRM	—	—	—
KPIECE	—	—	—
BKPIECE	0.50	42.06 ± 5.31	130 682
EST	—	—	—

3.3 封闭式狭窄环境下仿真结果与分析

封闭式狭窄环境主要由 9 个长 0.23 m、宽 0.2 m、高 0.22 m 置物格组成的置物架以及 1 个控制台、5 个垂直摆放的建材、1 张桌子、1 个废弃物放置桶和 1 个长 1.1 m、宽 1 m、高 1 m 的长方形舱体组成, 如图 10 所示. 该环境因机械臂工作空间被舱体四

面包围与压缩, 臂展为 1.26 m 的机械臂无法完全伸直作业而得名. 此时, 封闭舱体内其他障碍物的放置严重限制了机械臂的工作空间. 实验中机械臂初始构型位于置物架左下角的方格中, 关节向量为 $[-58.67^\circ, 41.71^\circ, 16.96^\circ, -130.99^\circ, -8.25^\circ, 206.20^\circ, -37.76^\circ]$; 其目标构型位于置物架右上角的方格中, 关节向量为 $[-69.04^\circ, -53.29^\circ, 77.81^\circ, -100.96^\circ, 28.76^\circ, 154.41^\circ, 117.51^\circ]$, 以完成置物架对角线取放物体的任务. 图中蓝色为机械臂起始构型, 橙色为机械臂目标构型. 算法中训练集容量设置为 50 000, 快速碰撞检测模型的聚类数 k 设置为 21, 检测阈值 $\rho_{\text{collision}}$ 与 ρ_{free} 分别设置为 -0.01 与 0.04 .




图 10 封闭式狭窄环境仿真测试: 重大装备加工制造
Fig.10 Closed narrow environment simulation test: Major equipment processing and manufacturing

仿真结果如表 3 所示. 由于封闭环境的狭窄性最为明显, 大部分算法在其中规划均为失败. 本文所提基于在线聚类的快速碰撞检测规划算法在其中展现出较高的规划效率与成功率, 相较于 RRT-Connect 规划效率提高 58.47%, 成功率提高 19.18%, 平均碰撞检测次数减少 66.98%, 而相对于学习狭窄特性的 SDCL, 在成功率相近的前提下, 规划效率提高 15.89%, 且平均碰撞检测次数减少 11.81%. 显

表 3 封闭式狭窄环境下算法性能对比
Table 3 Algorithm performance comparison in closed narrow environments

采样方法	成功率	平均时间均值 (s)	平均碰撞检测次数
本文方法	0.87	35.05 ± 39.82	332 764
RRT-Connect	0.73	84.40 ± 2.22	1 007 664
SDCL	0.90	41.67 ± 1.81	377 318
RRT	—	—	—
Lazy-RRT	—	—	—
TRRT	—	—	—
PRM	—	—	—
Lazy-PRM	—	—	—
KPIECE	—	—	—
BKPIECE	0.97	84.17 ± 53.95	460 425
EST	—	—	—

然,本文方法中线程并行、重规划机制、快速碰撞检测方法的设计,使其在复杂程度高、作业空间严重压缩的环境中具有良好的性能表现。

参数 $\rho_{\text{collision}}$ 与 ρ_{free} 的设定取决于环境的狭窄程度,二者共同界定碰撞构型与自由构型间的决策边界。合理的参数设置能够减少快速碰撞检测中假阴性或假阳性的样本数量。具体地,在简单环境中自由空间占主导,适当降低 $\rho_{\text{collision}}$ 与 ρ_{free} 的取值,可在放宽对自由构型判定条件的同时加强对碰撞构型的检测,有助于减少将实际碰撞构型误判为自由构型的概率。反之,在复杂环境中碰撞区域占比较大,适当提高二者取值,可强化对自由构型的识别能力,减少将实际自由构型误判为碰撞构型的数量。基于大量仿真测试,本文总结出 2 组具有一定环境适用性的参数,一是在简单环境中, $\rho_{\text{collision}}$ 与 ρ_{free} 建议设置为 -0.04 、 0.01 ;二是在复杂环境中, $\rho_{\text{collision}}$ 与 ρ_{free} 建议设置为 -0.01 、 0.04 。通过合理设置参数 $\rho_{\text{collision}}$ 与 ρ_{free} ,可在一定程度上减少快速碰撞检测模型中的误判结果,提高模型的检测精度。

综上,本文算法在不同复杂程度的狭窄空间中进行大量的仿真测试,均表现出优良的性能。具体地,较最新发表的 SDCL 算法而言,所提算法在简单狭窄环境中搜索效率显著提升,在开放环境中搜索性能与之相当,在最为复杂的封闭式狭窄空间中规划效率仍有 15.89% 的提升。SDCL 由于采用流形采样与非线性 SVM 频繁训练的实现机制,在简单环境中计算负担较重,从而导致规划效率下降。而本文通过在线构建快速碰撞检测模型,结合轻量无监督的球形 K-means 策略,保障算法的环境适应能力与整体规划效率。同时,本文算法较基线规划算法 RRT-Connect 在三类场景下路径搜索效率均有显著提升。换言之,所提算法在狭窄程度由易到难的环境下,兼具 SDCL 算法在狭窄环境中的规划能力与 RRT-Connect 算法高效处理多样化场景的优势,具有良好的实用性。

3.4 单次快速碰撞检测耗时结果与分析

本文所提快速碰撞检测算法,通过将传统基于包围盒的碰撞检测转化为待检测构型与聚类簇的马氏距离计算,旨在减少单次碰撞检测耗时以提高规划效率。因此,为验证该方法对路径搜索效率的影响,本文在 30 次规划中分别统计基于包围盒的层次碰撞检测与基于高维聚类的快速碰撞检测两类方法在数据测试集上的单次检测平均耗时,结果如图 11 所示,左侧主坐标轴表示基于高维聚类的快速碰撞检测耗时,右侧次坐标轴表示基于包围盒的层次碰撞检测耗时。由图 11 可知,所提检测方法通





图 11 单次碰撞检测平均耗时对比

Fig. 11 Comparison of average time consumption for single collision detection


过轻量级距离计算与阈值比较,相较于传统方法中的空间划分与递归检测过程,单次碰撞检测耗时显著减少,在简单、开放、封闭三类狭窄环境下分别减少 85.71%、94.00%、88.65%,验证了本文快速碰撞检测模型设计的有效性。

3.5 实机实验验证

为验证算法在实际场景中规划的可行性,本节基于 Franka Emika Panda 机械臂,搭建两类典型实际场景进行验证:开放式狭窄环境与封闭式狭窄环境,如图 12 所示。在开放式狭窄实机环境中,机



(a) 开放式狭窄环境
(a) Opened narrow environment



(b) 封闭式狭窄环境
(b) Closed narrow environment

图 12 机械臂实机验证环境示意图

Fig. 12 Schematic diagram of real machine verification environment of robotic arm

机械臂从顶部水平平行的电线间运动至前侧竖直平行的电线间, 起始与目标构型分别为 $[5^\circ, 29^\circ, -8^\circ, -64^\circ, 4^\circ, 93^\circ, 43^\circ]$ 与 $[-97^\circ, 99^\circ, 73^\circ, -122^\circ, -82^\circ, 207^\circ, 28^\circ]$; 在封闭式狭窄环境下, 机械臂在无法完全伸直的作业舱体中, 从高度受限的置物盒运动至开放的置物盒中, 起始与目标构型分别为 $[-26^\circ, 54^\circ, 8^\circ, -46^\circ, -4^\circ, 96^\circ, 47^\circ]$ 与 $[130^\circ, -12^\circ, -119^\circ, -130^\circ, 12^\circ, 200^\circ, -28^\circ]$. 本节在每个场景独立运行本文所提算法、RRT-Connect 与 SDCL 各 6 次, 统计相关性能指标. 如表 4 所示, 本文所提算法在实际狭窄场景中同样表现出规划成功率高、速度快的优势.

上述两种场景的规划路径如图 13 所示, 子图 Step 1 中标注了机械臂的起始与目标构型, 其余子图中机械臂虚影为上一时刻构型, 黄色箭头表示机械臂上一时刻至下一时刻的运动方向.

4 讨论

1) 本文方法中快速碰撞检测模块可能存在假阴性与假阳性的误判样本. 假阳性样本直接影响路径的可行性, 因而引入重规划机制以保障最终路径


表 4 实机实验算法性能对比

Table 4 Algorithm performance comparison in real machine experiments

环境类别	算法	规划成功率	规划耗时均值 (s)
开放式狭窄实机环境	本文	1.00	1.05
	RRT-Connect	0.83	1.53
	SDCL	0.83	2.41
封闭式狭窄实机环境	本文	1.00	0.38
	RRT-Connect	1.00	0.63
	SDCL	0.83	2.99


的可行性; 而假阴性样本通常表明待检测构型邻近碰撞簇, 潜在碰撞风险较高. 此类样本的存在促使算法采取更为保守的搜索策略, 对算法规划效率的影响相对有限. 本文通过参数调整以减少假阴性样本的出现, 保证路径搜索的高效性.

2) 尽管本文模型可通过阈值调节降低假阴性误判概率, 但在极端情形下, 若唯一可行路径上的关键自由构型被误判, 仍可能导致规划失败. 本文算法与现有数据驱动近似碰撞检测模型的方法 [21–22, 41–42] 类似, 虽然实现了高效、准确的碰撞检测, 但并未对方法的理论完备性进行严格证



(a) 开放式狭窄环境作业实机验证

(a) Real machine validation of opened narrow environment operation



(b) 封闭式狭窄环境作业实机验证

(b) Real machine validation of closed narrow environment operation

图 13 狭窄环境下机械臂规划路径示意图

Fig. 13 Schematic diagram of robotic arm planning path in narrow environment

明. 此外, 在实际应用中, 由于机械臂自身高自由度冗余构型的存在, 这类唯一路径的极端情况较为罕见; 即使存在此类路径, 受传感器噪声与控制误差的影响, 系统也难以实现对其的精确跟踪. 因此, 该极端情形在工程实践中可等效为无可行解问题. 尽管如此, 为提升方法的理论完备性与鲁棒性, 后续工作将引入历史误判构型的回溯与再验证等机制进行深化研究.

3) 在线快速碰撞检测基于球形 K-means 对构型数据进行聚类, 检测的效率与精度受限于聚类数 k 与初始值的选择, 因此未来可聚焦于更高效的高维数据聚类方法以优化该环节. 此外, 当前实验基于 MoveIt 静态场景进行, 障碍物位置依赖人工测量. 为此, 在模型中对障碍物施加了保守的膨胀处理, 以补偿潜在的建模误差, 确保实机运行的安全. 后续研究将进一步引入点云在线感知, 并扩展至动态障碍与多目标场景, 建立多维评价指标体系, 系统衡量算法在复杂真实环境中的性能与实用价值.

5 结束语

本文提出一种狭窄空间中基于高维构型空间快速碰撞检测的在线路径规划算法, 算法并行执行在线快速碰撞检测模型、基线路径规划两部分. 首先, 在线快速碰撞检测模型通过兼顾全局与狭窄环境的数据集在线构建策略, 提高自由构型与碰撞构型数量、均衡数据集的构建速度. 在快速碰撞检测模型训练部分, 对自由构型与碰撞构型数据进行映射与聚类, 将获得的聚类簇作为快速碰撞检测的信息基础. 若该模型精度达到预设阈值, 则将其替代基线路径规划算法中传统基于包围盒的碰撞检测方法. 该部分在线训练与检测的设计保证了算法的环境适应能力与高效性. 其次, 基线路径规划部分采用的并行设计能在快速碰撞检测模型启用前完成部分搜索树的生长, 从而提升整体路径规划的效率. 此外, 线程并行执行与针对模型误判结果的重规划机制共同保障了算法搜索的成功率与效率. 本文所提算法在狭窄程度递增的简单、开放、封闭三类环境中完成仿真对比实验, 并基于开放与封闭实际场景完成实机验证. 结果表明, 本文算法具有更优的搜索成功率与效率, 验证了其工程实践的有效性与可行性.

参考文献

- Wang Yao-Nan, Jiang Yi-Ming, Jiang Jiao, Zhang Hui, Tan Hao-Ran, Peng Wei-Xing, et al. Key technologies of robot perception and control and its intelligent manufacturing applications. *Acta Automatica Sinica*, 2023, **49**(3): 494–513 (王耀南, 江一鸣, 姜娇, 张辉, 谭浩然, 彭伟星, 等. 机器人感知与控制关键技术及其智能制造应用. 自动化学报, 2023, **49**(3): 494–513)
- Zhang Zhen-Guo, Mao Jian-Xu, Tan Hao-Ran, Wang Yao-Nan, Zhang Xue-Bo, Jiang Yi-Ming. A review of task allocation and motion planning for multi-robot in major equipment manufacturing. *Acta Automatica Sinica*, 2024, **50**(1): 21–41 (张振国, 毛建旭, 谭浩然, 王耀南, 张雪波, 江一鸣. 重大装备制造多机器人任务分配与运动规划技术研究综述. 自动化学报, 2024, **50**(1): 21–41)
- Hu Zi-Qi, Yuan Jing, Gong Yan-Song, Yu Shi-Zhuo, Zhang Xue-Bo. Reconstruction of lead wires of power lines for live-line working robots in distribution networks. *Control Engineering of China*, 2021, **28**(11): 2123–2130 (胡子琦, 苑晶, 公岩松, 俞诗卓, 张雪波. 面向配网带电作业机器人的输电线引线重建. 控制工程, 2021, **28**(11): 2123–2130)
- Bai Guang-Rui, Zheng Yu-Xiang, Wu Kai, Wu Shao-Lei, Guo Rui, Zhao Yu-Liang, et al. Power line identification and localization for live working robot of distribution line. *Power System Technology*, 2023, **47**(6): 2604–2611 (柏光瑞, 郑育祥, 吴凯, 吴少雷, 郭锐, 赵玉良, 等. 面向配网带电作业机器人的导线识别定位方法. 电网技术, 2023, **47**(6): 2604–2611)
- Zhang Hui-Wen, Su Yun, Liu Yu-Wang, Zhao Xin-Gang, Fu Cheng-Long, Leng Yu-Quan. SGPD: Stable grasp pose detection in complex environment. *Robot*, 2024, **46**(6): 703–712 (张会文, 苏贇, 刘玉旺, 赵新刚, 付成龙, 冷雨泉. SGPD: 复杂环境下的稳定抓取位姿检测. 机器人, 2024, **46**(6): 703–712)
- Cai Peng, Yue Xiao-Kui. Motion planning of space manipulator for on-orbit assembly based on HS-RRV algorithm. *Robot*, 2023, **45**(2): 166–178 (蔡鹏, 岳晓奎. 基于 HS-RRV 算法的空间机械臂在轨装配运动规划. 机器人, 2023, **45**(2): 166–178)
- Ratliff N, Zucker M, Bagnell J A, Srinivasa S. CHOMP: Gradient optimization techniques for efficient motion planning. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Kobe, Japan: IEEE, 2009. 489–494
- Kalakrishnan M, Chitta S, Theodorou E, Paster P, Schaal S. STOMP: Stochastic trajectory optimization for motion planning. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Shanghai, China: IEEE, 2011. 4569–4574
- Lavalle S. Rapidly-exploring random trees: A new tool for path planning. *Research Report*: 1999.
- Kavraki L E, Svestka P, Latombe J C, Overmars M H. Probabilistic roadmaps for path planning in high-dimensional configuration spaces. *IEEE Transactions on Robotics and Automation*, 2002, **12**(4): 566–580
- Das N, Yip M. Learning-based proxy collision detection for robot motion planning applications. *IEEE Transactions on Robotics*, 2020, **36**(4): 1096–1114
- Boor V, Overmars M H, van der Stappen A F. The Gaussian sampling strategy for probabilistic roadmap planners. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Detroit, USA: IEEE, 1999. 1018–1023
- Hsu D, Jiang T, Reif J, Sun Z. The bridge test for sampling narrow passages with probabilistic roadmap planners. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Taipei, China: IEEE, 2003. 4420–4426
- Xun X, Zhang R, Chai S, Chai R, Xia Y. Light reflection-guided RRT*: Efficient path planning in narrow passages. *IEEE Robotics and Automation Letters*, 2025, **10**(11): 11474–11481
- Ichter B, Harrison J, Pavone M. Learning sampling distributions for robot motion planning. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Brisbane, Australia: IEEE, 2018. 7087–7094
- Qureshi A H, Miao Y, Simeonov A, Yip M C. Motion planning networks: Bridging the gap between learning-based and classical motion planners. *IEEE Transactions on Robotics*, 2020, **37**(1): 48–66
- Wang Y, Duan X, He J. Learning-based motion planning with

- mixture density networks. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Yokohama, Japan: IEEE, 2024. 16482–16488
- 18 Wang R, Wang S, Ye J, Zhang Y, Hao L. Learning-based motion planning leveraging multivariate deep evidential regression. *IEEE Transactions on Robotics*, 2025, **41**: 5816–5834
 - 19 Li S, Dantam N T. Sample-driven connectivity learning for motion planning in narrow passages. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). London, United Kingdom: IEEE, 2023. 5681–5687
 - 20 Bohlin R, Kavraki L E. Path planning using lazy PRM. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). San Francisco, USA: IEEE, 2000. 521–528
 - 21 Koptev M, Figueroa N, Billard A. Neural joint space implicit signed distance functions for reactive robot manipulator control. *IEEE Robotics and Automation Letters*, 2022, **8**(2): 480–487
 - 22 Liu B, Jiang G, Zhao F, Mei X. Collision-free motion generation based on stochastic optimization and composite signed distance field networks of articulated robot. *IEEE Robotics and Automation Letters*, 2023, **8**(11): 7082–7089
 - 23 Joho D, Schwinn J, Safronov K. Neural implicit swept volume models for fast collision detection. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Yokohama, Japan: IEEE, 2024. 15402–15408
 - 24 Lee M, Lee J, Lee D. Narrow passage path planning using collision constraint interpolation. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Atlanta, USA: IEEE, 2025. 1–7
 - 25 Huh J, Lee D D. Learning high-dimensional mixture models for fast collision detection in rapidly-exploring random trees. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Stockholm, Sweden: IEEE, 2016. 63–69
 - 26 Yu C, Gao S. Reducing collision checking for sampling-based motion planning using graph neural networks. *Advances in Neural Information Processing Systems*, 2021, **34**: 4274–4289
 - 27 Xu J, He Y, Tian H, Wei Z. A random path sampling-based method for motion planning in many dimensions. *IEEE Transactions on Instrumentation and Measurement*, 2022, **73**: 1–8
 - 28 Huang S, Wang Z, Li P, Jia B, Liu T, Zhu Y, et al. Diffusion-based generation, optimization, and planning in 3D scenes. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, Canada: IEEE, 2023. 16750–16761
 - 29 Carvalho J, Le A T, Kicki P, Koert D, Peters J. Motion planning diffusion: Learning and adapting robot motion planning with diffusion models. *IEEE Transactions on Robotics*, 2025, **41**: 4881–4901
 - 30 Zhang Q, Liu Z, Fan H, Liu G, Zeng B, Liu S. FlowPolicy: Enabling fast and robust 3D flow-based policy via consistency flow matching for robot manipulation. In: Proceedings of the AAAI Conference on Artificial Intelligence. Philadelphia, USA: AAAI Press, 2025. 14754–14762
 - 31 Das D, Lu Y, Plaku E, Xiao X. Motion memory: Leveraging past experiences to accelerate future motion planning. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Yokohama, Japan: IEEE, 2024. 16467–16474
 - 32 Kuffner J J, LaValle S M. RRT-connect: An efficient approach to single-query path planning. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). San Francisco, USA: IEEE, 2000. 995–1001
 - 33 Dhillon I S, Modha D S. Concept decompositions for large sparse text data using clustering. *Machine Learning*, 2001, **42**(1): 143–175
 - 34 Hornik K, Feinerer I, Kober M, Buchta C. Spherical K-means clustering. *Journal of Statistical Software*, 2012, **50**: 1–22
 - 35 Li M, Xu D, Zhang D, Zou J. The seeding algorithms for spherical k-means clustering. *Journal of Global Optimization*, 2020, **76**(4): 695–708
 - 36 Chitta S, Sucan I, Cousins S. MoveIt! [ROS Topics]. *IEEE Robotics and Automation Magazine*, 2012, **19**(1): 18–19
 - 37 Sucan I A, Moll M, Kavraki L E. The open motion planning library. *IEEE Robotics and Automation Magazine*, 2012, **19**(4): 72–82
 - 38 Sucan I A, Kavraki L E. A sampling-based tree planner for systems with complex dynamics. *IEEE Transactions on Robotics*, 2011, **28**(1): 116–131
 - 39 Jaillet L, Cortés J, Siméon T. Sampling-based path planning on configuration-space costmaps. *IEEE Transactions on Robotics*, 2010, **26**(4): 635–646
 - 40 Hsu D, Latombe J C, Motwani R. Path planning in expansive configuration spaces. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Albuquerque, USA: IEEE, 1997. 2719–2726
 - 41 Zhu X, Xin Y, Li S, Liu H, Xia C, Liang B. Efficient collision detection framework for enhancing collision-free robot motion. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Atlanta, USA: IEEE, 2025. 16162–16168
 - 42 Fujii S, Pham Q C. Realtime trajectory smoothing with neural nets. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Philadelphia, USA: IEEE, 2022. 7248–7254



赖希睿 南开大学人工智能学院硕士研究生。2024 年获得南开大学学士学位。主要研究方向为机械臂运动规划。
E-mail: laixirui@mail.nankai.edu.cn
(LAI Xi-Rui Master student at the College of Artificial Intelligence, Nankai University. He received his bachelor degree from Nankai University in 2024. His main research interest is motion planning of robotic arm.)



王润花 南开大学机器人与信息自动化研究所讲师。主要研究方向为移动机器人自主导航, 机器人运动规划。本文通信作者。
E-mail: wrunhua@nankai.edu.cn
(WANG Run-Hua Lecturer at the Institute of Robotics and Automatic Information System, Nankai University. Her research interests include mobile robot autonomous navigation and robot motion planning. Corresponding author of this paper.)



王耀南 中国工程院院士, 湖南大学电气与信息工程学院教授。1995 年获湖南大学博士学位。主要研究方向为机器人学, 智能控制与图像处理。
E-mail: yaonan@hnu.edu.cn
(WANG Yao-Nan Academician at Chinese Academy of Engineering,

professor at the College of Electrical and Information Engineering, Hunan University. He received his Ph.D. degree from Hunan University in 1995. His research interests include robotics, intelligent control, and image processing.)



张雪波 南开大学机器人与信息自动化研究所教授. 主要研究方向为智能机器人, 包括建图定位、运动规划、视觉伺服、人智协同.

E-mail: zhangxuebo@nankai.edu.cn

(**ZHANG Xue-Bo** Professor at the Institute of Robotics and Automat-

ic Information System, Nankai University. His research interests include intelligent robotics, including mapping and localization, motion planning, visual servoing, and human-AI collaboration.)



杨磊 国网天津市电力公司电力科学研究院高级工程师. 主要研究方向为配电技术, 电力机器人和国际标准.

E-mail: lei.yang3@tj.sgcc.com.cn

(**YANG Lei** Senior engineer at the Electric Power Research Institute, State Grid Tianjin Electric Power

Company. His research interests include distribution technology, power robots, and international standard.)



李帅 浙江大学机械工程学院博士研究生, 正高级工程师. 主要研究方向为电力机器人, 机器人智能决策与控制系统设计.

E-mail: lishuai@sgepri.sgcc.com.cn

(**LI Shuai** Ph.D. candidate at the School of Mechanical Engineering, Zhejiang University. He is a senior engineer. His

research interests include electric robots, and the design of robot intelligent decision-making and control systems.)