

面向智能驾驶的自适应多尺度三维点云配准网络

汪霖 韩栋 韩景怡 陈圣梅 刘成
(西北大学电子信息学院, 710127, 西安)

摘要: 针对智能驾驶场景中激光雷达点云稀疏、特征模糊以及低重叠引发关键点误匹配的问题, 提出了一种面向智能驾驶的自适应多尺度三维点云配准网络。首先, 该网络利用自适应多尺度特征提取模块获取采样点的多层级特征, 并结合自适应邻域稳定器实现关键点的精确定位, 从而解决由于特征模糊而导致的匹配难题。其次, 通过融合多尺度特征匹配一致性与几何一致性校验, 提升待配准点对的内点置信度。最后, 基于该置信度, 采用由粗到精的迭代优化策略, 完成三维点云的精确配准。KITTI数据集上的测试结果表明: 该网络的相对平移误差和相对旋转误差分别低至0.0618 m和0.21°, 配准召回率高达99.8%。nuScenes数据集上的测试结果表明: 在帧间距离分别为10、20、30 m下, 配准召回率分别达到90.1%、83.3%和78.8%。上述结果验证了该网络能够有效抑制复杂道路场景下的误匹配, 实现高精度、高鲁棒性的大规模三维点云配准。该研究适配了动态复杂路况下的实际应用需求, 为自动驾驶场景下的精准定位、环境感知提供可靠的技术支撑。

关键词: 智能驾驶; 三维点云配准; 自适应; 多尺度特征

中图分类号: TP29 **文献标志码:** AA

文章编号: 0253-987X(XXXX)XX-0001-17

Adaptive Multi-scale 3D Point Cloud Registration Network for Autonomous Driving

WANG Lin, HAN Dong, HAN Jinyi, CHEN Shengmei, LIU Cheng
(School of Electronic Information, Northwest University, Xi'an 710127, China)

Abstract: To address the problems of sparse LiDAR point clouds, ambiguous features, and mismatches of keypoints caused by low overlap in intelligent driving scenarios, this paper proposes an adaptive multi-scale 3D point cloud registration network for intelligent driving. First, the network employs an adaptive multi-scale feature extraction module to obtain multi-level features of sampled points, combined with an adaptive neighborhood stabilizer for precise keypoint localization, thereby resolving matching difficulties caused by feature ambiguity. Second, by integrating multi-scale feature matching consistency with geometric consistency verification, the inlier confidence of point pairs to be registered is improved. Finally, based on this confidence, a coarse-to-fine iterative optimization strategy is adopted to achieve accurate 3D point cloud registration. Test results on the KITTI dataset demonstrate that the

收稿日期: 2026-04-21。

network achieves a relative translation error as low as 0.0618 m and a relative rotation error as low as 0.21° , with a registration recall of up to 99.8%. Results on the nuScenes dataset indicate that with inter-frame distances of 10 m, 20 m, and 30 m, the registration recall reaches 90.1%, 83.3%, and 78.8%, respectively. These findings validate that the proposed network effectively suppresses mismatches in complex road scenarios, achieving high-precision and highly robust large-scale 3D point cloud registration. This research meets the practical application requirements of dynamic and complex traffic conditions, providing reliable technical support for precise localization and environmental perception in autonomous driving scenarios.

Keywords: intelligent driving; three-dimensional point cloud registration; adaptive; multi-scale features

自动驾驶技术的迭代升级,推动了汽车行业的智能化转型。智能驾驶感知体系融合了车载相机、毫米波雷达、超声波雷达及激光雷达等多类传感器,其中,视觉感知与超声感知分别在纹理识别、近距离测距方面具备优势,但易受极端光照、恶劣天气与探测距离的约束,环境适应性有限。激光雷达三维感知可输出高精度、高密度的显性三维几何结构信息,并凭借主动探测、不受光照干扰的特性,成为实现全天候、高鲁棒性智能驾驶感知的核心器件,同时也是多传感器融合架构中空间对齐的绝对基准。自动驾驶系统依托连续采集的激光雷达三维点云,构建时空一致的三维环境表征,核心关键在于将多帧点云统一至同一坐标系下,并完成精准对齐与融合,以保障三维环境重建的可靠性。三维点云配准不仅可实现连续点云扫描、扫描与局部地图间的相对位姿估计,更是多传感器外参标定、高精地图构建及即时定位与建图的前置基础,其配准精度直接决定多帧点云融合的空间一致性,进而影响三维重建与高精地图

的最终质量^[1-5]。因此,充分发挥激光雷达点云的几何优势,实现高精度、高鲁棒性的三维点云配准,是自动驾驶场景下高质量建图、多源传感器融合与精准稳定定位的核心前提^[6-8]。

然而,相较于室内与静态场景,真实道路环境下的三维点云配准存在诸多难点与挑战。车辆行驶引发的高速运动与视角剧变,会造成相邻帧点云重叠区域的不稳定,同时导致远距离点云稀疏、几何结构残缺。道路场景中,车辆、行人等动态交通参与者产生的非刚体点,易引发匹配偏差,显著限制了传统基于最近邻搜索或单尺度特征配准方法的鲁棒性与稳定性。此外,直线路段、护栏、隧道等场景中广泛存在的几何退化结构,进一步提升了复杂道路场景的点云配准难度^[9-12]。

近年来,基于传统迭代最近点(ICP)方法^[13]对初值敏感,极易出现关键点误匹配、收敛速度慢甚至不收敛的问题,难以满足自动驾驶实时、精准的配准需求。基于深度学习的三维点云配准方法通过学习判别性特征在一定程度

上提升了匹配精度。Wang等^[14]提出了基于深度最近点的三维点云配准方法,该方法通过深度特征提取、注意力匹配和可微的奇异值分解(SVD)求解刚体变换矩阵。为了减弱对初始位姿的依赖,Yew等^[15]提出了一种三维点云配准网络RPM-Net,该网络通过利用Sinkhorn层与退火策略学习软对应关系,提取空间坐标与局部几何的混合特征,削弱了传统最近邻匹配对初始位姿的敏感性。但该网络在具有大量离散点和复杂结构的配准中缺乏强有力的约束。为此,Fu等^[16]提出了RGM网络,将三维点云转换为图结构,通过增强自身点及其邻域特征的关系,提升在离群点干扰下,点对应关系的质量。为进一步增强高离群点条件下的配准稳定性,Bai等^[17]提出了PointDSC网络,通过引入深度空间一致性和可微谱匹配机制,对候选对应增强鲁棒筛选。随后,Yew等^[18]提出了REGTR网络,利用了Transformer的自注意力与交叉注意力机制可直接预测出高质量的对应关系,并且取得了无需最近邻与随机抽样一致算法后处理的突破。不过,REGTR对刚体不变的几何约束相对不足,因此后续研究逐渐开始将距离、角度等几何关系编码融进网络表示中。Qin等^[19]提出了GeoTransformer,通过将点对距离和三元组角度等几何关系引入Transformer框架,增强了特征表示的刚体变换不变性,但其模型的复杂度和计算代价较高。然而,以上方法往往依

赖固定尺度的特征表示,难以同时兼顾近距离密集区域与远距离稀疏区域的结构差异,以及在复杂自动驾驶场景中的实际应用效果。

综上所述,在自动驾驶场景中,现有方法因关键点特征模糊、误匹配频发而导致配准精度下降,无法满足自动驾驶实时感知与定位需求,为了解决上述问题,本文提出了一种面向智能驾驶的自适应多尺度三维点云配准网络(AMS-Net)。该网络通过自适应提取关键点多尺度特征,基于匹配一致性形成点对之间的可靠性约束。引入自适应邻域稳定器增强对关键点选择的稳定性。基于几何一致性校验实现对内点的精确提取,并采用置信度迭代进行精配准,有效缓解因特征模糊导致的误匹配问题,提高了配准精度,为自动驾驶场景下的精准定位、环境感知提供可靠的技术支撑,适配动态复杂路况下的实际应用需求。

1 AMS-Net网络结构

本文提出的面向智能驾驶的自适应多尺度三维点云配准网络整体模型结构如图1所示。该网络由自适应多尺度特征提取、匹配置信度校准以及刚体变换估计这3个核心模块协同作用,通过学习三维点云的多尺度特征,实现高效的外点滤除和精细准配准。具体而言,在特征提取阶段,设计了增强特征区分度的自适应多尺度特征提取模块,以分层特征抽样框架为基础,借助自适应邻域

稳定器（ANS）检测关键点，并提取其邻域显著特征，有效缓解复杂道路大

规模场景下，局部特征模糊与全局信息缺失的问题。




图1 AMS-Net整体模型结构

Fig. 1 Overall model structure of AMS-Net

F^1, F^2, F^3, F^4 —1级至4级下采样编码器提取的层级特征；FP-1~FP-3—特征传播模块； P^L, Q^L, F^L —低尺度下提取的源、目标点云及其特征； P^M, Q^M, F^M —中尺度下提取的源、目标点云及其特征； P^H, Q^H, F^H —高尺度下提取的源、目标点云及其特征； $w_1 \sim w_N$ —匹配点对的匹配置信度； K_s —粗配准阶段筛选的高置信度匹配点对数量。

在特征匹配阶段，构建了匹配置信度校准模块，以不同尺度特征下的匹配一致性为原则构建匹配点对，结合多尺度特征相似度与刚体变换不变的空间几何约束，实现对高置信度内点的加权筛选与异常匹配的有效排除。在刚体变换估计阶段，利用匹配点对的几何一致性约束和匹配置信度逐步精细化配准迭代过程，进而实现高精度三维点云配准。

1.1 自适应多尺度特征提取模块

给定源三维点云 $P = \{p_i\}_{i=1}^{N_p} \in \mathbb{R}^{N_p \times 3}$ 和目标三维点云 $Q = \{q_j\}_{j=1}^{N_q} \in \mathbb{R}^{N_q \times 3}$ ，其中， p_i, q_j 分别为源和目标三维点云中第 i 、第 j 个点， N_p, N_q 分别为源和目标三维点云的个数。以源三维点云和目标三维点云作为输入，AMS-Net 构建了一个自适应多尺度特征提取模块，精准提取并强化不同尺度下的特征信息。自适应多尺度特征提取模块结构如图2所示。

此模块基于 PointNet++^[20] 的层次化集合抽样（SA）思想，构建了经典的编码和解码对称结构。其中，特征编码器采用 ANS 精确采样点的特征信息，并将原始三维点云映射到高维特征空间，自适应地进行分层下采样。而多尺度解码器则基于 PointNet++ 的特征传播（FP）模块构建多尺度的特征提取的上采样分支。二者协同作用，为后续的三维点云配准提供了丰富的特征支持。

特征编码器采用4级级联的下采样模块扩大感受野，编码三维点云在不同尺度下的特征信息。随着网络深度的增加，采样点的感受野可随之持续扩大，不仅可以捕获三维点云的精细局部细节，还可以融合更加完整的全局信息。因此，AMS-Net 采用了4级级联的下采样模块构建该编码器，其中每一级均包含关键点采样、局部邻域聚合和特征提取的完整流程。一级下采样筛选初始关键点，以保留点云的主体结构，并生成

初始匹配候选点,后三级则基于初筛关键点,逐层构建多尺度邻域特征。与此同时,各层下采样均保留了层级特征与关键点坐标,以作为解码器的输入并用

于上采样及匹配一致性校验。经4层迭代下采样,网络感受野逐层扩张,从而充分挖掘点云深层结构特征。




图2 多尺度特征提取模块结构

Fig. 2 Structure of multi-scale feature extraction module

多尺度解码器通过自适应邻域半径反距离加权插值,同时采用并行分支结构将各级下采样子集恢复至原始点云规模。为了能输出关键点的多尺度特征,AMS-Net设置了3条解码支路分别对感受域半径为0.5~2.0 m的低尺度局部细节、邻域半径为2.0~6.0 m的中尺度结构信息、邻域半径为6.0~15.0 m的高尺度全局特征。以低、中、高这3个尺度的稀疏特征作为输入,输出多特征 F^L , F^M 和 F^H 。定义级联的特征传播模块FP(F^1, F^2)表达式为

$$FP(F^1, F^2) = \text{MLP}(\text{cat}(\text{Up}(F^2), F^1)) \quad (1)$$

式中: $\text{cat}(\cdot)$ 为特征拼接操作; $\text{Up}(\cdot)$ 为反距离加权插值上采样; $\text{MLP}(\cdot)$ 为多层感知机,在具体网络结构中,该操作由一系列级联的 1×1 一维卷积(Conv1D)、批归一化(Batch Normalization)和ReLU非线性激活函数实现。该映射

函数独立作用于每个采样点,旨在将拼接后的高维特征在通道维度上进行深度融合与自适应降维,从而提取更具判别力的局部上下文信息。

1.2 自适应邻域稳定器

特征编码器可通过分层下采样,完成点云多尺度特征提取,而下采样策略的稳定性直接影响关键点选取质量与最终配准性能。PointNet++所采用的最远点采样(FPS)具备良好的空间覆盖能力,能够保障采样点的分布离散性。然而, FPS对初始点的选取与局部点的分布较为敏感,在三维点云部分重叠、无效区域较多的复杂配准场景下,单一使用FPS选取关键点,易出现采样分布不均、有效对应点缺失等问题,增加了有效匹配点对的构建难度。

为了解决上述问题, AMS-Net在特征编码器的每层中都内置了一个自适

应邻域稳定器,如图3所示。在保留FPS空间均匀优势的基础上,引入自适应机制对局部邻域构建与特征提取过程

进行优化,以提高关键点选择的稳定性和配准鲁棒性。




图3 自适应邻域稳定器结构

Fig. 3 Structure of adaptive neighborhood stabilizer

SA-1~SA-4—四级分层下采样模块; $N_1 \sim N_4$ —各级下采样后点云的点数; $C_1 \sim C_4$ —各级特征通道数。

在特征提取网络中对输入三维点云进行4次下采样。其中,第 l 层的输入为上一层下采样得到的点集与其特征 $\{\mathbf{P}^{l-1}, \mathbf{F}^{l-1}\}$,具体定义为

$$\begin{cases} \mathbf{P}^{l-1} = \{\mathbf{p}_j^{l-1}\}_{j=1}^{N_{l-1}} \\ \mathbf{F}^{l-1} \in \mathbb{R}^{N_{l-1} \times C_{l-1}} \end{cases} \quad (2)$$

式中: $\mathbf{P}^{l-1}$ 表示点集; $\mathbf{F}^{l-1}$ 表示特征; c_{l-1} 为上一层点特征的维度; N_{l-1} 为上一层下采样后点的个数。 $\mathbf{p}_j^{l-1}$ 为 $l-1$ 级点集中的第 j 个点,用于参与当前层级的邻域构建与特征聚合。

首先,ANS使用FPS从 $\mathbf{P}^{l-1}$ 中选取 N_l 个代表点作为本层的中心点集合,利用基于特征的插值算子从上一层特征中获得中心点的邻域特征表达式为

$$\mathbf{g}_i^l = \text{Interp}(\mathbf{p}_i^l, \mathbf{P}^{l-1}, \mathbf{F}^{l-1}) \in \mathbb{R}^{C_{l-1}} \quad (3)$$

式中: $\mathbf{g}_i^l$ 为第 l 级第 i 个中心点的上下文特征向量; $\text{Interp}(\cdot)$ 为特征插值算子,用于从上层点云特征中插值计算当前中心点的邻域特征。

其次,通过尺度预测网络对点级邻

域半径进行回归。该网络由一个线性映射层与非线性激活函数组成,表达式为

$$\begin{cases} \tilde{\sigma}_i^l = \mathbf{a}^T \mathbf{g}_i^l + \beta \\ \sigma_i^l = \text{softplus}(\tilde{\sigma}_i^l) + \varepsilon \end{cases} \quad (4)$$

式中: $\tilde{\sigma}_i^l$ 为第 l 级中第 i 个中心点的初始邻域半径; $\mathbf{a}$ 和 β 分别为线性映射层的可学习权重向量与偏置; σ_i^l 为第 l 级中第 i 个中心点的最终自适应邻域半径; $\text{softplus}(\cdot)$ 为非线性激活函数; $\varepsilon > 0$ 为常数。

最后,通过上述方式,不同空间位置的点可根据其局部结构复杂度自适应选择感受野大小,这样可避免固定尺度在稀疏或密集区域下带来的特征退化问题。以点 $\mathbf{p}_i^l$ 为圆心、 σ_i^l 为半径,在上一层点集上构建尺度自适应邻域,表达式为

$$\zeta_i^l = \{\mathbf{p}_j^{l-1} \in \mathbf{P}^{l-1} \mid \|\mathbf{p}_j^{l-1} - \mathbf{p}_i^l\|_2 \leq \sigma_i^l\} \quad (5)$$

式中: ζ_i^l 为第 l 级中第 i 个中心点的自适应邻域点集合; $\|\cdot\|_2$ 为欧式范数。

为了实现对局部信息的高效编码,将提取到的邻域特征输入至专门设计的

特征描述器中,结构如图4所示。该描述器由3层MLP与最大池化层级联构成,负责输出重定位关键点的初步特征描述子。以重定位的采样点为中心,以

自适应的邻域半径重新构建每个关键的三维点云特征。最后,邻域特征被输入描述子网络生成采样点的描述子。




图4 特征描述器结构

Fig. 4 Structure of feature descriptors

综上所述,自适应多尺度特征提取模块通过学习每个采样点的局部结构复杂度,自适应回归邻域半径,实现对不同密度区域的特征调整。同时,结合自适应邻域稳定器,以确保关键点选择的稳定性,从而在多尺度特征下实现高质量特征的自适应提取。

1.3 基于几何一致性的置信度校准模块

经过自适应多尺度特征网络后,可获取到源三维点云与目标三维点云关键点在低、中、高3个尺度下的特征描述子。为了降低弱内点在特征匹配阶段被误删除的风险,AMS-Net不采用根据硬阈值匹配点对的传统方法,而是基于多尺度特征相似性构建软对应集合,并考虑几何约束,实现对匹配点的精确筛选。

在特征匹配的初始阶段,一般的多尺度网络往往在特征层将不同尺度直接拼接成一个单一的全尺度表示,并据此进行一次相似性计算,这种处理方式

对三维点云密度不均和复杂道路大规模场景极为敏感。因此,AMS-Net首先保留了各尺度独立的判别能力,并分别计算源三维点云与目标三维点云关键点在单一尺度下的相似度,表达式为

$$S_{ij}^r = \left\langle \frac{\mathbf{d}_i^p}{\|\mathbf{d}_i^p\|_2}, \frac{\mathbf{d}_j^o}{\|\mathbf{d}_j^o\|_2} \right\rangle \quad (6)$$

式中: $\mathbf{d}_i^p$ 、 $\mathbf{d}_j^o$ 为源点云与目标点云第*i*、*j*个关键点的特征描述子; S_{ij}^r 为单一尺度下源三维点云中的第*i*个关键点和目标三维点云的第*j*个关键点之间的特征相似度;上标*r*可取L、M、H,为低、中、高三个任意尺度。

为了在保留各尺度独立判别能力的同时,实现跨尺度信息的互补,基于正确匹配对在任意尺度下均应具备特征一致性的基本原理,将低、中、高3个尺度下的相似性矩阵 $\mathbf{S}^L$ 、 $\mathbf{S}^M$ 和 $\mathbf{S}^H$ 进行融合叠加,得到跨尺度综合相似性矩阵 $\mathbf{S}$ 。对于具体的匹配点对,其在矩阵 $\mathbf{S}$ 中对应的综合相似度 S_{ij} ,表达式为

$$S_{ij} = S_{ij}^L + S_{ij}^M + S_{ij}^H \quad (7)$$

式中: S_{ij}^L 、 S_{ij}^M 、 S_{ij}^H 分别为3个尺度下的相似性矩阵中的元素; $S_{ij} \in [0, 3]$ 为构建初始候选对应集合 $C_0 = \{(\mathbf{x}_i, \mathbf{y}_i^*) \mid i = 1, \dots, N\}$ 中的综合置信度。其中, N 为候选点对的个数, $\mathbf{x}_i$ 是源三维点云 P 中被筛选出来的关键点, $\mathbf{y}_i^*$ 是目标三维点云 Q 中与 $\mathbf{x}_i$ 相对应的候选匹配点。理想情况下, 真实匹配点对在多个尺度下均应表现出较高的特征相似度, 因此其综合置信度通常显著高于伪匹配点对。




图5 GCC机制模型结构

Fig. 5 Model structure of the GCC mechanism

由于刚体的变换不变性, 真实匹配点对在其邻域结构中应保持稳定的几何关系。因此, GCC通过比较候选匹配点对与其邻域点对之间的距离关系差异, 构建几何一致性度量, 并将其与多尺度特征相似度进行融合, 从而形成更加可靠的匹配置信度估计。为了提升匹配点对的置信度, AMS-Net基于候选匹配集合 C_0 为每个匹配点对构建局部邻域图结构, 该结构包含边长和角度两种几何描述。在此基础上, 依据真实匹配点对在刚体变换下应保持邻域内距离和角度的关系稳定性, 通过比较源三维点云与目标三维点云邻域结构差异, 计算几

何一致性度量, 并使用多层感知器融合特征, 从而实现匹配点对置信度的校准。因此, 在多尺度特征融合的基础上, 引入几何一致性校准 (GCC) 机制, 通过量化匹配对的邻域几何结构一致性, 对综合特征置信度进行修正, 形成语义相似和几何一致的双维度判别依据, GCC机制模型结构如图5所示。

何一致性度量, 并使用多层感知器融合特征, 从而实现匹配点对置信度的校准。

在候选集合 C_0 内, 对于第 i 个候选匹配点对 $(\mathbf{x}_i, \mathbf{y}_i^*)$, 分别在源点云与目标点云选取相同 K 个最近点, 以构建具有刚体变换不变性的局部几何约束。具体而言, 针对邻域 $N(\mathbf{x}_i)$ 和 $N(\mathbf{y}_i^*)$ 构造邻域图结构, 并由边 $\mathbf{e}_{i,k}^x$ 、 $\mathbf{e}_{i,k}^{y^*}$ 和角 $a_{i,r,s}^x$ 、 $a_{i,r,s}^{y^*}$ 两种几何表示, 表达式为

$$\mathbf{e}_{i,k}^x = \mathbf{x}_i - \mathbf{x}_k; a_{i,r,s}^x = \angle(\mathbf{e}_{i,r}^x, \mathbf{e}_{i,s}^x) \quad (8)$$

$$\mathbf{e}_{i,k}^{y^*} = \mathbf{y}_i^* - \mathbf{y}_k^*; a_{i,r,s}^{y^*} = \angle(\mathbf{e}_{i,r}^{y^*}, \mathbf{e}_{i,s}^{y^*}) \quad (9)$$

式中: $\mathbf{x}_k$ 和 $\mathbf{y}_k^*$ 分别为中心点 $\mathbf{x}_i$ 和 $\mathbf{y}_i^*$ 在其

局部邻域 $N(\mathbf{x}_i)$ 和 $N(\mathbf{y}_j^*)$ 的第 k 个邻近点, $i \neq k, k=1, \dots, K$; r, s 为邻域内近邻点的索引, $r, s \in \{1, \dots, K\}$ 。

在获取基础的几何结构表示后, 为了更敏锐地捕捉上、下文信息并放大真实匹配与伪匹配间的几何差异, 利用多层感知器 f_θ 进行特征融合, 表达式为

$$\Delta_{i,k} = f_\theta \left(\text{concat} \left(\mathbf{e}_{i,k}^x, \mathbf{a}_{r,s}^x \right) - f_\theta \left(\text{concat} \left(\mathbf{e}_{i,k}^y, \mathbf{a}_{r,s}^y \right) \right) \right) \quad (10)$$

$$\delta_{i,k} = \text{softmax}(f_\mu(\Delta_{i,k})) \quad (11)$$

式中: $\delta_{i,k}$ 为第 k 组邻域对应的几何一致性归一化权重; f_μ 为可学习单层线性映射层, 用于对几何差值做维度缩放; $\Delta_{i,k}$ 为第 k 组邻域的几何特征差值; $\text{concat}(\cdot)$ 为特征拼接操作; $\text{softmax}(\cdot)$ 为归一化指数激活函数。

在获得邻域几何结构表示后, 通过多层感知器对几何一致性特征进行融合。最终通过加权聚合邻域几何一致性信息, 得到候选匹配点对的内点置信度 w_i 表达式为

$$w_i = 1 - \text{Tanh} \left(\left\| \varphi \left(\sum_{k=1}^K \delta_{i,k} \Delta_{i,k} \right) \right\| \right) \quad (12)$$

式中: $\text{Tanh}(\cdot)$ 为双曲正切非线性激活函数, 用于将无界的几何结构差异平滑地压缩至 $[0,1]$ 区间内; $\varphi(\cdot)$ 是网络可学习的无偏置单层线性映射函数, 形式为 $\varphi(\mathbf{x}) = \mathbf{v}^T \mathbf{x}$, $\mathbf{v}$ 为权重向量, 该函数仅做维度变换, 将高维特征空间投影至一维标量空间。

由于输入的几何差值 $\Delta_{i,k}$ 是基于刚体变换不变的边与夹角特征计算得到

的, 因此当候选匹配点对 $(\mathbf{x}_i, \mathbf{y}_i^*)$ 为真实的内点时, 其局部几何结构呈现高度的一致性, 即 $\sum_{k=1}^K \delta_{i,k} \Delta_{i,k} \rightarrow 0$ 。此时, 无偏置线性映射输出标量 $\varphi(0)=0$, 从而得到理想的最高置信度 $w_i \rightarrow 1$ 。反之, 若匹配对为伪匹配时, 显著的几何邻域结构差异将导致特征描述子的偏离, 进而使得置信度 w_i 被抑制并趋近于 0。

1.4 刚体变换估计

在获得候选匹配点及其内点置信度之后, 采用由粗到精的配准策略, 以估计三维点云之间的刚体变换。传统由粗到精的配准方法仅通过两次独立变换估计不同, 与其不同的是, AMS-Net 在两个阶段均利用内点置信度进行加权优化, 从而使匹配权重能够随着配准状态逐步优化。

在配准时, 首先根据候选对应的内点置信度 w_i 对集合 C_0 中的候选匹配点降序排序, 选取置信度排名靠前的高质量点对构建子集

$$C_h = \{(\mathbf{x}_h, \mathbf{y}_h^*) \mid h \in \text{TopK}_{K_s}(w_i), i = 1, \dots, N\} \quad (13)$$

式中: C_h 为筛选得到的高置信匹配点对集合; N 为初始候选匹配集合 C_0 内匹配点对总数量; $\text{TopK}_{K_s}(\cdot)$ 为序列筛选算子, 用于提取置信度最高的前 K_s 组匹配点对。若第 i 组匹配点对被选中为子集 C_h 中的第 h 个关键点对, 则其对应的置信度权重同步映射为 w_h 。

基于该子集构建加权最小二乘优化

目标,通过加权奇异值分解SVD求解源三维点云与目标三维点云之间的初始刚体变换,表达式为

$$(\mathbf{R}, \mathbf{t}) = \arg \min_{\mathbf{R}, \mathbf{t}} \sum_{(\mathbf{x}_h, \mathbf{y}_h^*) \in C_i} w_h \|\mathbf{R}\mathbf{x}_h + \mathbf{t} - \mathbf{y}_h^*\|_2^2 \quad (14)$$

式中: $\mathbf{R}$ 、 $\mathbf{t}$ 分别为旋转矩阵和平移向量; w_h 为该匹配点对对应的内点置信度; $\mathbf{y}_h^*$ 为源关键点 $\mathbf{x}_h$ 对应的目标匹配点。

随后,利用该初始变换,对源三维点云的关键点进行精配准,在坐标空间中重新构建局部匹配关系,并结合更新后的几何一致性重新评估匹配点的置信度,从而获得更加可靠的匹配权重。通过这种置信度递进优化策略,使匹配点权重能够随配准状态不断优化,进一步提高最终配准精度。

1.5 损失函数

在网络的训练阶段,AMS-Net采用端到端的有监督学习方式,模型利用数据集提供的真实位姿(Ground Truth)判定候选匹配点对的真实归属,并以此构建损失函数。为了有效优化三维点云的配准精度,AMS-Net设计了一种综合考虑特征匹配一致性、几何一致性和外点剔除的损失函数。所有损失的计算均基于初筛出的候选匹配点对集合 C_0 。

特征匹配损失函数用于衡量源三维点云与目标三维点云在特征空间中的相似性。给定候选匹配点对 $(\mathbf{x}_i, \mathbf{y}_i^*)$, 其特征描述符分别为 $\mathbf{d}(\mathbf{x}_i)$ 和 $\mathbf{d}(\mathbf{y}_i^*)$, 特征匹配损失函数 L_{feature} 的表达式为

$$L_{\text{feature}} = \frac{1}{N} \sum_{i=1}^N I_i^{\text{gt}} \|\mathbf{d}(\mathbf{x}_i) - \mathbf{d}(\mathbf{y}_i^*)\|_2^2 \quad (15)$$

式中: N 为匹配点对的数量; $I_i^{\text{gt}} \in \{0, 1\}$ 为第 i 个匹配点对的真实监督标签,表示其是否为内点。

几何一致性损失函数的作用是保证匹配点对在刚体变换下的几何关系的一致性。对于候选匹配集合中的真实点对,其与各自局部邻域点之间应当保持稳定的相对欧氏距离。几何一致性损失函数 L_{geometry} 的表达式为

$$L_{\text{geometry}} = \frac{1}{N} \sum_{i=1}^N I_i^{\text{gt}} \|\mathbf{R}_{\text{gt}} \mathbf{x}_i + \mathbf{t}_{\text{gt}} - \mathbf{y}_i^*\|_2^2 \quad (16)$$

式中: $\mathbf{R}_{\text{gt}}$ 和 $\mathbf{t}_{\text{gt}}$ 分别为源点云与目标点云之间的真实旋转矩阵和平移向量。

外点剔除损失函数利用真实标签对网络预测的匹配置信度进行监督。通过迫使网络对真实内点输出高置信度、对外点输出低置信度,从而在后续优化过程中自适应降低外点权重,减少误匹配对最终配准结果的影响。外点剔除损失函数 L_{outlier} 采用二元交叉熵形式,表达式为

$$L_{\text{outlier}} = -\frac{1}{N} \sum_{i=1}^N [I_i^{\text{gt}} \ln(w_i) + (1 - I_i^{\text{gt}}) \ln(1 - w_i)] \quad (17)$$

式中: w_i 为网络预测输出的第 i 个候选匹配点对的内点置信度。

通过加权外点剔除损失函数,模型能够有效剔除误匹配点对,从而优化三维点云的配准结果。

最终,在总损失函数 L_{total} 中,为特

征匹配损失函数、几何一致性损失函数、外点剔除损失函数分别赋予权重系数 λ_1 、 λ_2 、 λ_3 , 表达式为

$$L_{\text{total}} = \lambda_1 L_{\text{feature}} + \lambda_2 L_{\text{geometry}} + \lambda_3 L_{\text{outlier}} \quad (18)$$

式中: 本文以特征匹配损失函数为优化基础, 将其权重 λ_1 设为1.0。为兼顾刚体变换约束与外点抑制效果, 通过KITTI数据集上的预实验与消融对比, 选取 $\lambda_2=0.5$ 、 $\lambda_3=0.2$ 。

2 实验结果及分析

2.1 实验环境与参数设置

本文实验所使用的深度学习框架为PyTorch 1.8.1, 运行环境为基于Python 3.8 和 Ubuntu 18.04 的系统, 并且配置CUDA 11.1。硬件方面, 采用12个虚拟CPU的Intel(R) Xeon(R) Silver 4214R@2.40GHz, 配备90 GB系统内存, 且使用单张NVIDIA RTX 3080 Ti显卡, 具有12 GB显存。在优化方面, 选择了Adam优化器, 并设置初始学习率为 1×10^{-4} , 批次量大小为2, 训练轮次设为50, 同时使用了 1×10^{-4} 的权重衰减。

实验所用的数据集采用KITTI^[21]数据集。使用序列0至5进行训练, 序列6至7进行验证, 序列8至10进行测试。在KITTI数据集上, 由于该数据集主要来源于真实道路环境中的车载激光雷达扫描, 三维点云具有尺度大、稀疏性强以及运动变化明显等特点, 因此, 本文采用的评价指标为平移误差(RTE)、旋转误差(RRE)和配准召回率

(RR)。为提高位姿标注精度, 真值位姿先通过ICP进行精化, 并仅保留帧间距离不小于10 m的样本对用于评估。

平移误差 R_{RET} 是用于衡量估计平移向量与真实平移向量之间的差异, 通常定义为两者欧氏距离, 表达式为

$$R_{\text{RTE}} = \|\hat{\mathbf{t}} - \mathbf{t}\|_2 \quad (19)$$

式中: $\hat{\mathbf{t}}$ 为估计平移向量, $\mathbf{t}$ 为真实平移向量。

相对旋转误差 R_{RRE} 则用于衡量估计旋转矩阵与真实旋转矩阵之间的偏差, 其表达式为

$$R_{\text{RRE}} = \arccos\left(\frac{\text{trace}(\hat{\mathbf{R}}^T \mathbf{R}) - 1}{2}\right) \quad (20)$$

式中: $\text{trace}(\cdot)$ 为矩阵迹运算; $\hat{\mathbf{R}}$ 为估计旋转矩阵, $\mathbf{R}$ 为真实旋转矩阵。

配准召回率 R_{RR} 定义为同时满足平移误差和旋转误差阈值约束的样本占全部测试样本的比例。假设测试集中共有 M 对三维点云, 平移误差阈值为 τ_t , 旋转误差阈值为 τ_r , 则 R_{RR} 表达式为

$$R_{\text{RR}} = \frac{1}{M} \sum_{i=1}^M 1(R_{\text{RTE}_i} < \tau_t, R_{\text{RRE}_i} < \tau_r) \quad (21)$$

式中: $1(\cdot)$ 为指示函数, 当括号内条件成立时取值为1, 否则取值为0; R_{RTE_i} 、 R_{RRE_i} 分别为第 i 组样本的相对平移误差与相对旋转误差。

2.2 消融实验及分析

为了验证AMS-Net模型中所引入模块的贡献, 在KITTI数据集上进行了AMS-Net的消融实验。实验结果如表1所示。本实验在原始的单一全局尺度模

型 (BM) 上进行粗配准, 依次融合自适应多尺度特征提取模块 (AMS)、自适应邻域稳定器 (ANS)、基于几何一致性的置信度校准模块 (GCC) 和基于置信度递进的精配准策略 (CPFR)。

由表1可知, 在BM的基础上, 随着AMS、ANS、GCC和CPFR模块的逐步引入, AMS-Net在KITTI数据集上的配准性能呈现出稳定且持续的提升。在特征模糊、几何信息较少的区域的情景中, 基线模型BM的 R_{RTE} 、 R_{RRE} 和 R_{RR} 分别为0.088 2 m、0.55°和89.4%, 这是由于单一尺度不足以提供充足的特征信息。当加入所提出的AMS多尺度结构后, 能够提供更具判别力的信息。而再加入ANS则使固定采样和固定邻域带来的局部结构退化问题得到缓解, 这也是 R_{RR} 提升最为明显的重要原因。随后, 进一步引入GCC, 错误匹配被更进一步抑制。而最后在加入CPFR后, 模型获得了最优结果, R_{RTE} 降至0.061 8 m, R_{RRE} 降至0.21°, R_{RR} 提升至99.8%。

表1 KITTI数据集的AMS-Net消融实验

Table 1 Ablation experiments of AMS-Net on the KITTI dataset

BM	AMS	ANS	GCC	CPFR	R_{RTE}/m	$R_{\text{RRE}}/(\text{°})$	$R_{\text{RR}}/\%$
是	否	否	否	否	0.088 2	0.55	89.4
是	是	否	否	否	0.073 4	0.42	91.8
是	是	是	否	否	0.070 7	0.36	96.4
是	是	是	是	否	0.068 4	0.28	98.3
是	是	是	是	是	0.061 8	0.21	99.8

为了进一步验证自适应多尺度特征提取模块中, 网络深度对最终点云配准性能的具体影响, 本文设计了针对网络层级的消融实验。在保持其他网络结构与配置完全一致的前提下, 实验分别测试了网络层级从1级逐步递增至4级时模型的表现变化。具体的量化评估指标如表2所示。

表2 网络层级对配准性能的影响

Table 2 The impact of network hierarchy on registration performance

网络层级	R_{RTE}/m	$R_{\text{RRE}}/(\text{°})$	$R_{\text{RR}}/\%$
1级	0.065 9	0.28	98.4
2级	0.063 2	0.24	99.4
3级	0.062 0	0.21	99.7
4级	0.061 8	0.21	99.8

由表2可知, 网络层级由1级增至4级时配准性能稳步提升。 R_{RTE} 由0.065 9 m降至0.061 8 m, R_{RRE} 由0.28°降至0.21°, R_{RR} 由98.4%提升至99.8%。1级提升至3级网络的指标改善幅度明显, 这说明通过增加网络层级提取多尺度特征, 能有效提升配准精度与匹配召回率。而3至4级的网络性能提升幅度趋于平缓, 原因在于下采样点数的持续减少, 可提取的三维点云特征趋于匮乏。综合权衡配准精度与模型复杂度, 4级网络取得最优实验性能, 从而验证了AMS-Net网络层级设计的有效性与合理性。

2.3 对比实验及分析

为了验证所提算法的有效性,

AMS-Net在大规模场景的KITTI数据上进行配准,并与CoFiNet^[22]、PREDATOR^[23]、PointDSC^[17]、GeoTransformer^[19]以及TurboReg^[24]多种经典及先进的方法进行对比。实验结果如表3所示。

表3 KITTI数据集的对比实验

Table 3 Comparative experiments of the KITTI dataset

方法	R_{RTE}/m	$R_{\text{RRE}}/(\text{^\circ})$	$R_{\text{RR}}/\%$
FCGF	0.095 4	0.25	96.6
CoFiNet	0.082 4	0.41	99.8
PREDATOR	0.068 7	0.27	99.8
PointDSC	0.083 5	0.38	98.2
GeoTransformer	0.062 0	0.23	99.8
TurboReg	0.079 1	0.39	98.6
FLAT	0.069 0	0.24	99.8
本文算法	0.061 8	0.21	99.8

由表3可知,AMS-Net方法的 R_{RTE} 为0.061 8m, R_{RRE} 为0.21°, R_{RR} 达到99.8%,综合指标最优。与等召回率同高的算法相比,本文方法的平移、旋转误差均更低,其余基线方法或位姿误差偏高,或召回率不足,仅依靠高匹配召回难以保证精准配准。这表明本文所设计的自适应多尺度特征架构可在维持高匹配召回率的同时,有效削减位姿估计偏差,兼顾匹配完备性与配准精度。

为进一步验证本文所提网络在真实车载场景的配准性能与泛化能力,本文将nuScenes^[25]数据集作为测试样本,对三维点云帧间隔分别为10、20和30 m的数据进行配准。该数据集采用32线激光雷达采集,传感器规格、路况场景

与原KITTI数据集存在明显差异,实验结果如

表4所示。相较于KITTI数据集的64线激光雷达,nuScenes数据集使用32线激光雷达采集数据,点云密度更低,且城市道路对模型的泛化能力提出了更高要求。实验结果表明:随着帧间跨度的增大,点云重叠率和密度急剧下降,导致所有基准算法的性能均出现不同程度的衰退。在10 m的距离下,本文方法的 R_{RTE} 为0.32 m、 R_{RRE} 为0.48°和 R_{RR} 为90.1%。在20 m的距离下,本文方法的 R_{RTE} 为0.48 m、 R_{RRE} 为0.75°和 R_{RR} 为83.3%。当跨度增加至30 m的极端稀疏场景时,依然保持了 R_{RR} 为78.8%的高配准率。本文方法在3种帧间距离下均取得了较优的配准效果,由此证明该模型能够有效适配不同规格的车载激光雷达数据,在异构三维点云场景下依然保持稳定的配准精度。

2.4 可视化对比及分析

为进一步直观展示在真实三维点云场景下的配准效果,给出不同算法在KITTI和nuScenes数据集上配准结果的细节差异。

图6为在KITTI数据集上的对比实验配准结果可视化,图中从上至下依次展示了3个不同路况场景下的配准效果。现有对比算法虽可初步恢复帧间点云空间的对应关系,但均存在如红色框标注的结构偏移与紫色框标注的局部错位问题。尤其在场景边缘、稀疏区域及

几何复杂区域,源三维点云与目标三维点云重合度较差,这表明现有方法在复杂干扰场景下仍存在显著误匹配缺陷。相比之下,针对三维点云分布不均、细长结构及低重叠比例等难点场景,本文方法仍可保持稳定的配准一致性,在多

组可视化样例中均展现出更优的配准效果,帧间点云重叠度更高,主体结构边缘对齐更规整,局部细节匹配精度更佳,有效验证了该方法在部分重叠点云配准任务中的有效性与优越性。

表4 nuScenes数据集的对比实验

Table 4 Comparative experiments on the nuScenes dataset

方法	10 m			20 m			30 m		
	R_{RTE}/m	$R_{\text{RRE}}/(^{\circ})$	$R_{\text{RR}}/\%$	R_{RTE}/m	$R_{\text{RRE}}/(^{\circ})$	$R_{\text{RR}}/\%$	R_{RTE}/m	$R_{\text{RRE}}/(^{\circ})$	$R_{\text{RR}}/\%$
FCGF	0.35	0.51	77.5	0.75	1.85	62.8	0.78	2.04	50.7
CoFiNet	0.49	0.84	57.3	0.64	1.04	53.0	0.60	1.68	66.2
PREDATOR	0.35	0.57	79.5	0.57	1.88	50.4	0.67	2.16	56.4
PointDSC	0.40	0.67	75.7	0.74	1.76	70.2	0.86	1.92	59.4
GeoTransformer	0.35	0.51	89.9	0.49	0.73	76.7	0.50	1.09	69.0
TurboReg	0.46	0.78	89.1	0.84	0.97	83.6	0.79	1.26	68.2
FLAT	0.47	0.94	80.3	0.57	1.69	66.5	0.76	1.88	58.4
本文算法	0.32	0.48	90.1	0.48	0.75	83.3	0.67	1.03	78.8

图7为在nuScenes数据集上的对比实验配准结果可视化,图中从上至下依次展示了帧间距离分别为10、20和30 m的条件下的配准效果。在间隔10 m的场景下,对比方法均存在紫色框标注的局部错位问题,但随着帧间距离的增大,对比方法出现了明显的对齐偏差,红色框标注的结构偏移问题显著增多。而本文算法在所有距离下均实现了源三维点云与目标三维点云的高度对齐,道路边缘、建筑轮廓等关键结构无明显偏差,从而验证了其配准精度与鲁棒性。

3 结论

本文面向自动驾驶激光雷达点云配准任务,针对复杂动态道路场景中三维

点云稀疏、特征模糊以及帧间重叠度低导致关键点误匹配的问题,提出了面向智能驾驶的自适应多尺度三维点云配准网络。该网络通过多尺度特征匹配一致性剔除外点,利用自适应多尺度特征提取与邻域稳定器降低特征模糊场景下的误匹配,通过融合特征与几何约束,双重筛选可靠内点,依据内点置信度由粗到精的迭代完成高精度配准。在KITTI数据集上,配准误差 R_{RTE} 为0.061 8 m, R_{RRE} 为0.21°, R_{RR} 为99.8%。在nuScenes数据集的跨大帧间距场景下,间隔10、20和30 m的 R_{RTE} 分别为0.32 m、0.48 m和0.67 m, R_{RRE} 分别为0.48°、0.75°和1.03°, R_{RR} 分别稳定至90.1%、83.3%和78.8%。实验结果证明,所提三维点云

配准网络 AMS-Net 能够有效挖掘点云多尺度特征并抑制帧间误匹配,在真实

车载异构点云环境中具备优异的配准精度与场景泛化鲁棒性。




图6 KITTI数据集上的配准结果对比

Fig. 6 Comparison of registration results on the KITTI dataset

结构偏移 局部错位 (a) CoFiNet (b) PREDATOR (c) PointDSC (d) GeoTransformer (e) TurboReg (f) 本文算法




图7 nuScenes数据集上的配准结果对比

Fig. 7 Comparison of registration results on the nuScenes dataset

结构偏移 局部错位 (a) CoFiNet (b) PREDATOR (c) PointDSC (d) GeoTransformer (e) TurboReg (f) 本文算法

参考文献

- [1] YU Z, ZHANG P, SHI J. Transformation of industrial robotics with natural language models: Recent progress and future prospects[J]. Robotics and Computer Integrated Manufacturing, 2026, 97: 103113-103151.
- [2] 周翔, 宋林烨, 夏海峰, 等. 个性化热舒适系统在电动汽车中的应用与展望[J]. 西安交通大学学报, 2026, 60(1): 1-13.
- ZHOU X, SONG L, XIA H, et al. Application and prospect of personalized thermal

- comfort system in electric vehicles[J]. Journal of Xi'an Jiaotong University, 2026, 60(1): 1-13.
- [3] SONG C H, BLUKIS V, TREMBLAY J, et al. Robospatial: Teaching spatial understanding to 2D and 3D vision-language models for robotics[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2025: 15768-15780.
- [4] WANG Z, SU Y, LI C, et al. Open-vocabulary octree-graph for 3D scene understanding[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2025: 7037-7047.
- [5] 马庆禄, 白锋, 张杰, 等. 基于激光雷达点云地图的车辆定位与导航[J]. 光学精密工程, 2024, 32(16): 2537-2549.
- MA Q, BAI F, ZHANG J, et al. Vehicle localization and navigation based on LiDAR point cloud map[J]. Optics and Precision Engineering, 2024, 32(16): 2537-2549.
- [6] MAKEN F A, KARMAKA M, PRABHU V, et al. Improving 3D reconstruction through RGB-D sensor uncertainty estimation and noise modeling[J]. Sensors, 2025, 25(3): 950-966.
- [7] TIAN Y, LI X, YIN J. From pseudo-to non-correspondences: robust point cloud registration via thickness-guided self-correction[J]. Computers & Graphics, 2026: 104521-104540.
- [8] MA K, YAN F, LI S, et al. Low-overlap registration of multi-source LiDAR point clouds in urban scenes through dual-stage feature pruning and progressive hierarchical methods[J]. Remote Sensing, 2025, 17(17): 2938-2955.
- [9] KASHEF TABRIZIAN S, TERRY S, VANDERBORGHT B. Toward autonomous self-healing in soft robotics: a review and perspective for future research[J]. Advanced Intelligent Systems, 2025, 7(8): 2400790-2400815.
- [10] 王丞, 田暄, 郭瑞, 等. 自适应Harris角点提取的点云粗配准算法[J]. 西安交通大学学报, 2022, 56(3): 33-44.
- WANG C, TIAN X, GUO R, et al. A coarse registration algorithm for point clouds based on adaptive Harris corner detection[J]. Journal of Xi'an Jiaotong University, 2022, 56(3): 33-44.
- [11] WANG W, MEI G, ZHANG J, et al. Fully-geometric cross-attention for point cloud registration[C]// 2025 International Conference on 3D Vision (3DV), IEEE, 2025: 347-356.
- [12] YAQI X, YAN X, et al. ASFM-Net: Asymmetrical siamese feature matching network for point completion[C]// Proceedings of the 29th ACM International Conference on Multimedia, 2021: 1938-1947.
- [13] BESL P J, MCKAY N D. A method for registration of 3-D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.
- [14] WANG Y, SOLOMON J M. Deep closest point: Learning representations for point cloud registration[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3523-3532.
- [15] YEW Z J, LEE G H. RPM-Net: Robust point matching using learned features[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11824-11833.
- [16] FU K, LIU S, LUO X, et al. Robust point cloud registration framework based on

- deep graph matching[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 8893-8902.
- [17] BAI X, LUO Z, ZHOU L, et al. PointDSC: Robust point cloud registration using deep spatial consistency[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 15859-15869.
- [18] YEW Z J, LEE G H. REGTR: end-to-end point cloud correspondences with transformers[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 6677-6686.
- [19] QIN Z, YU H, WANG C, et al. Geometric transformer for fast and robust point cloud registration[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11143-11152.
- [20] QI C R, YI L, SU H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space[J]. Advances in Neural Information Processing Systems, 2017: 30-39.
- [21] GEIGER A, LENZ P, URTASUN R. Are we ready for autonomous driving? the KITTI vision benchmark suite[C]// 2012 IEEE Conference on Computer Vision and Pattern Recognition, 2012: 3354-3361.
- [22] YU H, LI F, SALEH M, et al. CoFiNet: reliable coarse-to-fine correspondences for robust point cloud registration[J]. Advances in Neural Information Processing Systems, 2021, 34: 23872-23884.
- [23] HUANG S, GOJCIC Z, USVYATSOV M, et al. PREDATOR: registration of 3D point clouds with low overlap[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 4267-4276.
- [24] YAN S, SHI P, ZHAO Z, et al. TurboReg: turboclique for robust and efficient point cloud registration[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2025: 26371-26381.
- [25] CAESAR H, BANKITI V, et al. NuScenes: a multimodal dataset for autonomous driving[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11621-11631.