

文章编号 1004-924X(2026)08-1314-16

融合深度特征一致性与注意力网络的 点云配准方法

赵夫群^{1,2*}, 陈俊汐^{1,2}, 周明全³

- (1. 西安财经大学 信息学院, 陕西 西安 710100;
2. 智财协同可信计算陕西省高等学校重点实验室(西安财经大学), 陕西 西安 710100;
3. 西北大学 计算机学院(软件学院), 陕西 西安 710127)

摘要:针对传统点云配准算法在初始位姿误差、噪声干扰及局部结构重复等复杂条件下易陷入局部最优的问题,提出一种融合深度特征一致性约束与注意力网络的点云配准方法。该方法构建注意力增强的深度特征提取网络 AENet,通过自监督学习提取具有刚体变换不变性的点级描述符;在此基础上,首先利用深度特征相似性进行初始匹配并估计粗变换,进而在多尺度 ICP 迭代优化框架中引入深度特征一致性约束项,形成联合几何与特征相似性的优化目标,实现由粗至精的稳定对齐。在 ModelNet40 数据集上与现有主流方法进行对比的实验结果表明,所提方法在各项误差指标上均表现显著优势。具体而言,旋转均方根误差 RMSE-R 相较于 FINet, OGMM, IDAM-GNN, PREDATOR 和 RoCNet 分别降低了约 85.5%, 89.7%, 78.8%, 74.3% 和 61.6%;平移均方根误差 RMSE-t 分别降低了约 88.2%, 87.0%, 51.1%, 72.0% 和 18.2%。因此,该方法是一种能够有效提升配准精度与稳定性的点云配准方法。

关键词:点云配准;深度特征;注意力机制;迭代最近点;多尺度优化;自监督学习

中图分类号:TP391 文献标识码:A

doi:10.37188/OPE.20263408.1314 CSTR:32169.14.OPE.20263408.1314

Point cloud registration by fusing deep feature consistency with attention network

ZHAO Fuqun^{1,2*}, CHEN Junxi^{1,2}, ZHOU Mingquan³

- (1. School of Information, Xi'an University of Finance and Economics, Xi'an 710100, China;
2. Shaanxi Province Key Laboratory of Intelligent Finance Collaboration and
Trusted Computing (Xi'an University of Finance and Economics), Xi'an 710100, China;
3. School of Computer (School of Software), Northwest University, Xi'an 710127, China)

* Corresponding author, E-mail: fuqunzhao@126.com

Abstract: Traditional point cloud registration algorithms are often observed to converge to local optima. This occurs when initial pose errors, noise, and repeated structures exist. To address this issue, a registration method was proposed to integrate deep feature consistency constraints with an attention mechanism. An attention-enhanced deep feature extraction network (AENet) was constructed. It was trained via self-

收稿日期:2026-01-23;修订日期:2026-03-03.

基金项目:国家自然科学基金(No. 62271393);陕西省教育厅科学研究计划项目(No. 25JS049)

supervised learning to generate point-wise descriptors invariant to rigid transformations. Using these descriptors, initial correspondences were established. A coarse transformation was then estimated, providing a reliable initialization for subsequent refinement. A deep feature consistency term was embedded into a multi-scale iterative closest point (ICP) optimization framework. It formed a joint objective that unified geometric alignment and deep feature matching for coarse-to-fine registration. By incorporating the feature similarity constraint into geometric optimization, a unified model was established. This model jointly enforced geometric proximity and deep feature consistency throughout the registration process. Refinement was performed progressively. It proceeded through coarse, intermediate, and fine scales. This improved convergence stability and reduced sensitivity to challenging conditions such as large pose variations and structural ambiguities. Extensive experiments are conducted on the ModelNet40 dataset. Results demonstrate significant improvements across multiple error metrics. Specifically, the root mean square error of rotation (RMSE R) is reduced by approximately 85.5%, 89.7%, 78.8%, 74.3% and 61.6% compared to FINet, OGMM, IDAM GNN, PREDATOR and RoCNet respectively. Similarly, the root mean square error of translation (RMSE t) is lowered by about 88.2%, 87.0%, 51.1%, 72.0% and 18.2%. These results indicate that the proposed framework effectively improves both accuracy and robustness. It provides a practical solution for high-precision point cloud alignment. The method performs well under complex environments and structural ambiguities.

Key words: point cloud registration; deep feature; attention mechanism; iterative closest point (ICP); multi-scale optimization; self-supervised learning

1 引言

在三维点云配准任务中,如何在存在初始位姿误差、噪声干扰以及局部结构重复等复杂条件下实现稳定而高精度的对齐,一直是三维视觉领域中的核心问题。传统方法通过增强对复杂场景的几何与统计描述能力来提升鲁棒性,在小位姿偏差和高重叠率的理想场景中表现良好。例如,胡冰楠等^[1]提出的INDT算法通过融合雷达硬件参数对点云进行不确定度建模,并结合自速度估计显著抑制了SLAM中的轨迹漂移;殷果等^[2]设计的两阶段加权ICP框架通过融合多几何特征有效降低了结构化场景中的误匹配率;李泉凯等^[3]提出的CUBE-ICP算法引入概率化不确定度建模与正则化约束,提升了动态复杂环境下的配准稳健性;张伟等^[4]则针对低重叠率点云提出自适应采样与特征融合描述符,实现了高精度粗配准;聂吉祥等^[5]通过流形聚类与曲率采样解决了密度不均匀点云的配准问题;王鑫森等^[6]采用SLFD特征差异匹配,增强了ICP对噪声与缺失的鲁棒性;李茂月等^[7]结合逐点前进法与双向

Kd-tree优化,实现了高效稳定的配准。然而,这类方法本质上依赖几何距离进行最近邻搜索与优化,对初始位姿高度敏感,且在结构相似、噪声明显或部分重叠的复杂场景中容易陷入局部最优。

随着深度学习在三维视觉中的快速发展,基于深度学习的点云配准方法取得了显著进展,进一步探索了深度特征的结构化建模与迭代优化机制。例如,Xie等^[8]提出的IFNet通过反馈机制实现高层信息对低层特征的持续增强;汤洁等^[9]提出的CGENet通过邻域几何质心编码与质心感知特征提取模块,增强了局部结构建模能力,在低重叠率点云配准中表现优异;陈睿星等^[10]提出的RPMNet++融合Copula去噪模块与双向注意力机制,在抑制噪声干扰的同时强化了局部细粒度特征学习;易见兵等^[11]通过特征交互与匹配增强模块提升对异常点和部分重叠的鲁棒性;岳倩雯等^[12]利用多维聚焦与自适应优化机制应对低重叠与高离群值场景;Xu等^[13]提出的FINet通过多级特征交互实现源与目标点云间的信息交换;Slimani等^[14]提

出的 RoCNet 结合图卷积与注意力机制来编码局部几何与法线变化;Mei 等^[15]提出的 OGMM 引入重叠引导的高斯混合模型,通过聚类注意力检测重叠区域;Li 等^[16]提出的 IDAM-GNN 融合几何与距离特征,并采用两级点消除策略;Huang 等^[17]提出的 PREDATOR 则专注于低重叠场景,通过重叠注意力预测点级重叠与匹配性分数。这类方法具有强大的全局特征学习与匹配能力,有效克服了传统方法对初始位姿的依赖,并在噪声、低重叠等复杂场景下表现出良好的鲁棒性。然而,现有端到端方法往往将配准建模为单次前向回归过程,在优化过程中缺乏显式的几何一致性约束与多步迭代细化能力,限制了其在极端噪声、严重遮挡等挑战性场景下的稳定性和精度。

近年来,一些研究尝试将深度特征与传统优化框架结合。例如,Fu 等^[18]提出的 RGM 框架通过深度图匹配获取更鲁棒的对应关系,但其在利用 SVD 求解最终变换时,深度特征仅作为生成匹配权重的静态输入,未在求解过程中转化为可优化的语义一致性约束;陆军等^[19]通过特征融合与网络采样增强关键点描述符,并采用加权 SVD 完成配准,然而其加权过程同样基于静态特征相似度,缺乏在迭代优化中对特征一致性的显式闭环监督。

针对上述问题,本文提出一种融合深度特征一致性约束与注意力网络的点云配准方法。该

方法通过构建注意力增强的深度特征提取网络 AENet,从原始点云中学习具有判别性的点级描述子,并在多尺度 ICP 优化过程中引入深度特征一致性项,使几何对齐与语义一致性协同优化,从而有效提升算法在复杂场景下的收敛稳定性与配准精度。与 PointNet++ 和 DGCNN 等以分类或分割为目标的网络相比,所提方法不依赖语义监督,而是通过自监督约束显式增强点级特征在刚体变换下的一致性。AENet 网络在特征通道维度引入轻量级注意力重标定机制,并将生成的深度特征持续嵌入多尺度 ICP 优化过程中,实现特征学习与几何优化的协同配准。

2 配准方法

2.1 基于注意力增强的深度特征提取网络 AENet

2.1.1 网络整体架构

为从原始点云数据中学习稳定且具有判别性的点级特征,本文提出了一种注意力增强的深度特征提取网络 AENet。该网络以无序点集为输入,通过多层特征编码、全局特征聚合以及局部与全局特征融合等模块,生成对刚体变换具有不变性的点级深度特征描述子。网络整体结构在保证置换不变性的前提下,实现了局部几何信息与整体结构信息的联合建模。AENet 的整体网络结构如图 1 所示。




图 1 AENet 网络整体架构

Fig. 1 Overall architecture of AENet

在网络结构设计上, AENet以 PointNet 与 PointNet++ 的点集特征学习方法为基础, 通过共享权重的多层感知机对每个点进行独立的非线性映射^[20-22]。由于各点在特征编码阶段共享同一组网络参数, 该过程满足点云数据的置换不变性要求; 同时, 网络在特征融合阶段采用对称函数对点集特征进行汇聚, 使整体特征表示不依赖于输入点的排列顺序。不同于仅依赖单一全局池化获取整体特征的传统方法, AENet在特征编码与中高层特征表示阶段引入多层特征融合机制, 通过将局部点级特征与全局特征向量进行融合, 使每个点的最终特征描述子同时编码局部几何信息与全局结构信息, 从而在面对大尺度结构变化或点云密度变化时保持较为稳定的特征表达能力。

设从点云训练数据集中采样的单个点云样本为 $P = \{p_i \in \mathbb{R}^3 | i = 1, 2, \dots, N\}$, 其中 p_i 表示第 i 个点的三维空间坐标, N 为点云中点的数量。AENet的目标是为输入点云中的每个点学习一个高维特征向量, 从而构成点级深度特征集合 $F = \{f_i \in \mathbb{R}^d | i = 1, 2, \dots, N\}$, 其中 f_i 为与点 p_i 对应的深度特征描述子, d 表示特征维度。

在点级特征编码阶段, 网络通过残差块与通道注意力模块实现多尺度映射与全局聚合, 构建了从局部到全局的逐点特征表示。具体定义如下:

(1) 中间特征 h_i : 网络采用由残差块与通道注意力模块构成的编码器, 对每个点的三维坐标进行独立的非线性映射, 定义该映射函数为 $\phi(\cdot)$, 则点 p_i 经映射后得到的中间特征 h_i 可表示为:

$$h_i = \phi(p_i), \quad (1)$$

其中: $h_i \in \mathbb{R}^{d_1}$, d_1 为中间特征维度。

由于所有点共享同一映射函数, 该过程对输入点的排列顺序不敏感, 从结构上保证了网络的置换不变性。

(2) 全局特征 g : 网络通过对称的全局池化操作对点级中间特征 h_i 进行聚合, 以提取描述点云整体几何结构的全局特征向量 g , 定义全局特征向量 g 为:

$$g = \text{Pool}(\{h_i\}_{i=1}^N), \quad (2)$$

其中: $\text{Pool}(\cdot)$ 表示全局最大池化函数, $g \in \mathbb{R}^{d_2}$ 为全局特征向量, d_2 为全局特征维度。

(3) 融合后的点级特征 f_i : 在特征融合阶段, 网络将全局特征向量 g 回传并与各点对应的中间特征 h_i 进行融合, 生成融合后的点级深度特征 $f_i \in \mathbb{R}^d$, 其定义为:

$$f_i = \psi([h_i, g]), \quad (3)$$

其中: $[\cdot, \cdot]$ 表示特征拼接操作, $\psi(\cdot)$ 为后续特征映射函数。

通过该融合过程, 输出的点级特征 f_i 在保留局部几何信息的同时引入了整体结构约束。

2.1.2 注意力机制与残差设计

在编码器的每个残差块后, 不同特征分量在描述几何结构时的判别性存在显著差异。AENet网络引入通道注意力机制对特征进行自适应重标定。

与通用通道注意力模块不同, AENet网络的注意力模块仅作用于特征通道维度, 不对点间关系建模, 从而降低计算复杂度并保持输入点排列的置换不变性。注意力权重由残差块输出的局部特征通过共享 MLP 生成, 并直接嵌入残差结构用于点级特征更新。该设计不仅实现通道级特征选择, 同时保持梯度传播稳定, 为后续局部与全局特征融合提供更具判别性的基础表征。

设当前残差块输出的局部特征为 $f \in \mathbb{R}^{d_0}$, d_0 为当前阶段特征维度。注意力加权过程定义为:

$$\tilde{f} = \alpha_i \oplus f, \quad (4)$$

其中: $\tilde{f}$ 是增强后的特征, α_i 表示由网络自适应学习得到的注意力权重向量, 其定义与式(5)一致, $\oplus$ 表示逐元素乘法运算。

注意力加权的权重分布过程如图2所示。图2中, 红色区域表示高权重, 蓝色区域表示低权重(彩图见期刊电子版)。注意力权重主要集中于边缘、角点及曲率变化处等几何结构显著的区域, 而平滑区域及噪声点则被赋予较低权重。这表明注意力模块能够自适应地聚焦于几何判别性强的局部结构, 从而生成更具鲁棒性的点级特征表示。

注意力模块计算得到的权重向量 α_i 作用于




图2 注意力权重分布图

Fig. 2 Attention weight distribution map

特征 f_i 。对于反映点云关键几何结构的特征分量,模型赋予其较高的权值。这使得在特征空间中,具有显著辨识度的几何元素被放大,增强了特征在配准任务中的描述力。

具体实现中,注意力权重向量 α_i 由一个轻量的多层感知机模块计算得出。首先,残差块输出的局部特征 f 经过一个由两个全连接层、批归一化和 ReLU 激活函数构成的多层感知机进行变换;随后,通过 Sigmoid 激活函数将输出映射为 $(0, 1)$ 区间内的权重,其计算式定义为:

$$\alpha_i = \sigma \left(\text{MLP}_2 \left(\delta \left(\text{BN} \left(\text{MLP}_1(f) \right) \right) \right) \right), \quad (5)$$

其中: MLP_1 和 MLP_2 为两个全连接层,BN表示批归一化操作, δ 为 ReLU 激活函数, σ 表示 Sigmoid 激活函数。

经过注意力增强与残差融合后的点级特征 $\tilde{f}$ 将作为下一个残差块的输入或经过压缩后用于全局特征提取。

2.1.3 自监督训练与损失函数

为在无需人工标注点级对应关系的情况下训练网络,AENet采用自监督学习策略,通过联合重建任务与特征判别任务,引导网络学习对刚体变换具有不变性的点级特征表示。网络以自编码器形式构建,通过编码器提取点级特征,经解码器重建原始点云,同时利用对比学习增强特征的判别能力。

重建任务采用改进的 Chamfer 距离^[23]作为损

失函数,以约束重建点云与原始点云在空间分布上的一致性,该点级特征一致性损失项 $\mathcal{L}_{\text{recon}}$ 定义为:

$$\mathcal{L}_{\text{recon}} = \frac{1}{N} \sum_{i=1}^N \min_j \|p_i - \hat{p}_j\|_2^2 + \frac{1}{N} \sum_{j=1}^N \min_i \|\hat{p}_j - \hat{p}_i\|_2^2, \quad (6)$$

其中: p_i 表示原始点云中的点坐标, $\hat{p}_j$ 表示重建点云中的对应点坐标, N 为点云点数。

特征判别任务采用一种增强的对比损失^[24],旨在最大化正样本对之间的特征相似性,同时最小化负样本对之间的相似性,从而提升特征的判别能力。该特征分离约束项 $\mathcal{L}_{\text{cont}}$ 定义为:

$$\mathcal{L}_{\text{cont}} = -\frac{1}{B} \sum_{i=1}^B \log \frac{\exp(\text{sim}(z_i, z_i^+)/\tau)}{\sum_{j \neq i} \exp(\text{sim}(z_i, z_j)/\tau)}, \quad (7)$$

其中: z_i 表示第 i 个样本通过全局最大池化得到的全局特征, z_i^+ 表示其正样本特征,即来自同一物体的不同增强版本, $\text{sim}(\bullet)$ 表示余弦相似度, τ 为温度参数, B 为批次大小。

网络训练采用联合优化策略,总体目标函数 $\mathcal{L}$ 定义为:

$$\mathcal{L} = \mathcal{L}_{\text{recon}} + \lambda \mathcal{L}_{\text{cont}}, \quad (8)$$

其中: $\mathcal{L}_{\text{recon}}$ 表示点级特征一致性损失项, $\mathcal{L}_{\text{cont}}$ 表示特征分离约束项, λ 为动态调整的权重系数,随训练轮次从0.3线性衰减至0.1,以平衡重建精度与特征判别性的优化需求。

经过注意力增强与自监督训练后,AENet最

终输出的点级深度特征集合 $F^* = \{f_i^* \in \mathbb{R}^d | i = 1, 2, \dots, N\}$, 其中 f_i^* 表示与点 p_i 对应的最终深度特征描述子。该特征集合在训练过程中通过重建约束与对比约束, 使特征对刚体变换保持不变并具备较强的几何判别能力。

2.2 深度特征一致性约束配准

本文提出的 AENet 网络能够从输入点云中学习到稳定且判别性强的点级深度特征。这些特征不仅保留了点云局部几何结构信息, 同时编码了全局上下文约束, 对刚体变换具有相对不变性, 为跨点云匹配提供可靠依据。在此基础上, 本文提出了一种融合深度特征一致性约束的点云配准方法, 用于精确估计源点云 P_s 与目标点云 P_t 之间的刚体变换。

定义源点云为 $P_s = \{p_i^s | i = 1, 2, \dots, N_s\}$, 目标点云为 $P_t = \{p_j^t | j = 1, 2, \dots, N_t\}$, 其中 $p_i^s \in \mathbb{R}^3$ 和 $p_j^t \in \mathbb{R}^3$ 分别表示源点云 P_s 与目标点云 P_t 中的三维点坐标, N_s 和 N_t 为对应点云的点数。

由 AENet 网络分别作用于源点云 P_s 与目标点云 P_t 后, 其输出的点级深度特征集合分别为 $F_s^* = \{f_i^s \in \mathbb{R}^d | i = 1, 2, \dots, N_s\}$ 和 $F_t^* = \{f_j^t \in \mathbb{R}^d | j = 1, 2, \dots, N_t\}$, 其中 f_i^s 与 f_j^t 分别表示点 p_i^s 与 p_j^t 的 AENet 网络深度特征描述子。

2.2.1 基于深度特征的初始匹配

在获得 AENet 网络提取的点级深度特征后, 首先需要在特征空间中建立源点云与目标点云的初始对应关系, 该匹配为后续配准提供稳定的起始条件, 其核心是基于特征相似度的最近邻匹配。具体步骤如下:

步骤 1: 对于任意一对源点与目标点, 定义其特征空间中的欧氏距离 d_{ij} 作为相似性度量, 其计算式为:

$$d_{ij} = \|f_i^s - f_j^t\|, \quad (9)$$

其中: $\|\cdot\|$ 表示欧氏范数。该欧氏距离 d_{ij} 越小, 表示两点在局部几何结构及整体上下文语义上越为相近。

基于该度量, 为每个源点 p_i^s 在目标特征集合 F_t^* 中搜索最近邻, 得到初始匹配点对 (p_i^s, p_j^t) , 所有匹配点对构成初始匹配集合 $C_{\text{init}} = \{(p_i^s, p_j^t)\}$ 。

该相似性度量的有效性得益于 AENet 特征的刚体变换不变性, 使得基于最近邻的搜索能够跨越空间位姿偏差, 直接捕获点与点之间的内在结构对应关系, 从而在源点云与目标点云存在大位姿差异时仍能保持匹配稳定性。

步骤 2: 初始匹配集合 C_{init} 仅依赖深度特征的相似性, 未引入显式的几何一致性约束, 为提高可靠性, 采用 RANSAC 算法对 C_{init} 进行几何校验, 剔除异常匹配点, 得到内点匹配集合 C_{inlier} , 计算初始刚体变换 T_{init} 为:

$$T_{\text{init}} = \arg \min_{R, t} \sum_{(p_i^s, p_j^t) \in C_{\text{inlier}}} \|Rp_i^s + t - p_j^t\|^2, \quad (10)$$

其中: $R \in SO(3)$ 为旋转矩阵, $t \in \mathbb{R}^3$ 为平移向量。

通过这种方式, 初始匹配阶段为后续的精细几何对齐提供了稳定的起始条件, 同时在大姿态差异下减少了错误匹配对位姿估计的负面影响。

2.2.2 多尺度 ICP 迭代优化

在获得初始匹配集合 $C_{\text{init}} = \{(p_i^s, p_j^t)\}$ 及初始刚体变换 T_{init} 后, 为进一步提升点云配准精度, 本文采用多尺度迭代优化策略对源点云进行几何对齐。该策略通过在不同分辨率下逐步更新刚体变换参数, 使点云由整体结构对齐逐渐过渡到局部几何精细对齐, 从而在保持全局一致性的同时有效减少局部残差, 提高配准的收敛稳定性与精度。

设第 k 次迭代中源点云的刚体变换 $T^{(k)}$ 为:

$$T^{(k)}(p_i^s) = R^{(k)}p_i^s + t^{(k)}, \quad (11)$$

其中: $R^{(k)} \in SO(3)$ 为旋转矩阵, $t^{(k)} \in \mathbb{R}^3$ 为平移向量。

对于每一对匹配点 $(p_i^s, p_j^t) \in C_{\text{init}}$, 其几何残差 e_{geo} 可表示为:

$$e_{\text{geo}} = \|R^{(k)}p_i^s + t^{(k)} - p_j^t\|. \quad (12)$$

为了更精细地刻画局部几何误差, 并充分利用目标点云的表面信息, 本文进一步采用点到平面的残差形式。具体而言, 将上述几何残差向量 r_{geo} 投影到目标点 p_j^t 的单位法向量 n_j^t 方向上, 得到标量投影距离作为新的残差度量 r_{geo} , 其定义为:

$$r_{\text{geo}} = ((R^{(k)}p_i^s + t^{(k)} - p_j^t) \cdot n_j^t)^2. \quad (13)$$

该投影能够更准确地反映点对之间在法向量方向上的几何差异,从而对局部表面特征提供更敏感的约束。

多尺度迭代优化流程主要包括以下三个阶段:

(1)粗尺度对齐:对源点云进行稀疏下采样,优先调整全局结构,实现源点云与目标点云的大尺度旋转和平移对齐。此阶段主要消除初始位姿差异对局部优化的影响,为后续迭代提供稳定的初始条件。

(2)中尺度对齐:逐步增加点云的采样密度,通过更细的点点残差优化局部几何结构,精确对齐平面、曲面及特征边界,提高点对匹配精度。此阶段能够有效处理局部形状相似但全局位置偏差的情况。

(3)细尺度对齐:在完整点云上进行微调迭代,将残差最小化至全局和局部误差均收敛。该阶段进一步提升配准精度,确保对复杂曲面、尖锐边缘以及局部细节的充分捕捉。

通过这种由粗到细的逐层优化策略,算法能够兼顾全局一致性和局部精度,有效避免陷入局部最优,尤其在复杂场景和噪声干扰条件下表现出良好的收敛性。

2.2.3 深度特征一致性约束 DFC

尽管多尺度几何对齐能够在一定程度上缓解初始误差,但在结构对称或局部重复的区域,仅依赖几何残差仍可能保留错误匹配,从而影响刚体变换估计。为此,本文在迭代优化过程中引入深度特征一致性约束,将点点深度特征信息作为额外约束融入联合优化目标。

对于匹配点对 (p_i^s, p_j^t) , 其深度特征一致性残差 r_{feat} 定义为:

$$r_{\text{feat}} = \|f_i^s - f_j^t\|. \quad (14)$$

该残差衡量匹配点在深度特征空间的相似性,与几何残差互为补充。结合几何残差与特征残差,构建联合优化目标函数 $\mathcal{L}^*$ 为:

$$\mathcal{L}^* = \frac{w_{\text{geo}}}{N} \sum_{i=1}^N r_{\text{geo}} + \frac{w_{\text{feat}}}{N} \sum_{i=1}^N r_{\text{feat}}, \quad (15)$$

其中: N 为匹配点对数量, w_{geo} 与 w_{feat} 分别为几何和特征残差权重。旋转矩阵通过李代数参数化,

优化使用高斯-牛顿迭代最小化联合损失。

该约束能够有效抑制几何空间接近但特征差异显著的错误匹配,同时在结构对称或局部重复区域增强匹配判别能力。此外,在噪声、点云稀疏或密度变化情况下,特征一致性提供了额外信息维度,提高迭代优化收敛稳定性。优化输出最终刚体变换 T^* 及对应匹配点集合 C^* , 其中每个匹配点在几何和特征空间均保持一致性。

3 实验结果与分析

3.1 数据集

为全面评估所提出方法在点云配准任务中的性能,本文在 ModelNet40 上数据集进行了系统性实验。ModelNet40 包含 40 个不同类别的 12 311 个高质量 CAD 模型,是三维点云配准领域广泛使用的基准数据集。实验采用标准数据划分方案,其中训练集包含 9 843 个样本,测试集包含 2 468 个样本。对于每个点云样本,通过最远点采样统一采样至 1 024 个点,并进行坐标归一化处理以消除尺度差异。

3.2 实验设置

所有实验均在配置单个 NVIDIA RTX 2080Ti GPU 的设备上使用 PyTorch 框架实现。采用 ModelNet40 多类别点云数据集,输入点数为 1 024。训练使用 AdamW 优化器,初始学习率设为 1×10^{-3} ,权重衰减为 1×10^{-4} ,并结合 OneCycleLR 调度器在训练周期内动态调整学习率。训练轮次为 100,批量大小为 8。

数据增强包括随机旋转、平移、缩放及高斯噪声,预处理阶段通过离群点剪枝和最远点采样确保点云均匀性。损失函数采用改进的 Chamfer 距离与增强对比损失的联合训练策略,对比损失权重由 0.3 线性衰减至 0.1,以平衡重建精度与特征判别能力。

模型以点云三维坐标作为输入,通过 AENet 提取深度特征。编码器输出特征维度为 128,融合后的全局特征维度为 512。表 1 给出了本文所提出深度特征提取模型的详细设置。

表 1 AENet 的详细设置
Tab. 1 Detailed settings of AENet

模块名称	输入维度	核心操作	输出维度
输入层	$N \times 3$	维度转置	$3 \times N$
编码器第一层	$3 \times N$	卷积(3→64)→批归一化→激活	$64 \times N$
残差块 1	$64 \times N$	卷积(64→128)→残差连接	$128 \times N$
注意力模块 1	$128 \times N$	生成注意力权重→特征加权	$128 \times N$
残差块 2	$128 \times N$	卷积(128→256)→残差连接	$256 \times N$
注意力模块 2	$256 \times N$	生成注意力权重→特征加权	$256 \times N$
残差块 3	$256 \times N$	卷积(256→512)→残差连接	$512 \times N$
注意力模块 3	$512 \times N$	生成注意力权重→特征加权	$512 \times N$
编码器最终层	$512 \times N$	卷积(512→128)→批归一化→激活	$128 \times N$
全局特征提取	$128 \times N$	全局最大池化	128×1
全局特征 MLP	128	MLP(128→512→128)→层归一化	128
特征融合	局部 $128 \times N$ 全局 128	特征相加融合	$128 \times N$
解码器(训练模式)	$128 \times N$	卷积(128→512→256→128→64→3)→残差连接	$3 \times N$
输出层	$3 \times N$	维度转置	$N \times 3$

3.3 评价指标

为定量评估点云配准的精度,本文采用旋转均方根误差(RMSE-R)和平移均方根误差(RMSE-t)作为主要评价指标。对于测试集中的 M 个样本,设第 i 个样本的真实刚体变换为旋转矩阵 R_i^{gt} 和平移向量 t_i^{gt} ,预测的刚体变换为 R_i^{pred} 和 t_i^{pred} 。则旋转均方根误差定义为:

$$\text{RMSE-R} = \sqrt{\frac{1}{M} \sum_{i=1}^M \left\| \theta \left((R_i^{\text{gt}})^{-1} R_i^{\text{pred}} \right) \right\|^2}, \quad (16)$$

其中: $\|\cdot\|$ 为欧氏范数, $\theta(\cdot)$ 表示将旋转矩阵转换为对应的旋转角度。

平移均方根误差定义为:

$$\text{RMSE-t} = \sqrt{\frac{1}{M} \sum_{i=1}^M \left\| t_i^{\text{gt}} - t_i^{\text{pred}} \right\|^2}. \quad (17)$$

RMSE-R 和 RMSE-t 分别衡量旋转和平移估计的总体误差,数值越小表明配准精度越高。

3.4 本文方法实验结果

3.4.1 特征表达能力分析

本文方法构建了基于残差注意力机制的 AENet 网络,通过层级式特征聚合学习点云的判别性特征表示。为验证 AENet 网络中注意力机制对特征提取的调制效果,图 3~图 4 分别展示了中间特征、融合特征及全局特征向量的结果。

图 3 中,热力图直观呈现了特征在不同演进




图 3 中间特征与融合特征热力图

Fig. 3 Heatmaps of Intermediate and Fused Features

阶段的选择性响应机理。图 3(b)中间特征热力图中,红色高强度响应显著富集于边缘及角点等




图4 全局特征向量条形图

Fig. 4 Bar chart of global feature vectors

高曲率部位,而蓝色低强度响应则覆盖平坦区域,反映了网络对点云局部显著结构的精准捕获能力(彩图见期刊电子版)。在此基础上,通过全局池化实现空间信息聚合。

图4中,各类别全局向量在不同通道上的数值分布具有显著差异,形成了极具辨识度的语义表征,确保了算法在面对大位姿偏差时,仍能通过特征相似性检索建立准确的同源对应关系。进一步地,通过全局信息的回传与级联,融合特征热力图显示其红色区域由孤立点演变为空间连续的高一致性分布,体现了上下文信息对局部细节的调制增强(彩图见期刊电子版)。这种特征分布的稳定性为表2中初始匹配阶段获得约0.48的特征相似度提供了物理依据,有效抑制了局部结构重复带来的干扰。综上,局部判别力与全局语义一致性的结合构建了稳健的特征约束,为后续由粗至精的多尺度迭代奠定了可靠的起始条件。

3.4.2 配准结果

为验证深度特征一致性约束与多尺度迭代优化策略在配准各阶段的有效性,基于上述提取的强判别性深度特征进行配准实验。实验

中,为模拟真实采集环境下的数据扰动,在最大 45° 旋转角度的初始位姿偏差及局部结构重复的条件下,对输入点云添加标准差 σ 为0.01的高斯随机噪声,并依次完成初始匹配、粗尺度、中尺度及细尺度对齐。图5给出了从初始匹配到多尺度ICP迭代优化全过程的点云对齐结果,各阶段对齐效果由相应变换矩阵作用于原始点云后得到。配准结果的定量分析如表2所示。

表2给出了四个类别在多尺度迭代各阶段的配准误差与误差降低情况。在初始匹配阶段,各类别均获得了约0.48的特征相似度,表明AENet提取的深度特征在大位姿偏差下仍能维持较稳定的匹配关系,为后续粗尺度对齐提供了可靠的初始对应。粗尺度阶段在所有类别中均实现了最主要的位姿校正,旋转误差降低85%以上,平移误差降低42%以上;中尺度阶段通过提高采样密度进一步优化局部几何一致性,各误差指标持续下降;细尺度阶段在完整点云上完成高分辨率微调,最终误差收敛至较低水平。整体上,误差随尺度递进呈单调下降趋势,体现了由全局结构调整到局部几何细化的渐进收敛过程,




图5 本文方法各阶段配准结果

Fig. 5 Registration results of each stage of the proposed method

验证了多尺度框架在提升配准稳定性与精度方面的有效性。

3.5 对比实验

为验证所提出方法的配准性能,本文将所提方法的配准结果与以下基于端到端的深度学习点云配准方法 FINet^[13], OGMM^[15], IDAM-GNN^[16], PREDATOR^[17] 以及 RoCNet^[14] 进行对比以验证方法有效性。同时,与文献[5, 10]一样,针对旋转矩阵和平移向量分别计算平均绝对误差(MAE)、平均各向同性误差(MIE)和均方根误差(RMSE),以衡量模型的性能,其对比结果如图6和表3所示。

表3给出了不同深度学习方法在ModelNet40

数据集上的点云配准结果。对比方法均为端到端配准网络,通过直接回归刚体变换完成配准。相比之下,本文方法将深度特征学习与多尺度ICP迭代优化相结合,在优化过程中引入深度特征一致性约束。从定量结果可以看出,本文方法在旋转误差相关的MAE-R, MIE-R及RMSE-R指标上均取得最低误差,其中RMSE-R相较于FINet, OGMM, IDAM-GNN, PREDATOR 和 RoCNet分别降低约85.5%, 89.7%, 78.8%, 74.3%和61.6%,表明其在复杂姿态变化和较大初始位姿偏差条件下能够更稳定地估计旋转变换。

在平移误差方面,尽管本文方法与IDAM-GNN在MAE-指标上 t 均为0.004 3 m,但

表 2 本文方法的定量分析结果
Tab. 2 Quantitative analysis results of the proposed method

类别	迭代阶段	采样点数	特征相似度	RMSE-R/(°)	RMSE-t/m	误差降低/%
Chair	初始匹配	1 024	0.481 9	39.270 8	0.090 2	—
	粗尺度对齐	206	—	0.414 7	0.007 0	98.9/92.2
	中尺度对齐	645	—	0.366 3	0.006 1	11.7/12.9
	细尺度对齐	1 024	—	0.313 5	0.004 7	14.4/8.2
Lamp	初始匹配	1 024	0.477 4	4.237 2	0.059 4	—
	粗尺度对齐	242	—	0.603 9	0.005 1	85.7/91.4
	中尺度对齐	669	—	0.569 6	0.003 7	5.7/27.5
	细尺度对齐	1 024	—	0.512 8	0.002 9	10.0/21.6
Flower_pot	初始匹配	1 024	0.473 6	30.101 9	0.197 6	—
	粗尺度对齐	474	—	1.204 9	0.114 1	96.0/42.3
	中尺度对齐	944	—	0.800 5	0.009 1	33.6/92.0
	细尺度对齐	1 024	—	0.720 3	0.005 7	10.0/37.4
Airplane	初始匹配	1 024	0.477 7	23.161 1	0.156 9	—
	粗尺度对齐	210	—	0.945 0	0.016 6	95.9/89.4
	中尺度对齐	603	—	0.830 7	0.008 5	12.1/48.8
	细尺度对齐	1 024	—	0.731 0	0.004 7	12.0/44.7




图 6 各方法对比结果
Fig. 6 Comparison results of various methods

表 3 不同方法的配准结果对比
Tab. 3 Comparison of registration results among different methods

方法	MAE-R/(°)	MIE-R/(°)	RMSE-R/(°)	MAE-t/m	MIE-t/m	RMSE-t/m
FINet	2.617 3	4.991 7	3.928 9	0.028 7	0.057 9	0.038 1
OGMM	1.350 2	2.683 0	5.518 7	0.008 1	0.017 2	0.034 7
IDAM-GNN	0.917 1	1.821 6	2.679 3	0.004 3	0.008 5	0.009 2
PREDATOR	0.887 7	1.716 8	2.218 3	0.007 3	0.015 6	0.016 1
RoCNet	1.197 9	2.520 8	1.481 6	0.004 6	0.010 3	0.005 5
本文方法	0.520 3	0.989 6	0.569 4	0.004 3	0.007 6	0.004 5

注:MAE-R,MIE-R,RMSE-R,MAE-t,MIE-t及RMSE-t六个评价指标值越小,表示配准效果越好。

RMSE-t分别为0.004 5 m和0.009 2 m,MAE反映平均平移偏差相当,而RMSE通过平方放大误差样本的影响,表明IDAM-GNN在部分样本上存在离群预测,而本文方法的RMSE-t接近MAE-t,误差分布更加集中且稳健。这得益于迭代优化中引入的深度特征一致性约束,通过在几何残差基础上增加特征空间正则项,有效抑制局部结构重复、噪声干扰及初始位姿偏差导致的错误匹配,从而提升平移估计的稳定性。相比其他方法,本文在RMSE-t上分别降低约88.2%,

87.0%,51.1%,72.0%和18.2%,并在MIE-t上保持低水平,进一步验证了优化驱动框架中深度特征一致性嵌入的有效性。

3.6 鲁棒性分析

为进一步评估方法在更大扰动条件下的鲁棒性,实验设置初始最大旋转角度为90°,并对输入点云添加标准差 σ 为0.04的高斯随机噪声,以模拟极端环境下的位姿偏差与数据扰动。在ModelNet40数据集上进行验证,对比不同方法的配准误差,结果如表4所示。

表 4 最大旋转角度 90°、噪声 $\sigma=0.04$ 条件下的鲁棒性测试结果
Tab. 4 Robustness results with 90° max rotation and $\sigma=0.04$ noise conditions

方法	MAE-R/(°)	MIE-R/(°)	RMSE-R/(°)	MAE-t/m	MIE-t/m	RMSE-t/m
FINet	3.271 6	5.990 2	4.931 6	0.035 9	0.069 5	0.047 6
OGMM	1.630 2	3.175 9	6.070 6	0.009 3	0.019 7	0.038 2
IDAM-GNN	1.082 5	2.094 8	3.081 9	0.004 7	0.009 4	0.010 3
PREDATOR	1.065 2	1.974 3	2.551 0	0.008 4	0.017 9	0.018 5
RoCNet	1.497 4	3.025 4	1.703 8	0.005 3	0.012 6	0.006 1
本文方法	0.598 3	1.038 0	0.653 8	0.004 6	0.008 2	0.005 0

在90°大角度偏差与强噪声干扰下,本文方法的MAE-R和MIE-R分别为0.598 3°和1.038 0°,显著低于对比方法。其MAE-t为0.004 6 m,MIE-t为0.008 2 m,均优于所有对比方法。RMSE-R与RMSE-t分别为0.653 8°和0.005 0 m,均为最低,表明配准结果离散度小且可靠性高。相比之下,FINet与OGMM等方法的误差明显增大,例如OGMM的RMSE-R达6.070 6°,反映出其对大角度偏差与强噪声的敏感性。实验

结果表明,本文方法在极端扰动条件下仍能保持高精度与高稳定性,展现出较好的鲁棒性。

3.7 消融实验

为验证点级特征编码阶段各模块的有效性,在ModelNet40数据集上进行了消融实验。实验在保持训练策略、优化参数及整体网络结构一致的前提下,仅对指定模块进行替换或删除,注意力机制、多尺度ICP优化框架以及深度特征一致性约束均保持不变,并重新训练至收敛。

具体而言,变体 A 移除了非线性映射结构,仅保留最大池化与特征融合模块,用于分析共享多层感知机对特征表达能力的贡献;变体 B 保留非线性映射与特征融合模块,但将最大池化替换为平均池化,以评估不同全局聚合方式对表示稳定

性与判别性的影响;变体 C 保留非线性映射与最大池化结构,但移除特征融合模块,用于验证融合策略对配准精度的作用。本文方法保留非线性映射、最大池化与特征融合模块,作为完整模型进行对比,实验结果和定量比较如图 7、表 5 所示。




图 7 不同消融实验在 ModelNet40 数据集上的配准结果

Fig. 7 Registration results of the proposed method

从实验结果可见,各模块对配准精度均具有正向贡献。变体 A 移除非线性映射结构后,MAE-R 升至 0.7406° ,MAE-t 升至 0.0053 m ,均高于完整模型,表明共享多层感知机所提取的非

线性点级特征是描述判别能力的基础。变体 B 将最大池化替换为平均池化后,平移误差显著增大,其中 MAE-t 达 0.0113 m ,MIE-t 达 0.0381 m ,说明平均池化在聚合全局特征时易

表 5 不同消融实验在 ModelNet40 数据集上的定量比较

Tab. 5 Quantitative comparison of different ablation experiments on the ModelNet40 dataset

模型	模块	MAE-R/ (°)	MIE-R/ (°)	RMSE-R/ (°)	MAE-t/ m	MIE-t/ m	RMSE-t/ m
变体 A	最大池化+特征融合	0.740 6	2.270 8	1.254 0	0.005 3	0.013 2	0.006 2
变体 B	非线性映射+特征融合+平均池化	0.801 9	1.732 4	0.950 7	0.011 3	0.038 1	0.016 7
变体 C	非线性映射+最大池化	1.042 2	3.546 1	1.573 8	0.006 4	0.026 0	0.010 1
本文方法	非线性映射+特征融合+最大池化	0.520 3	0.989 6	0.569 4	0.004 3	0.007 6	0.004 5

受离群点影响,稳定性低于最大池化,进而削弱了平移估计精度。变体 C 移除特征融合模块后,旋转误差明显升高,在所有变体中表现最差,证明局部特征与全局特征的融合对于应对大位姿变化至关重要。相比之下,本文方法同时集成非线性映射、最大池化与特征融合,在所有指标上均达到最优,充分验证了所提模块组合的有效性与互补性。

4 结 论

针对传统点云配准方法在初始位姿偏差大、噪声干扰强、局部结构重复等复杂条件下易陷入局部最优、对初始位姿敏感的问题,提出一种融合深度特征一致性与注意力网络的点云配准方法。该方法首先构建了注意力增强的深度特征提取网络 AENet,通过自监督学习提取具有判别性且对刚体变换保持鲁棒的点级特征描述符;在此基础上,利用深度特征相似性进行初始匹配并

估计粗变换;进而,在多尺度 ICP 迭代优化框架中引入深度特征一致性约束,构建融合几何误差与特征相似性的联合优化目标,实现由粗到精的稳定配准。实验结果表明,该方法对 ModelNet40 数据集具有良好的配准效果,在旋转误差、平移误差及配准适应度等评价指标上均优于多种主流深度配准方法。该方法通过将深度特征嵌入传统优化流程,显著缓解了噪声、部分重叠与结构重复对配准结果的影响。然而,在极端点云缺失、严重遮挡或非刚性形变等复杂场景下,方法的泛化能力仍存在一定局限。未来工作将进一步探索更鲁棒的特征表示、自适应权重机制,以增强方法在开放场景与动态环境中的适用性。

作者贡献声明:

赵夫群:算法提出,论文构思;
陈俊汐:设计实验及初稿写作;
周明全:论文审核与编辑写作。

参考文献:

[1] 胡冰楠,刘康,郑恩辉,等. 基于 4D 毫米波雷达点云的改进正态分布变换配准算法[J]. 激光与光电子学进展, 2025, 62(20): 264-275.
HU B N, LIU K, ZHENG E H, *et al.* Improved normal distribution transformation registration algorithm based on 4D millimeter-wave radar point cloud [J]. *Laser & Optoelectronics Progress*, 2025, 62 (20): 264-275. (in Chinese)

[2] 殷果,王大庆,孙玉香,等. 融合改进 SAC-IA 与加权 ICP 的高效点云配准方法[J/OL]. 哈尔滨工业大学学报, 1-18[2026-01-21]. <https://link.cnki.net/urlid/23.1235.t.20251010.1655.006>.
YIN G, WANG D Q, SUN Y X, *et al.* An efficient

point cloud registration method integrating improved SAC-IA and weighted ICP [J/OL]. *Journal of Harbin Institute of Technology*, 1-18[2026-01-21]. (in Chinese)

[3] 李泉凯,李广云,王力. 一种多阶段优化的 CUBE-ICP 点云配准算法[J]. 测绘通报, 2025(12): 77-81, 120.
LI X K, LI G Y, WANG L. A multi-stage optimized CUBE-ICP point cloud registration algorithm [J]. *Bulletin of Surveying and Mapping*, 2025 (12): 77-81, 120. (in Chinese)

[4] 张伟,方麒,曾志龙,等. 自适应采样与几何-空间特征融合的点云配准[J]. 光学精密工程, 2025, 33(20): 3315-3330.
ZHANG W, FANG Q, ZENG Z L, *et al.* Point

- cloud registration using adaptive sampling and geometric-spatial feature fusion [J]. *Opt. Precision Eng.*, 2025, 33(20): 3315-3330. (in Chinese)
- [5] 聂吉祥, 王怡博, 沈秋兵, 等. 基于流形聚类的欠采样非均匀密度三维点云配准[J]. *液晶与显示*, 2024, 39(9): 1255-1263.
- NIE J X, WANG Y B, SHEN Q B, *et al.* Undersampled non-uniform density multi-station 3D point cloud alignment method based on manifold clustering [J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(9): 1255-1263. (in Chinese)
- [6] 王鑫森, 李新春, 陶志勇. 基于统计局部特征描述与匹配的点云配准算法[J]. *液晶与显示*, 2024, 39(1): 89-99.
- WANG X M, LI X C, TAO Z Y. Point cloud registration algorithm based on statistical local feature description and matching [J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(1): 89-99. (in Chinese)
- [7] 李茂月, 许圣博, 孟令强, 等. 基于逐点前进法的改进型点云配准方法[J]. *中国光学(中英文)*, 2024, 17(4): 875-885.
- LI M Y, XU S B, MENG L Q, *et al.* An improved point cloud registration method based on the point-by-point forward method[J]. *Chinese Optics*, 2024, 17(4): 875-885. (in Chinese)
- [8] XIE Y F, WANG B Y, LI S Q, *et al.* Iterative feedback network for unsupervised point cloud registration[J]. *IEEE Robotics and Automation Letters*, 2024, 9(3): 2327-2334.
- [9] 汤洁, 陈文武, 周昕然, 等. 基于邻域几何质心的深度学习点云配准[J]. *光子学报*, 2025, 54(9): 232-244.
- TANG J, CHEN W W, ZHOU X R, *et al.* Deep learning-based point cloud registration via neighborhood geometric centroids[J]. *Acta Photonica Sinica*, 2025, 54(9): 232-244. (in Chinese)
- [10] 陈睿星, 吴军, 赵雪梅, 等. RPMNet++: 结合 Copula 去噪模块的双向注意力点云配准网络[J]. *计算机辅助设计与图形学学报*, 2025, 37(6): 944-960.
- CHEN R X, WU J, ZHAO X M, *et al.* RPMNet++: a bidirectional attention point cloud registration network combining copula denoising [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2025, 37(6): 944-960. (in Chinese)
- [11] 易见兵, 熊文武, 彭鑫, 等. 融合特征交互和点匹配增强的无监督点云配准算法[J]. *光学精密工程*, 2025, 33(20): 3281-3298.
- YI J B, XIONG W W, PENG X, *et al.* Unsupervised point cloud registration algorithm integrating feature interaction and point matching enhancement [J]. *Opt. Precision Eng.*, 2025, 33(20): 3281-3298. (in Chinese)
- [12] 岳倩雯, 王东强, 张强. 融合自适应优化与多维聚焦的点云配准网络[J]. *计算机科学*, 2025, 52(S2): 502-508.
- YUE Q W, WANG D Q, ZHANG Q. Point cloud registration network integrating adaptive optimization and multi-dimensional focusing[J]. *Computer Science*, 2025, 52(S2): 502-508. (in Chinese)
- [13] XU H, YE N J, LIU G H, *et al.* FINet: dual branches feature interaction for partial-to-partial point cloud registration [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, 36(3): 2848-2856.
- [14] SLIMANI K, TAMADAZTE B, ACHARD C. Rocnet: 3D robust registration of points clouds using deep learning[J]. *Machine Vision and Applications*, 2024, 35(4): 100.
- [15] MEI G F, POIESI F, SALTORI C, *et al.* Overlap-guided gaussian mixture models for point cloud registration[C]. *2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. January 2-7, 2023, Waikoloa, HI, USA. IEEE, 2023: 4500-4509.
- [16] LI J H, ZHANG C H, XU Z Y, *et al.* Iterative Distance-aware similarity matrix convolution with mutual-supervised point elimination for efficient point cloud registration[C]. *Computer Vision-EC-CV 2020*. Cham: Springer, 2020: 378-394.
- [17] HUANG S Y, GOJCIC Z, USVYATSOV M, *et al.* PREDATOR: registration of 3D point clouds with low overlap [C]. *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 20-25, 2021, Nashville, TN, USA. IEEE, 2021: 4265-4274.
- [18] FU K X, LUO J Z, LUO X Y, *et al.* Robust point cloud registration framework based on deep graph matching[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(5): 6183-6195.
- [19] 陆军, 王文豪, 杜宏劲. 基于特征融合和网络采

- 样的点云配准[J]. 智能系统学报, 2025, 20(3): 621-630.
- LU J, WANG W H, DU H J. Point cloud registration based on feature fusion and network sampling [J]. *CAAI Transactions on Intelligent Systems*, 2025, 20(3): 621-630. (in Chinese)
- [20] 赵宝, 王梓涵, 贾兆红, 等. 基于动态图卷积和 PointNet 的三维局部特征描述符[J]. 计算机辅助设计与图形学学报, 2025, 37(1): 89-99.
- ZHAO B, WANG Z H, JIA Z H, *et al.* Three-dimensional local feature descriptor based on dynamic graph convolution and PointNet [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2025, 37(1): 89-99. (in Chinese)
- [21] 郝佳, 姚国英, 周剑, 等. 基于图像和点云融合的三维小目标检测方法[J]. 测绘通报, 2025(3): 33-38.
- HAO J, YAO G Y, ZHOU J, *et al.* 3D small object detection method based on image and point cloud fusion [J]. *Bulletin of Surveying and Mapping*, 2025(3): 33-38. (in Chinese)
- [22] 赵凯旋, 王锦锦, 高颂, 等. 基于 PointNet++ 和改进 ConvNeXt 模型的奶牛个体身份识别方法[J]. 农业机械学报, 2025, 56(7): 567-574, 595.
- ZHAO K X, WANG J J, GAO S, *et al.* Individual cow identification method based on PointNet++ and improved ConvNeXt network [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(7): 567-574, 595. (in Chinese)
- [23] 邢燕, 马俊, 檀结庆. 保特征的单幅图像三维网格重建[J]. 计算机辅助设计与图形学学报, 2023, 35(3): 354-361.
- XING Y, MA J, TAN J Q. Feature preserving mesh reconstruction from a single image [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2023, 35(3): 354-361. (in Chinese)
- [24] 汤家谱, 李曼, 曹文明, 等. 基于图扩散增强的对比学习推荐系统框架[J]. 计算机应用研究, 2025, 42(11): 3265-3274.
- TANG J P, LI M, CAO W M, *et al.* Graph diffusion-augmented based contrastive learning framework for recommendation systems [J]. *Application Research of Computers*, 2025, 42(11): 3265-3274. (in Chinese)

作者简介:



赵夫群(1982—),女,山东临沂人,博士,教授,硕士研究生导师,2007年、2019年分别于西安石油大学、西北大学获得硕士和博士学位,主要从事图形图像处理和三维重建方面的研究。E-mail: fuqunzhao@126.com



陈俊汐(2000—),女,陕西汉中,人,硕士研究生,2023年于西安财经大学获得学士学位,现就读于西安财经大学,主要从事图形图像处理。E-mail: cjx1596@163.com