

面向薄板件在线检测的机器人轨迹自主规划

王元民, 李彦征, 王雪琪, 段振霞, 刘银华

(上海理工大学 机械工程学院, 上海 200093)

摘要: 针对工业机器人在非结构化环境中轨迹规划效率低、规划结果适应性差等问题, 提出一种基于生成对抗式神经网络的视觉检测机器人在线轨迹规划算法。首先, 提出基于机器人操作系统仿真的点云数据集构建方法。其次, 通过对检测特征点云数据提取和机器人检测轨迹的自动标注, 提出全新的基于编码-解码结构的生成对抗式网络, 利用所输入的检测特征点云数据端到端地生成机器人检测轨迹。同时, 通过融合薄板件的点云几何特征的自注意力机制模块, 提高了生成轨迹的准确性。然后, 结合机器人运动学模型, 提出一种多样性损失函数, 提高了生成对抗式网络所生成数据的多样性, 解决了笛卡尔空间到机器人关节空间映射的不唯一性下的求解难题。最后, 通过案例对比分析, 验证了算法的有效性。结果表明: 机器人检测规划时间降低了 52.6%, 末端轨迹精度提高了 67.4%。

关键词: 薄板件检测; 工业机器人; 轨迹规划; 生成对抗式网络

中图分类号: TP 15 **文献标志码:** A

Autonomous robot trajectory planning for online inspection of compliant sheet parts

WANG Yuanmin, LI Yanzheng, WANG Xueqi, DUAN Zhenxia, LIU Yinhua

(School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: A vision inspection robot online trajectory planning algorithm based on generative adversarial neural networks was proposed for industrial robots to address the problems of low trajectory planning efficiency and poor adaptability of planning results in unstructured environments. Firstly, a point cloud dataset construction method based on robot operating system simulation was proposed. Secondly, a new

收稿日期: 2023-04-25

基金项目: 国家自然科学基金资助项目(51875362); 上海市自然科学基金资助项目(21ZR1444500); 上海市浦江人才计划(22PJD048)

第一作者: 王元民(1999-), 男, 硕士研究生。研究方向: 机器人运动规划。E-mail: wang_yuan_min@163.com

通信作者: 刘银华(1983-), 女, 教授。研究方向: 数字化工艺设计与制造。E-mail: liuyinhua@usst.edu.cn

引文格式: 王元民, 李彦征, 王雪琪, 等. 面向薄板件在线检测的机器人轨迹自主规划[J]. 上海理工大学学报, 2024, 46(5): 517-524.

Citation: WANG Yuanmin, LI Yanzheng, WANG Xueqi, et al. Autonomous robot trajectory planning for online inspection of compliant sheet parts[J]. Journal of University of Shanghai for Science and Technology, 2024, 46(5): 517-524.

coding-decoding structure-based generative adversarial networks was proposed to generate robot inspection trajectories end-to-end using the point cloud data of the input inspection features by extracting the point cloud data of the inspection features and automatically labeling the robot inspection trajectories. Meanwhile, the accuracy of the generated trajectories was improved by incorporating a self-attention mechanism module with point cloud geometric features of compliant sheet parts. Then, a diversity loss function was proposed in conjunction with the robot kinematics to improve the diversity of the data generated by the generative adversarial network and solve the solution problem under the uniqueness of the mapping from Cartesian space to robot joint space. Finally, the effectiveness of the algorithm in this paper was verified by case comparison analysis. The results show that the robot inspection planning time is reduced by 52.6% and the end trajectory accuracy is improved by 67.4%.

Keywords: *compliant sheet parts inspection; industrial robot; trajectory planning; generative adversarial networks*

随着人工智能、传感器、网络和通信技术的快速发展，工业机器人智能化程度不断提升，其发展方向趋于高度的自主性，具有自学习能力的运动规划方法成为一个重要的研究方向^[1]。运动规划是利用传感器获取的外部信息，搜索当前位姿到目标位姿的无碰撞最优路径。目前运动规划方法可以分为基于采样的运动规划和基于学习算法的运动规划。

基于采样的运动规划算法主要由概率图法 (probabilistic roadmap, PRM)^[2] 和快速探索随机树法 (rapidly exploring random tree, RRT)^[3] 构成。张振等^[4] 提出了基于约束采样的 RRT 算法，通过减少重复性采样，提高了全局搜索效率。王怀震等^[5] 提出基于自适应步长的启发式 RRT*-Connect 算法，引入目标偏向策略进行椭圆子集约束采样，使得采样点可以更快地收敛到最优值。陈满意等^[6] 提出低振荡人工势场-自适应快速扩展树混合算法，实现了路径规划中快速逃离局部极小、碰撞等情况。Qureshi 等^[7] 使用智能双向快速探索树算法 (IB-RRT*) 用于复杂环境中的机器人运动规划。Gao 等^[8] 使用高斯采样机制和中点碰撞检测来实现狭窄焊缝和密集障碍物场景的高效规划。

然而，面对非结构化场景，基于采样的运动规划方法不仅难以满足实时性需求，而且缺乏先验知识，同时无法利用三维环境信息，因此国内外学者研究基于学习算法的运动规划方法，利用深度学习 (deep learning, DL) 算法的神经网络感知能力从未知环境状态的输入中提取特征，实现从环境信息到规划结果的映射。Fang 等^[9] 提出一个

端到端的抓取姿态预测网络，以点云数据作为网络输入，学习其抓取位姿和接近方向。Zhao 等^[10] 提出一种终身学习框架，首先基于生成对抗式网络 (generative adversarial networks, GAN) 构建一个轻量级轨迹规划模型，用于映射初始状态、最终状态和控制行为序列，其次通过将 GAN 嵌入到 RRT 算法中，解决了目前长距离多阶段任务难以规划问题。DeepMind 团队进行融合强化学习 (reinforcement learning, RL)，提出一种深度强化学习 (deep reinforcement learning, DRL) 方法^[11]。Zhu 等^[12] 提出基于 Actor-Critic 模型与 AI2-THOR 框架，提供了一个高质量三维场景，解决了 DRL 难以收敛和缺乏对新目标的泛化能力，该框架为端到端训练方式，降低了特征匹配及三维重建过程的不确定性。周玮杰^[13] 提出基于近端策略优化的动态窗口方法，设计一种新型深度神经网络，获取环境信息与动态窗口方法中评价函数的权重因子相关联，在非结构化环境下，验证了算法对于环境变化的自适应性，赋予了机器人在动态环境下的作业能力。Qureshi 等^[14] 在不以原始点云数据和障碍物信息作为输入的前提下，使用卷积神经网络 (convolutional neural networks, CNN) 学习对象级语义信息生成的采样分布，改进了未知环境中的规划结果。Huh 等^[15] 借鉴强化学习中状态-行为值函数的概念，提出 Softmax 节点选择方法，加速了 RRT 算法的规划效率。

综上所述，为了提高工业机器人在非结构化环境下轨迹规划的效率和质量，本文提出一种基于生成对抗式神经网络的机器人在线检测轨迹

规划算法, 在充分融合三维环境信息与运动规划的前提下, 构建了一种环境到运动的直接规划方法。

1 检测工艺数据集构建

目前高效的 DL 模型依赖于大量数据集, 在面对机器人检测问题, 目前并没有相关的数据集被提出。为了实现机器人在线检测工艺规划, 本文

构建了具有丰富标注的孔、槽等待检测特征的检测路径生成数据集。基于机器人操作系统 (robot operation system, ROS) 仿真环境获取相关点云信息, 并计算得到机器人检测过程的运动信息, 最终获得完整的检测数据集。具体过程如图 1 所示。其中, URDF 模型为统一机器人描述格式的文本文件。

获取点云数据需要对孔边界点云及机器人检测的运动轨迹进行标注。




图 1 机器人在线检测工艺规划数据集构建
Fig.1 Construction of online planning dataset for robotic inspection

1.1 孔边界点云数据标注

通过数据增强后, 共得到 1008 组点云数据, 为每一组点云数据注释孔边界点云将非常耗费人力。因此, 本文采用网格划分法^[16]对每一组点云数据进行孔边界点云的提取, 获得孔边界点云的标注结果, 如图 2 所示。



图 2 孔特征边界点云数据提取

Fig.2 Hole feature boundary point cloud data extraction

1.2 机器人运动轨迹标注

机器人运动轨迹标注与常见的视觉任务标注不同, 运动轨迹分布在一个较大的连续搜索空间中, 这带来了无限的标注, 手动注释每个场景的人工成本非常高。因此, 本文针对机器人检测问题, 提出了一种用于机器人检测运动轨迹的自动标注过程。如图 3 所示。

首先, 利用主成分分析 (principal component

analysis, PCA) 计算每个孔边界点云数据的特征向量, 即点云数据的 3 个主方向, 将 Z 轴主方向定义为孔的矢量方向, 最大特征值对应的特征向量定义为孔的主方向。其次, 查询 Gocator-2450 的用户手册可以得知, 其最佳扫描距离为 545 mm。之后, 计算孔在主方向上距离最远的两个点, 并分别沿孔的矢量方向延长 545 mm, 作为机器人的起点与终点, 同时 Gocator 的坐标系 Z 轴平行于孔的矢量方向, 指向待检测零件。最后, 利用机器人的逆运动学求解机器人的各关节角度。综上, 得到机器人运动轨迹的标注。




图 3 机器人检测运动轨迹标注
Fig.3 Labeling of robot inspection motion trajectory

2 自主运动规划网络框架

假设待检测特征的点云数据为 $P = \{p_i =$

$(x_i, y_i, z_i) | 1 \leq i \leq N\}$, $P \in \mathbb{R}^{N \times 3}$, 机器人关节空间的真实值定义为 $C = [\theta_{i1}, \theta_{i2}, \dots, \theta_{i6}]$, 本章节目的是基于输入的点云数据自主生成机器人运动过程的关节空间信息 $\hat{C} = [\hat{\theta}_{i1}, \hat{\theta}_{i2}, \dots, \hat{\theta}_{i6}]$, 其中 i 表示机器人在第 i 时刻的关节信息。

2.1 InsGAN 机器人运动轨迹生成框架

GAN 通常由两个相互对立训练的神经网络构成。这两个对立训练的模型为：捕获数据分布的生成模型与估计样本的来源是否为真实数据的判别模型。生成模型以变量 z 作为输入量，输出样本 $G(z)$ ，判别模型以样本 x 作为输入量，输出其为真实数据概率结果 $D(x)$ 。训练的目标函数为

$$\min_G \max_D V(G, D) = E_{x \sim p_{(x)}} [\log D(x)] + E_{z \sim p_{(z)}} [\log (1 - D(G(z)))] \tag{1}$$

式中： E 为数据分布信息， $p_{(x)}$ 为真实数据分布； $p_{(z)}$ 为生成器数据分布。

本文提出的 InsGAN 网络如图 4 所示。其中，LSTM(long short-term memory)为长短期记忆神经网络；MLP(multilayer perceptron)为多层感知机。与传统的 GAN 网络相似，该模型由轨迹生成器 G 和轨迹判别器 D 组成。生成器将待检测特征的点云数据作为输入量，然后输出机器人检测的运动轨迹。其中，轨迹生成器由 5 个模块组成：编码器、解码器、点云数据关系计算模块、注意力模块 A 及池化模块 P 。在编码器中，接受待检测特征的点云数据信息，基于 PointNet 框架进行编码，得到隐藏向量 H ，然后与点云数据间关系一起输入注意力模块中，从而实现对重点信息特征

提取的效率提升。池化模块 P 将注意力模块的输出 A 作为输入生成池化向量 P ，学习点云数据的分布对机器人运动轨迹的影响。解码器接受隐藏向量 H 与池化向量 P 作为机器人运动轨迹生成条件以生成轨迹。D 模块则接受 G 模块生成的机器人运动轨迹 $\hat{C}$ 和数据集的真实样本，对比真实数据与生成数据之间的关系，提升模型的有效性。

2.2 生成器模块

为实现点云数据 P 到机器人关节空间 C 的映射，将生成器设计为编码器-解码器的结构。

2.2.1 编码器

在编码器中，基于 PointNet 结构对点云数据的特征进行提取，将每个点 p_i 的特征升维至一个高维特征向量 H_i ，其中 $H_i \in \mathbb{R}^{1024}$ ，具体计算过程如下：

$$H_i = \text{PointNet}(p_i; W) \tag{2}$$

式中， W 表示编码器编码过程的权重。

2.2.2 注意力机制

机器人检测轨迹不仅与待检测特征的位置息息相关，也与待检测特征的形状紧密相连。为准确描述形状对机器人轨迹的影响，同时也为强化注意力机制对点云数据特征提取的准确性与针对性，本文考虑了点云数据的形状特征。

首先，利用 K 最邻近 (K -nearest neighbor, KNN) 算法计算点 p_i 的 K 个邻点，构建局部领域图 G ，并计算局部协方差矩阵 M ，计算方法如下：

$$M = \frac{1}{K} \sum_{j \in G} (p_j - \bar{p})(p_j - \bar{p})^T \tag{3}$$




图 4 InsGAN 框架

Fig.4 InsGAN framework


式中, $\bar{p}$ 表示局部邻域图 $\mathcal{G}$ 的中心点, 即 $\bar{p} = \frac{1}{K} \sum_{i=1}^K p_i$ 。其次, 基于奇异值分解算法计算协方差矩阵 $\mathbf{M}$ 的特征值 $\lambda_1^i, \lambda_2^i, \lambda_3^i, \lambda_1^i \geq \lambda_2^i \geq \lambda_3^i$ 。最后, 计算点 p_i 的线特征 L_i 、面特征 P_i 、球形特征 S_i 及各向异性 A_i 。

$$\begin{cases} L_i = \frac{\lambda_1 - \lambda_2}{\lambda_1} \\ P_i = \frac{\lambda_2 - \lambda_3}{\lambda_1} \\ S_i = \frac{\lambda_3}{\lambda_1} \\ A_i = \frac{\lambda_1 - \lambda_3}{\lambda_1} \end{cases} \quad (4)$$

基于所计算的低维几何特征 $f_1 = \{L_i, P_i, S_i, A_i\}$, 利用 MLP 层将低维的形状特征映射至高维特征空间, 计算得到高维几何特征 $f_h \in \mathbb{R}^{64}$ 。本文提出了基于自注意力机制^[17]的几何特征对检测轨迹影响权重的提取。注意力机制流程如图 5 所示。首先将 f_h 与隐藏向量 $\mathbf{H}$ 相结合, 并通过 MLP 层计算映射后的高维特征; 其次利用 $F(\mathbf{Q}, \mathbf{K}, \mathbf{V})$ 模块求解查询矩阵 $\mathbf{Q}$ 、键矩阵 $\mathbf{K}$ 及值矩阵 $\mathbf{V}$; 随后将与高维特征相减的结果输入至 MLP 层, 并再次与高维矩阵执行相加操作, 得到最终的结果 $\mathbf{A}$ 。具体计算过程如下:

$$\begin{cases} F'_h = \text{MLP}_1(f_h; \mathbf{H}) \\ F_a = F(\mathbf{Q}, \mathbf{K}, \mathbf{V})(F'_h) \\ F_s = \text{MLP}_2(F'_h - F_a) \\ \mathbf{A} = F_s + F'_h \end{cases} \quad (5)$$

式中, F'_h, F_a, F_s 均为过程变量。其中, $F(\mathbf{Q}, \mathbf{K}, \mathbf{V})$,



(a) 自注意力机制

$\mathbf{V}$ 模块的求解过程如公式 6 所示:

$$\begin{cases} (\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{MLP}_{(\mathbf{Q}, \mathbf{K}, \mathbf{V})}(P; W_Q, W_K, W_V) \\ F_a = \mathbf{Q} \times \mathbf{K}^T \times \mathbf{V} \end{cases} \quad (6)$$

其中, W_Q, W_K, W_V 分别为用于计算矩阵 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 的可学习系数。

对点云数据几何特征注意力机制的结果进行汇总, 输入至池化模块中, 池化模块可以更好的总结对机器人检测轨迹有决定性影响的信息, 最终输出结果 $\mathbf{P}$, 具体计算过程如公式 (7) 所示:

$$\mathbf{P} = \max(\mathbf{A}) \quad (7)$$

2.2.3 解码器

解码器主要用于生成机器人检测轨迹。不同于编码器的 PointNet 模块, 本文将 LSTM 网络用于解码器。将编码器产生的隐藏向量 $\mathbf{H}$ 与池化向量 $\mathbf{P}$ 相结合, 得到合成特征向量 $\mathbf{O}$, 作为编码器的输入, 可以有效对点云数据形状与机器人检测轨迹的关系进行推理。


$$\mathbf{O} = \text{MLP}(\mathbf{H}, \mathbf{P}) \quad (8)$$

$$\mathbf{C} = \text{MLP}(\text{LSTM}(\mathbf{O}; W_L); W_M) \quad (9)$$

式中: W_L 表示 LSTM 网络的参数, W_M 为输出层 MLP 的可学习参数。

2.3 判别器模块

如图 4 所示, 判别器模块由编码器、LSTM 及 MLP 层组成, 其目的是对生成的机器人检测轨迹可否接受进行判别。不同于生成器中的编码功能, 判别器的编码器由 PointNet 与 LSTM 组成, PointNet 接受原始点云数据, LSTM 接受生成器生成的检测轨迹与真实检测轨迹, 最后利用 MLP 输



(b) $F(\mathbf{Q}, \mathbf{K}, \mathbf{V})$ 模块流程

图 5 自注意力机制计算流程

Fig.5 Calculation process of self-attention mechanism

出机器人检测轨迹的真假标签。

$$\begin{aligned} H_D = & \text{LSTM}(\text{PointNet}(P; W_P), \\ & \text{LSTM}_e(C; W_e); W_L) \end{aligned} \tag{10}$$

$$L = \text{MLP}(H_D; W_M) \tag{11}$$

式中： H_D 为判别器内部数据传输的过程量； W_P 为 PointNet 模型参数； L 表示真假标签。

2.4 损失函数

根据机器人运动学可知，当末端位姿相同时，机器人关节空间 C 对应多组解，然而传统的损失函数让网络失去了生成多样性结果的可能，因此本文提出多样性损失函数，增加机器人检测轨迹的多样性。利用机器人运动学知识，将关节空间 C 映射至笛卡尔坐标系下，对网络的可学习参数进行优化，最终的损失函数为

$$\mathcal{L} = \mathcal{L}_G + \lambda \mathcal{L}_* \tag{12}$$

式中： $\mathcal{L}_G$ 为 GAN 网络的损失函数； λ 为平衡因子； $\mathcal{L}_*$ 为多样性损失。

$$\mathcal{L}_* = \|\text{Kin}(\widehat{C}) - \text{Kin}(C)\|_2^2 \tag{13}$$

式中，Kin表示机器人正运动学公式。

3 案例分析

利用本文构建的检测数据集评估所提出的机器人轨迹生成网络性能。为量化网络性能，提出平均关节误差 (average joint error, AJE)、平均末端执行器位姿误差 (average end effector position error, AEEPE) 及轨迹生成时间 (generate time, GT) 作为评价指标。同时，使用 GraspNet、SGAN 网络模型，以及 ϵ 贪心前向树搜索算法 (ϵ -greedy forward tree search, FTS)、RRT算法作为基准方法进行对比验证。

3.1 案例分析

网络相关参数的设置方面，生成器与判别器均采用 Adam 优化器进行优化，初始学习率设置为 0.005，批处理设置为 16，迭代 200 轮。生成器中的编码器模块最终输出隐藏向量 H 的维度为 1024，注意力机制输出向量 A 维度同样为 1024，KNN 算法中 K 取 10，平衡因子 λ 设置为 0.9。

最终轨迹生成的定量化结果如表 1 所示。可以看出，本文方法 InsGAN 在关于准确性的两个指标 AJE 和 AEEPE 中，仅略低于 RRT 算法，两指标分别与 RRT 相差为 0.04 及 0.12。然而，为实现

机器人在线检测工艺规划的需求，轨迹规划时间至关重要，从 GT 一栏中可以看出，本文算法相较于 RRT 算法在规划时间上有大于 50% 的提升。当机器人始末点距离过大时，RRT 算法将出现明显的冗余问题，RRT 将机器人的轨迹离散化，每搜索一次可行路径都需要机器人逆运动学的求解，因此导致了规划时间的指数型增长。与传统算法相比，在不影响检测质量的前提下，本文方法可有效地提高规划效率，满足在线规划需求。

表 1 不同方法所生成的检测轨迹的定量结果
Tab.1 Quantitative results of inspection trajectories generated by different methods

评价指标	GraspNet	SGAN	FTS	RRT	InsGAN
AJE /°	0.54	0.89	1.32	0.39	0.43
AEEPE	1.18	1.78	2.50	0.82	0.94
GT/s	1.43	0.95	1.15	2.15	1.02

与目前主流轨迹在线规划方法相比，本文方法在两种准确性指标 AJE 和 AEEPE 中，均取得了最优结果，误差至多减少了 0.89 及 1.56，证明 InsGAN 框架的有效性。最后针对指标 GT，由于生成器中的各模块参数较多，对最终轨迹生成时间影响较大，导致轨迹规划时间升高了 0.07 s。与主流在线规划框架相比，InsGAN 在满足在线规划需求的前提下，提高了轨迹生成质量，满足了检测质量要求，该方法有效可行。

综上所述，本文所提出的机器人轨迹生成框架可以有效解决机器人在线检测轨迹规划中的规划质量低问题，并且在不影响检测质量的前提下，大幅提高规划时间。

为更直观地展示机器人轨迹规划结果，图 6 给出了针对不同位置处待检测的最终规划结果。

3.2 消融实验

针对机器人在线检测工艺规划问题，提出全新的基于 GAN 框架的机器人检测轨迹生成网络。首先通过编码-解码结构将点云空间映射到机器人关节空间内；其次引入点云几何结构及自注意力机制实现机器人与环境之间的交互；最后提出多样性损失函数，解决了 GAN 结构训练易崩溃等问题。采用消融实验对 InsGAN 网络模型中的各模块的效果进行评估。

表 2 给出了各模块针对机器人检测轨迹生成问题的效果，从表中可以看出，编码器模块在轨




图 6 位于不同位置下特征的检测轨迹生成结果

Fig.6 Generation results of inspection trajectory for features located in different locations

迹生成过程中起到了主要作用, 当失去编码器时, 两类误差 AJE 和 AEEPE 提升至 1.48 和 2.51。这也验证了编码器对于点云空间到关节空间映射的重要性。可以发现自注意力机制是影响轨迹生成速度的主要原因, 这不仅是由于自注意力机制增加了网络参数数量, 也由于在点云形状特征计算过程中需要大量的存储空间, 双重因素下, 拖慢了检测路径的整体运算效率。

表 3 给出了不同的池化方法对最终检测轨迹的影响, 选择最大池化层、平均池化层和共享 MLP 层 3 类用于对比。如表 3 所示, 最大池化层取得了最好的结果, 相比于其他两种方法, 两类误差相关的评价指标分别降低了 0.41 和 0.78, 这也验证了本文在构建 InsGAN 网络模型时的选择。

图 7 给出了不同平衡因子 λ 对 GAN 结构训练稳定性的提升。可以看出, 当 $\lambda=0$, 即只使用普通对抗损失函数时, 损失函数难以收敛, 当融合于多样性损失之后, 平均损失小于未应用多样性

表 2 各模块所生成机器人检测轨迹的效果

Tab.2 Results of the robot inspection trajectory generated by each module

评价指标	编码-解码模块	无编码器模块	InsGAN
AJE /°	0.95	1.48	0.43
AEEPE	1.82	2.51	0.94
GT/s	0.85	0.95	1.02

表 3 不同池化模块对生成轨迹的影响

Tab.3 Impact of different pooling modules on generated trajectories

评价指标	最大池化层	平均池化层	共享MLP层
AJE /°	0.43	0.72	0.84
AEEPE	0.94	1.44	1.72
GT/s	1.02	1.02	1.03

损失的网络模型, 并在大部分情况下趋于收敛, 这证明了本文所提出的多样性损失有效解决了




图 7 基于不同平衡因子的生成器损失曲线

Fig.7 Generator loss curves based on different balance factors

GAN 网络难以训练的问题。当 $\lambda = 0.9$ 时，网络损失在训练 20 轮后逐渐收敛，同时最终损失取得了最小值。

4 结 论

针对机器人在线检测轨迹规划问题，提出基于 ROS 仿真环境下的检测数据集制作方法。通过分析形状特征对机器人检测轨迹规划的影响，提出基于自注意力机制的点云形状信息提取方法。基于构建的生成对抗式网络框架，提出了基于待检测特征点云数据的机器人检测轨迹在线生成算法。针对机器人逆运动学求解非唯一问题，提出了多样性损失函数的逆运动学高效求解方法。最后，通过搭建的机器人轨迹规划案例，验证了所提方法的有效性与实时性。

参考文献:

[1] 唐永兴, 朱战霞, 张红文, 等. 机器人运动规划方法综述 [J]. 航空学报, 2023, 44(2): 026495.

[2] KAVRAKI L E, SVESTKA P, LATOMBE J C, et al. Probabilistic roadmaps for path planning in high-dimensional configuration spaces[J]. *IEEE Transactions on Robotics and Automation*, 1996, 12(4): 566–580.

[3] LAVALLE S M, KUFFNER J J. Randomized kinodynamic planning[C]/IEEE International Conference on Robotics and Automation. Detroit: IEEE, 1999: 473–479.

[4] 张振, 李新宇, 董昊臻, 等. 基于约束采样 RRT 的机械臂运动规划 [J]. 计算机集成制造系统, 2022, 28(6): 1616–1626.

[5] 王怀震, 高明, 王建华, 等. 基于改进 RRT^{*}-Connect 算法

的机械臂多场景运动规划 [J]. *农业机械学报*, 2022, 53(4): 432–440.

[6] 陈满意, 张桥, 张弓, 等. 多障碍环境下机械臂避障路径规划 [J]. 计算机集成制造系统, 2021, 27(4): 990–998.

[7] QURESHI A H, AYAZ Y. Intelligent bidirectional rapidly-exploring random trees for optimal motion planning in complex cluttered environments[J]. *Robotics and Autonomous Systems*, 2015, 68: 1–11.

[8] GAO W X, TANG Q, YAO J, et al. Automatic motion planning for complex welding problems by considering angular redundancy[J]. *Robotics and Computer-Integrated Manufacturing*, 2020, 62: 101862.

[9] FANG H S, WANG C X, GOU M H, et al. GraspNet-1billion: a large-scale benchmark for general object grasping[C]/2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 11441–11450.

[10] ZHAO C, ZHU Y F, DU Y C, et al. A novel direct trajectory planning approach based on generative adversarial networks and rapidly-exploring random tree[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(10): 17910–17921.

[11] SILVER D, HUANG A, MADDISON C J. et al. Mastering the game of go with deep neural networks and tree search[J]. *Nature*, 2016, 529(7587): 484–489.

[12] ZHU Y K, MOTTAGHI R, KOLVE E, et al. Target-driven visual navigation in indoor scenes using deep reinforcement learning[C]/2017 IEEE International Conference on Robotics and Automation (ICRA). Singapore: IEEE, 2017: 3357–3364.

[13] 周玮杰. 基于深度强化学习的室内服务机器人路径规划方法研究 [D]. 沈阳: 沈阳工业大学, 2022.

[14] QURESHI A H, SIMEONOV A, BENCY M J, et al. Motion planning networks[C]/2019 International Conference on Robotics and Automation (ICRA). Montreal: ACM, 2019: 2118–2124.

[15] HUH J, LEE D D. Efficient sampling with *Q*-learning to guide rapidly exploring random trees[J]. *IEEE Robotics and Automation Letters*, 2018, 3(4): 3868–3875.

[16] 杨雪娇. 点云的边界提取及角点检测算法研究 [D]. 哈尔滨: 哈尔滨工程大学, 2010.

[17] 沈露, 杨家志, 周国清, 等. 集自注意力与边卷积的点云分类分割模型 [J]. *计算机工程与应用*, 2023, 59(19): 106–113.

(编辑: 董 伟)