

文章编号 1004-924X(2025)20-3281-18

融合特征交互和点匹配增强的 无监督点云配准算法

易见兵^{1,2*}, 熊文武^{1,2}, 彭鑫^{1,2}, 吴欣^{1,2}

(1. 江西理工大学 信息工程学院, 江西 赣州 341000;

2. 江西理工大学 多维智能感知与控制江西省重点实验室, 江西 赣州 341000)

摘要:为了解决点云配准过程中因异常点干扰、部分点重叠及非对应相似点等因素导致点云间部分点对误匹配问题,本文设计了一种融合特征交互和点匹配增强的无监督点云配准算法。首先,设计了一种特征融合模块,将提取的源点云和目标点云特征信息进行交互,并将该交互特征与其对应位置的上一层提取特征进行融合,以增强特征表达能力。其次,提出了一种图卷积-Transformer融合模块,利用图卷积提取局部几何信息且通过Transformer的自注意力机制获取全局上下文信息,同时引入交叉注意力机制实现点云间特征交互融合。最后,引入了一种点匹配增强模块,利用源点云和目标点云的点特征欧式距离及点的邻域特征相似性来匹配点间对应关系。本文算法在ModelNet40(含噪声),7Scenes,ICL-NUIM,KITTI和ScanObjectNN数据集上进行了验证,实验结果表明,相较于IFNet算法,本文算法在均方根误差RMSE(R)上分别下降31.93%,23.72%,19.76%,10.53%和21.05%,充分验证了所提算法在配准精度和鲁棒性方面的优势。综上所述,本文算法在配准精度、泛化能力与抗噪性方面表现优异,展现出良好应用潜力。

关键词:点云配准;特征交互;交叉注意力;点匹配增强;无监督

中图分类号:TP391.4 **文献标识码:**A

doi:10.37188/OPE.20253320.3281

CSTR:32169.14.OPE.20253320.3281

Unsupervised point cloud registration algorithm integrating feature interaction and point matching enhancement

YI Jianbing^{1,2*}, XIONG Wenwu^{1,2}, PENG Xin^{1,2}, WU Xin^{1,2}

(1. College of Information Engineering, Jiangxi University of Science and Technology,
Ganzhou 341000, China;

2. Jiangxi Provincial Key Laboratory of Multidimensional Intelligent Perception and Control,
Jiangxi University of Science and Technology, Ganzhou 341000, China)

* Corresponding author, E-mail: yijianbing8@jxust.edu.cn

Abstract: To address the issue of partial point mismatches in point cloud registration caused by outliers, partial overlap, and geometrically similar but non-corresponding points, this paper proposed an Unsupervised Point Cloud Registration Algorithm Integrating Feature Interaction and Point Matching Enhancement. First, a feature fusion module was developed to perform interactive integration between features of

收稿日期:2025-06-20;修订日期:2025-07-28.

基金项目:国家自然科学基金(No. 62366017);江西省自然科学基金(No. 20181BAB202004);江西省研究生创新专项资金(No. YC2024-S570, No. YC2024-S572);赣州市重点研发计划项目(No. GZ2024YLLJ273)

the source and target point clouds, and to fuse the resulting features with those extracted at the corresponding positions in the previous layer, thereby enhancing feature representation capability. Second, a graph Convolutional Network-Transformer fusion module was designed, in which graph convolution was employed to extract local geometric information, while the self-attention mechanism of the Transformer was used to capture global contextual information. A cross-attention mechanism was further incorporated to achieve effective feature interaction between point clouds. Finally, a point matching enhancement module was introduced, which established point correspondences by jointly considering the Euclidean distance of point features and the similarity of their local neighborhoods. The proposed algorithm was evaluated on the ModelNet40 (with noise), 7Scenes, ICL-NUIM, KITTI, and ScanObjectNN datasets. Experimental results demonstrate that, compared with the IFNet algorithm, the proposed method achieves reductions in root mean square error RMSE(R) of 31.93%, 23.72%, 19.76%, 10.53%, and 21.05%, respectively, validating its superiority in both registration accuracy and robustness. Overall, the proposed algorithm exhibits excellent performance in registration accuracy, generalization capability, and noise resistance, showing strong potential for real-world applications.

Key words: point cloud registration; feature interaction; cross-attention; point matching enhancement; unsupervised

1 引言

随着基于深度学习的点云配准技术^[1]的快速发展,点云配准在自动驾驶^[2]、医学影像处理^[3]、机器人导航^[4]、以及地图构建^[5]等领域得到了广泛应用。作为点云数据处理的关键技术之一,点云配准旨在求解源点云和目标点云之间的最优变换矩阵^[6],将两片点云对齐到同一坐标系下。然而,由于点云数据往往存在部分点重叠^[7]以及噪声^[8]等问题,这些因素可能干扰点云特征的提取,导致点对之间的真实对应关系出现异常,点云配准效果不佳。

传统方法中ICP^[9]是具有代表性的算法,通过最近邻搜索^[10]建立点对,计算刚性变换矩阵完成配准,但依赖于初始位姿^[11]且易陷入局部最优^[12],从而限制了配准精度。随着深度学习技术的快速发展,基于深度学习的点云配准方法被提出。Qi等人^[13]首次提出了专用于点云PointNet框架,采用MLP提取特征实现置换不变性,但容易受异常点干扰,在复杂场景下表现不稳定。为了解决这一问题,Qi等人^[14]又对局部特征提取方法进行了改进,但在处理复杂结构或部分点重叠时,依然未能充分考虑点云几何结构和局部点之间的关系,限制了其性能表现。Wang等人^[15]提出了DCP算法,采用动态图卷积网络^[16]来提取

点云特征,通过奇异值分解实现配准,但DCP算法主要关注局部特征^[17],忽略了全局信息的有效利用,导致在大范围部分重叠场景下难以获得稳定匹配。Choy等人^[18]提出了FCGF算法,采用Minkowski卷积^[19]解决点云稀疏性问题,并实现了全卷积特征提取,尽管如此,FCGF在多尺度特征信息^[20]的利用上有所不足,并可能引入特征冗余,尤其在面对含有异常点和非对应相似点时,难以稳定获取可靠的匹配关系。Sarode等人^[21]提出的PCRNet算法结合了PointNet和深度学习技术,用于提取全局特征,避免了点对计算,从而提高了配准效率。然而,在MLP降采样过程中,可能会丢失部分局部信息,在面对复杂或重叠区域时性能有所下降。Huang等人^[22]提出基于特征度量的无监督配准框架FMR,通过最小化投影误差优化配准。尽管该方法能够缓解局部几何相似性引起的问题,但对异常点和重叠区域较为敏感^[23]。Shen等人^[24]提出的RIENet算法利用邻域图结构差异识别内点,适应性强,但在部分重叠点云场景中仍有识别性能的改进空间。Jiang等人^[25]提出CEMNet算法,将点云配准建模为马尔可夫决策^[26]过程,并通过强化学习优化配准性能,尽管该方法增强了鲁棒性,但依赖特征选择^[27]的问题仍未完全解决。Xie等人^[28]提出IFNet算法,通过反馈块递归生成刚性变换和

高级特征,提升了无监督配准性能,但该方法对初始位姿依赖性较强,缺乏针对非对应相似点的判别机制,仍难以从特征层面避免误匹配。Xu 等人^[29]提出的 FINet 算法通过多级特征交互^[30]和双分支结构^[31]实现部分点云配准,无需注意力机制或显式掩码估计,然而在局部特征处理能力和应对部分点重叠方面仍有改进空间。

近年来,深度学习在三维点云配准中取得了较大进展,显著提升了特征提取能力与点云配准精度。然而,在复杂场景或无监督框架下,现有方法仍面临挑战。一方面,异常点干扰导致提取的局部特征有较多冗余信息,降低点对匹配的准确性;另一方面,视角遮挡等问题易造成点云间部分重叠,限制了局部与全局信息的获取。此外,多数方法依赖特征距离进行匹配,在特征不显著或结构相似区域易发生误匹配,从而影响最终配准效果。为了解决上述挑战,本文旨在提出一种融合特征交互和点匹配增强的无监督点云配准算法,综合提升特征表达与点对匹配的准确性。该算法有助于推动无监督点云配准技术的理论发展,同时提升其在自动驾驶、机器人导航、增强现实等实际应用中的可靠性与普适性,具有广阔的应用前景。本文的主要贡献如下:

(1) 针对点云配准时,提取的点云特征容易受到异常点干扰,导致点云之间部分点的对应关系不准确,本文提出了一种特征融合模块。该模块通过引导源点云与目标点云之间的特征信息进行交互,并将该交互特征与其对应位置的上一层提取特征进行融合,在扩大感受野的同时,有效缓解异常点带来的噪声干扰,且能够有效关联点云间的局部几何结构上的相似性。

(2) 针对点云配准时,点云部分点重叠容易导致局部信息的丢失与全局信息提取的不足,本

文设计了一种图卷积-Transformer 融合模块,该模块首先通过 K 近邻算法获取关键点的邻域信息,并通过边缘卷积处理局部特征,从而减少局部信息的丢失,接着通过 Transformer 中的自注意力机制来捕获有效的全局信息以缓解部分点重叠导致的信息丢失问题,并利用交叉注意力机制实现点云间特征交互融合,从而提升点云配准的鲁棒性。

(3) 针对点云配准时,非对应相似点由于具有相近的局部几何结构特征,仅依据点云特征距离来确定点的对应关系存在部分点对匹配不准确,本文引入了一种点匹配增强模块,通过源点云和目标点云的特征相似性进行软匹配来构建初步匹配关系,然后结合邻域特征相似性来综合度量点对相似性,同时利用共享源点云的 KNN 索引,有效地提取伪目标点云中对应点的边缘特征,并分析源点云与伪目标点云之间的几何差异,以正确匹配点间对应关系。

2 点云配准网络

在三维点云配准任务中,给定源点云 $X = \{x_i \in \mathbb{R}^3 | i = 1, 2, \dots, N\}$ 与目标点云 $Y = \{y_j \in \mathbb{R}^3 | j = 1, 2, \dots, M\}$,旨在找到两组点云之间的对应集合,以及最优的旋转矩阵 $R \in SO(3)$ 和平移向量 $t \in \mathbb{R}^3$,使得两组点云之间的距离最近, N 和 M 则分别表示源点云和目标点云中的数量。

本文提出的点云配准框架如图 1 所示。首先,将源点云与目标点云输入融合特征交互和点匹配增强的无监督点云配准网络(Unsupervised Point Cloud Registration Network Integrating Feature Interaction and Point Matching Enhancement,




图 1 点云配准框架图

Fig. 1 Point cloud registration framework diagram

UFIPME-Net), 获得初始的刚性变换, 并对源点云进行形变, 其中 UFIPME-Net 为本文提出的点云配准网络。随后, 更新后的源点云再次与原目标点云一同输入 UFIPME-Net 网络, 继续优化配准结果, 该过程连续迭代三次, 每次均基于前一次的变换结果对源点云进行更新, 而目标点云保持不变, 不断细化点对之间的匹配关系, 逐步提升配准精度。三次配准完成后, 输出最终的刚性变换结果, 构成一次完整的点云配准过程。

为了实现上述多轮配准迭代, 本文设计了融合特征交互和点匹配增强的无监督点云配准网络 UFIPME-Net, 如图 2 所示。首先, 将源点云和

目标点云输入到特征融合模块, 通过多层卷积逐步提取局部几何特征, 并引入特征交互模块进行特征融合, 从而将不同深度卷积层的特征拼接形成高维特征。接着, 将获得的高维特征输入到结合图卷积与 Transformer 的融合模块, 捕获每个点云中的局部信息和全局信息。随后, 源点云和目标点云的特征信息被传递到点对匹配增强模块, 通过计算特征相似性来构建点匹配得分矩阵, 并融合邻域匹配信息生成相似性匹配映射图。基于源点云与伪目标点云之间的几何差异, 评估点对的匹配置信度, 得到正确的点间对应关系。




图 2 本文算法的点云配准网络 UFIPME-Net

Fig. 2 Point cloud registration network UFIPME-Net of our algorithm

最后, 利用奇异值分解 (Singular Value Decomposition, SVD) 方法估计源点云与目标点云之间的最优刚性变换, 并将该变换用于更新源点云的位置, 以便进入下一轮迭代。

2.1 特征融合模块

针对点云特征提取过程中易受到异常点干扰, 导致提取的特征部分信息缺失和增加了一些

冗余信息, 受文献[32-33]启发, 本文设计了一种特征融合模块, 引导源点云与目标点云之间的特征信息交互与融合, 在扩大感受野的同时, 有效缓解异常点干扰带来的影响, 所提出的特征融合模块结构如图 3 所示。

首先, 输入的点云数据通过多层卷积逐步提取局部几何特征, 第一层将特征映射到 3 维空间,




图 3 特征融合模块

Fig. 3 Feature fusion module

接下来的卷积层依次增加特征维度至 32, 64, 128, 256, 提取更高阶特征, 在卷积层后采用批归一化和 ReLU 激活函数以加速训练和稳定学习。为增强特征表达, 在第二层和第三层卷积后引入特征交互模块, 同时对 32 和 64 深度的特征进行复制, 扩展最大池化特征至相同维度。最后, 将不同深度卷积层的特征拼接, 得到更丰富的高维特征。这种特征交互机制能够有效地从点云中提取相关特征且实现信息互补, 以抑制因异常点干扰而导致的提取冗余特征问题。计算公式如下:

$$h_{x1} = f_2(f_1(X)) \odot \text{repeat}(\max(f_2(f_1(Y)))) \quad (1)$$

$$h_{y1} = f_2(f_1(Y)) \odot \text{repeat}(\max(f_2(f_1(X)))) \quad (2)$$

$$h_{x2} = f_3(h_{x1}) \odot \text{repeat}(\max(f_3(h_{y1}))) \quad (3)$$

$$f_{x5} = f_5(f_4(h_{x2})), \quad (4)$$

其中: X, Y 分别表示源点云和目标点云, $f_i(\cdot)$ 表示由卷积层、批归一化与激活函数组成的特征提取操作, h_{x1}, h_{x2} 和 h_{y1} 表示特征交互操作后的输出特征, f_{x5} 表示特征提取操作对应的输出特征, $\max(\cdot)$ 表示最大池化层, $\text{repeat}(\cdot)$ 表示特征复制操作。目标点云 Y 的特征提取过程与上述

相同。

每层卷积后通过最大池化提取局部特征, 并在通道维度上进行拼接, 融合不同尺度的几何结构信息, 得到高维特征表示。计算公式如下:

$$F_X = \text{Concat}(f_{x1}, f_{x2}, f_{x3}, f_{x4}, f_{x5}), \quad (5)$$

其中: F_X 表示特征融合模块的输出特征, $\text{Concat}(\cdot)$ 表示特征拼接, $f_{x1}, f_{x2}, f_{x3}, f_{x4}$ 和 f_{x5} 分别表示各特征提取操作对应的输出特征, 目标点云 Y 的特征提取过程与上述相同。

2.2 图卷积-Transformer 融合模块

针对部分点重叠导致的局部信息缺失及全局信息提取不足问题。本文受到 Transformer 机制^[34-35]的启发, 设计了一种图卷积-Transformer 融合模块, 如图 4 所示。首先, 将融合特征输入到图卷积中, 通过 k 近邻算法获取关键点的邻域信息, 并通过边缘卷积处理局部特征, 从而减少局部信息的丢失。接着, 将局部特征与几何结构编码输入到 Transformer 中的自注意力机制中, 通过计算点与点之间的关系, 进一步捕捉全局上下文信息, 有助于缓解部分点重叠带来的影响。最后, 通过交叉注意力机制促进源点云与目标点云之间的特征交互和信息融合。对比两点云的特




图 4 图卷积-Transformer 融合模块

Figure 4 Graph convolution-Transformer fusion module

征,基于逐点几何特征强化不同点云间的特征关联性,从而在关键区域实现更精细的特征匹配,进一步优化配准性能。

为了增强模型对点云局部几何结构的感知能力,本文采用了几何结构编码方法。首先使用 k 近邻算法来确定顶点 p_i 的两个最近点 p_{i1} 和 p_{i2} ,建立局部连接关系。基于邻域点的关系,分别构建边向量、边长和法向量,从而形成完整的几何结构编码。

具体而言,边向量 $d_{i,j}$ 定义为顶点 p_i 指向其第 j 个邻居点 p_j 的向量,计算公式如式(6):

$$d_{i,j} = p_j - p_i. \quad (6)$$

边长 $l_{i,j}$ 是对应边向量的欧氏范数,反映了邻接点之间的空间距离,计算公式为:

$$l_{i,j} = \|p_j - p_i\|_2 = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2 + (z_j - z_i)^2}. \quad (7)$$

为了捕捉点云局部的表面特征得到每个点的几何结构编码,本文通过边向量之间的叉乘计算局部平面法向量 n_i 。具体方法如式(8):

$$n_i = \frac{(p_{i1} - p_i) \times (p_{i2} - p_i)}{\|(p_{i1} - p_i) \times (p_{i2} - p_i)\|}. \quad (8)$$

然后,将顶点 p_i ,边向量 $d_{i,j}$,边长 $l_{i,j}$ 和法向量 n_i 进行拼接,得到每个点的几何结构编码,其中, $\text{Concat}(\cdot)$ 表示特征拼接。公式表示如式(9):

$$B_i = \text{Concat}(p_i, d_{i,j}, l_{i,j}, n_i). \quad (9)$$

接下来采用边缘卷积对特征进行处理,基于点云的空间分布关系构建 k 近邻图结构,以确定每个关键点的局部邻域。设给定点云 $C = \{c_1, \dots, c_n\} \subseteq \mathbb{R}^F$ 。其中, F 表示每个点的特征维度。对于点 c_i 及其邻域中的点 c_j ,定义边缘特征 b_{ij} 如公式(10)所示:

$$b_{ij} = r_\Omega(c_i, c_j - c_i), \quad (10)$$

其中: r_Ω 表示是非线性函数,由神经网络实现, Ω 表示可学习参数。在卷积操作中,通过邻域内的边缘特征聚合来获取每个中心点的局部特征表示,计算公式可由(11)表示:

$$I_i = \frac{1}{|N(i)|} \sum_{j \in N(i)} r_\Omega(c_i, c_j - c_i), \quad (11)$$

其中: c_j 表示 c_i 的 k 邻域点,可将 c_i 视为中心点, $N(i)$ 表示每个点 c_i 的邻域集合, c_i 为中心点的所有邻域点 c_j ,邻近点特征差 $c_j - c_i$ 表示局部邻域信息。图卷积计算流程如图 5 所示。




图 5 图卷积计算流程图

Fig. 5 Graph convolution calculation flowchart

在图卷积处理之后,局部特征和几何结构编码被输入到 Transformer 的自注意力机制中。自注意力机制能够通过计算点与点之间的关系,进一步捕捉全局上下文信息。以 X 的计算为例(同样适用于 Y),将图卷积处理得到的特征和几何位置编码输入到自注意力机制中。通过将输入特征 $I \in \mathbb{R}^{N \times d_i}$ 分别与三个投影矩阵进行线性映射,得到 Q, K 和 V 。然后,通过聚合两个分支来

计算注意力分数矩阵 e_{ij} 来获得点云自身几何结构信息和上下文信息之间的相似度。然后通过 softmax 对 e_{ij} 进行逐行处理得到 $S_{i,j}$,最后通过矩阵相乘计算得到逐点几何结构特征 $H_{i \circ}$ 。自注意力输出特征的具体实现如下:

$$e_{i,j} = \frac{(h_i W_Q)(h_j W_K + R_{i,j} W_R)^T}{\sqrt{d_i}}, \quad (12)$$

$$S_{i,j} = \text{softmax}(e_{i,j}), \quad (13)$$

$$H_i = \sum_{j=1}^N S_{i,j} (h_j W_V), \quad (14)$$

其中: $S_{i,j}$ 是通过几何结构自注意力得分 $e_{i,j}$ 进行逐行 softmax 处理得到的权重系数, W_V 表示数值向量的投影矩阵, W_Q 表示查询向量的投影矩阵, W_K 表示关键字向量的投影矩阵, d_i 表示特征维度。

将交叉注意力机制以逐点几何结构特征 H_i 作为输入, 键值对 (K, V) 由输入特征 H_Y 分别通过线性映射得到, 查询向量 Q 也由输入特征 H_X 线性映射得到, 然后, 通过聚合两个分支来计算交叉注意分数矩阵 $u_{i,j}$ 来获得点云之间的特征相似度, 并交换特征信息, 促进两点云之间的相互关系。接着通过 softmax 对 $u_{i,j}$ 进行逐行处理得到 $S'_{i,j}$ 。最后通过矩阵相乘计算得到交叉注意力特征 $L_{X,i}$ 。具体实现如下:

$$u_{i,j} = \frac{(h_i^X W_Q)(h_j^Y W_K)^T}{\sqrt{d_i}}, \quad (15)$$

$$S'_{i,j} = \text{softmax}(u_{i,j}), \quad (16)$$

$$L_{X,i} = \sum_{j=1}^Y S'_{i,j} (h_j^Y W_V), \quad (17)$$

其中: $S'_{i,j}$ 是通过交叉注意力得分 $u_{i,j}$ 进行逐行 softmax 处理得到的权重系数, h_i^X 为 H_X 的逐点特征, h_j^Y 为 H_Y 的逐点特征, $u_{i,j}$ 表示两个点云特征

矩阵之间的相关性匹配值, 同时以相同的方式计算 Y 的交叉注意力特征 $L_{Y,j}$ 。

2.3 点匹配增强模块

点对匹配通过计算源点云与目标点云的欧式距离, 并利用 softmax 函数生成匹配矩阵。该方法虽然能识别点对关系, 但容易受到具有相似特征的非对应点干扰, 导致部分点对匹配不准确。针对上述问题, 本文提出一种点匹配增强模块, 如图 6 所示, 将邻域点的匹配值融入单点特征中, 丰富了单点特征表达。同时, 利用相似性匹配映射图对目标点云进行投影, 生成伪目标点云, 确保其特征与源点云相似, 然后共享源点云 X 的 KNN 索引, 以有效获取伪目标点云 Y^* 中对应点的边缘特征, 通过分析源点云与伪目标点云的几何差异^[36], 精确评估匹配可靠性, 从而提高配准精度。

首先, 利用提取到的特征 $L_X \in \mathbb{R}^{N \times d}$ 和 $L_Y \in \mathbb{R}^{N \times d}$, 使用归一化的负特征欧式距离计算 x_i 和 y_j 的点对匹配值。从本质上看, 欧氏距离是一种衡量两个特征向量之间几何差异的常用指标, 其值越小, 表示两者在特征空间中的相似性越高。然而, 在实际的特征匹配任务中, 通常采用相似度得分越高代表匹配关系越强的评判标准。




图 6 点匹配增强模块

Fig. 6 Point matching enhancement module

基于此,将欧氏距离取负,不仅实现了从差异性度量向相似性度量的转换,也使得匹配得分更符合计算逻辑与直观理解。该处理方式在保留欧氏距离良好几何判别能力的同时,提升了特征匹配过程的可解释性和实用性,有助于后续相似性分析与配准精度的提升。具体实现如下:

$$A_{i,j} = \text{soft max}([-D_{i,1}, \dots, -D_{i,M}])_j, \quad (18)$$

$$G_{i,j} = \frac{1}{K} \sum_{x'_i \in N_{x'_i}} \sum_{y'_j \in N_{y'_j}} A_{i',j'}, \quad (19)$$

其中: $D_{i,j}$ 表示点 x_i 和 y_j 之间的欧式距离, $A_{i,j}$ 表示点对匹配值,基于估计的点对匹配值来构建初始的相似性匹配映射矩阵 A 。 $N_{x'_i}$ 和 $N_{y'_j}$ 分别表示点 x_i 和点 y_j 的 k 个近邻点集合,并通过计算点 x_i 和 y_j 各自邻域内 k 个最近邻点匹配值的平均值,得到其邻域匹配值 $G_{i,j}$ 。点的高邻域匹配值通常意味着其周围的大多数邻域点具有较高的匹配值,从而对应较高的匹配概率;而点的低邻域匹配值则表明该点邻域内多数点的匹配值较低,匹配结果的不确定性较大,可靠性相对较低。真实对应点具有更高的邻域相似性,相较之下,错误匹配点的相似性较低。为提升匹配精度,采用负指数函数构建邻域匹配值与点对相关度的映射关系,并通过调节参数 β 控制其影响,从而生成优化后的相似性匹配矩阵 A' ,计算过程如图6所示。优化匹配矩阵有助于识别非对应点对,以提高点对匹配的准确性,具体实现如下:

$$D'_{i,j} = \exp(\beta - G_{i,j}) * D_{i,j}, \quad (20)$$

$$A'_{i,j} = \text{soft max}([-D'_{i,j}, \dots, -D'_{i,M}])_j. \quad (21)$$

在优化后的匹配矩阵 A' 基础上,对于源点云中的每个点 x_i ,利用得到的优化匹配矩阵生成其对应的伪匹配点,具体实现如式(22):

$$y'_i = \sum_{j=1}^A A'_{i,j} \cdot y_j \in \mathbb{R}^3. \quad (22)$$

紧接着以源点云 X 和伪目标点云 Y^* 为输入,模型的目标是输出置信度 w_i ,在源点云 X 的 k 个邻域中搜索以提取边缘特征 $e_{i,k}^x = x_i - x_k$,然后共享源点云 X 的KNN索引,获取伪目标点云 Y^* 中对应点的边缘特征 $e_{i,k}^y = y_i - y_k$,确保源点云 X 和伪目标点云 Y^* 邻域点之间的一致性。通过简单的减法操作突出源点云和伪目标点云之间的差异,以便更好地进行匹配。然后,使用MLP处理操作和求和操作生成对应特征,并将

这些特征投影到置信度中,从而有效捕捉两个邻域间的相似性和差异性。根据式(23),置信度 w_i 的计算公式为:

$$w_i = \text{sigmoid}\left(\rho\left(\sum_{k=1}^K \varphi\left(u\left(e_{i,k}^x\right) - u\left(e_{i,k}^y\right)\right)\right)\right), \quad (23)$$

其中: $\text{sigmoid}(\cdot)$ 表示 sigmoid 函数, $e_{i,k}^x$ 和 $e_{i,k}^y$ 分别表示源点云和伪目标点云的邻域边缘特征, $\varphi(\cdot)$ 和 $\rho(\cdot)$ 分别表示带有不同参数的MLP处理函数。最后,每次迭代生成一组伪对应及其置信度 w_i ,然后利用 w_i 对伪对应执行加权SVD分解方式来求解刚性变换矩阵 $\{R, t\}$ 。

2.4 损失函数

在本文中,损失函数如式(24)所示:

$$L_S = L_{\text{glo}} + \lambda L_{\text{loc}} + \eta L_{\text{spa}}, \quad (24)$$

其中: L_S 表示总损失, L_{glo} 表示基于Huber函数的全局对齐损失,能够在存在部分点重叠的情况下稳定优化配准过程,提升整体对齐精度; L_{loc} 表示局部一致性损失,利用学习到的置信度 w_i ,可以通过选择权重最高的 k_0 个点对,从源点云和目标点云中提取出可信点。 L_{spa} 表示空间一致性损失,为进一步消除每个选定的伪目标对应关系和真实目标对应关系之间的空间间隙,利用基于交叉熵的空间一致性损失来优化其匹配分布; λ 和 η 分别表示控制局部一致性和空间一致性损失权重的超参数。

Huber函数计算如下:

$$h_\delta(\nu) = \begin{cases} \frac{1}{2} \nu^2, & \text{if } |\nu| \leq \delta \\ \delta \left(|\nu| - \frac{1}{2} \delta \right), & \text{otherwise} \end{cases}, \quad (25)$$

其中: δ 表示控制内部点范围和异常值配准误差的阈值, ν 表示真实值和预测值之间的差异, $h_\delta(\nu)$ 表示一种用于回归问题的损失函数。

基于Huber函数的全局对齐损失 L_{glo} 定义如下:

$$L_{\text{glo}}(\hat{X}, Y) = \sum_{\hat{x} \in \hat{X}} h_\delta \left(\min_{y \in Y} \|\hat{x} - y\|_2 \right) + \sum_{y \in Y} h_\delta \left(\min_{\hat{x} \in \hat{X}} \|y - \hat{x}\|_2 \right), \quad (26)$$

其中: $\min(\cdot)$ 表示取最小值, $\|\cdot\|_2$ 表示 L_2 范数, $\sum(\cdot)$ 表示累加操作, $\hat{X}$ 表示变换后的源点云, Y 表示目标点云。

局部一致性损失 L_{loc} 定义如下:

$$L_{\text{loc}} = \sum_{\bar{x}_i \in \bar{X}, \bar{y}_i \in \bar{Y}} \sum_{\bar{x}_j' \in N_{\bar{x}_i}, \bar{y}_j' \in N_{\bar{y}_i}} \|R \cdot \bar{x}_j' + t - \bar{y}_j'\|_2, \quad (27)$$

其中: $\bar{X}$ 和 $\bar{Y}$ 分别表示源点云和目标点云中的可信点集合, $\bar{x}_i$ 和 $\bar{y}_i$ 分别表示源点云和目标点云中的可信点, $N_{\bar{x}_i}$ 和 $N_{\bar{y}_i}$ 分别表示源点云和目标点云中可信点的 k 个近邻点集合, $\bar{x}_j'$ 和 $\bar{y}_j'$ 分别表示源点云和目标点云中可信点的近邻点, R 表示旋转矩阵, t 表示平移向量。

空间一致性损失 L_{geo} 定义如下:

$$L_{\text{geo}} = -\frac{1}{|\bar{X}|} \sum_{X_i \in \bar{X}} \sum_{j=1}^M \left\{ j = \arg \max_{j'} A'_{i,j'} \right\} \log A'_{i,j}, \quad (28)$$

其中: $|\bar{X}|$ 表示点云中可信点的个数。 $\{\cdot\}$ 表示指示函数, A' 表示匹配矩阵。

3 实验及结果分析

3.1 实验环境及参数设置

本算法的软件实验环境:操作系统为 Ubuntu, 深度学习框架为 Pytorch, 编程语言为 Python3.8, GPU 的运行环境为 CUDA11.1; 本算法的硬件实验环境:CPU 为 Intel Xeon w5-2455X (3.2 GHz), 显卡为 NVIDIA RTX A5000 (24 GB)。该算法在训练时采用 Adam 优化器, 初始学习率设为 0.001, Batchsize 大小设为 2, epoch 为 100。

3.2 实验数据及预处理

为了验证算法的有效性, 本文选用了 5 个具有代表性的数据集, 包括 ModelNet40^[37], 7Scenes^[38], ICL-NUIM^[39], KITTI^[40] 和 ScanObjectN^[41]。ModelNet40 数据集由美国普林斯顿大学所创建, 是一个被广泛用于点云配准任务的数据集, 包含 40 个不同类别, 有 12 311 个 CAD 模型, 例如桌子、马桶、花瓶、椅子、花等。每个模型选取 1 024 个点, 通过降采样得到 768 个点。

7Scenes 数据集由英国微软剑桥研究院创建, 是一个小型但高质量的室内场景数据集, 包含了 7 个不同的室内环境, 如厨房、卧室等, 共有 353 个样本, 每个点云样本随机采样 2 048 个点,

通过降采样得到 1 536 个点。ICL-NUIM 数据集由英国帝国理工学院创建, 涵盖了办公室、实验室和走廊等室内环境, 共有 1 478 个样本, 每个点云样本随机采样 2 048 个点, 通过降采样得到 1 536 个点。7Scenes 和 ICL-NUIM 均来源于真实室内环境, 包含视角变化、遮挡和光照不均等因素, 普遍存在异常点和部分点重叠问题, 同时场景中重复结构较多, 容易引发非对应相似点误匹配。

KITTI 数据集由德国卡尔斯鲁厄理工学院和丰田美国技术研究院共同创建, 包含 11 个激光雷达扫描序列, 共有 23 190 个样本, 每个点云样本随机采样 2 048 个点。该数据集场景多样且复杂, 含有动态目标和反射误差导致的异常点, 且点云帧间存在不完全重叠现象。

ScanObjectNN 数据集由中国香港科技大学创建, 是一个基于真实扫描生成的室内物体点云数据集, 涵盖多类常见物品, 共有 2 890 个样本, 每个点云样本随机采样 1 024 个点, 通过降采样得到 768 个点。数据中包含扫描误差、背景残留、遮挡缺失等噪声因素, 并常伴随几何结构相似的非真实对应点。

3.3 评价指标

为了量化点云配准效果, 本文采用了两种常见的评价指标: 均方根误差 (Root Mean Square Error, RMSE) 和平均绝对误差 (Mean Absolute Error, MAE)。考虑到刚性变换矩阵包括旋转和位移两个主要成分, 故本文将分别对旋转矩阵 R 和平移向量 t 进行独立评估。相关评价指标的计算公式如下所示:

$$RMSE(R) = \sqrt{\frac{1}{m} \sum_{i=1}^m (R_{\text{pre}} - R_{\text{gt}})_i^2}, \quad (29)$$

$$RMSE(t) = \sqrt{\frac{1}{m} \sum_{i=1}^m (t_{\text{pre}} - t_{\text{gt}})_i^2}, \quad (30)$$

其中: $RMSE(R)$ 表示旋转矩阵预测值与真实值的均方根误差, $RMSE(t)$ 表示平移向量预测值与真实值的均方根误差, R_{pre} 和 t_{pre} 分别表示旋转和平移的预测结果, R_{gt} 和 t_{gt} 旋转和平移的真实结果, m 表示点云配准后的点云个数。

$$MAE(R) = \frac{1}{m} \sum_{i=1}^m \|R_{\text{pre}} - R_{\text{gt}}\|_1, \quad (31)$$

$$MAE(t) = \frac{1}{m} \sum_{i=1}^m \|t_{\text{pre}} - t_{\text{gt}}\|_1, \quad (32)$$

其中: $MAE(R)$ 表示旋转矩阵预测值与真实值的平均绝对误差, $MAE(t)$ 表示平移向量预测值与真实值的平均绝对误差, $\|\cdot\|_1$ 表示 L_1 范数。在上述评价指标中, $RMSE$ 以及 MAE 评价指标的数值越小,表明配准的精度越高。

3.4 实验结果分析

3.4.1 各算法的配准精度

为评估本算法的配准精度,本文将其与传统经典配准算法 ICP^[9],FGR^[42],SDRSAC^[43]以及基于深度学习的配准算法 DCP^[15],IDAM^[44],FINet^[29],FMR^[22],CEMNet^[25],RIENet^[24],IFNet^[28]进行了对比。在 ModelNet40,7Scenes,ICL-NUIM,KITTI 和 ScanObjectNN 数据集上进行相关实验,并提供了相应的可视化结果,源点云和目标点云分别以绿色和红色表示(彩图见期刊电子版)。

为了检验模型的性能,在具有相同类别的 ModelNet40 数据集上进行验证,使用 40 个类别进行训练与测试,共有 12 311 个 CAD 模型,其中 9 843 个 CAD 模型用于训练,2 468 个 CAD 模型用于测试。在表 1 中,IFNET^[28]算法的实验结果为本文复现,ICP^[9],FGR^[42],SDRSAC^[43],DCP^[15],IDAM^[44],FINet^[29],FMR^[22],CEMNet^[25],RIENet^[24]算法的实验结果来自参考文献[28]。本算法和其他先进算法相比,在性能上均有提高,其 $RMSE(R)$ 为 0.007 2, $MAE(R)$ 为

0.005 9,相对于 IFNet^[28]算法分别减少 0.003 9 和 0.002 7,体现出更高的配准精度与更强的鲁棒性。

为了进一步验证本文所提出的配准算法的性能,在 7Scenes 和 ICL-NUIM 两个公开数据集上进行实验。其中,7Scenes 数据集包含 353 个样本,选取其中 296 个样本用于训练,57 个样本用于测试;ICL-NUIM 数据集包含 1 478 个样本,其中 1 278 个样本用于训练,200 个样本用于测试。与 ModelNet40 数据集相比,这两个数据集具有更复杂和真实的场景。为了保证实验的公平性,本文算法采用的训练集和测试集与其他算法相同。将本文算法和其他经典算法进行比较,表 2 和表 3 中的 IFNET^[28]算法的实验结果为本文复现,其他算法的实验结果来自参考文献[28]。表 2 和表 3 分别表示在 7SCENES 和 ICL-NUIM 数据集上不同算法的实验结果。表 2 中,本文算法相较于 IFNet^[28]算法, $RMSE(R)$ 和 $MAE(R)$ 分别减少了 23.72% 和 21.11%;表 3 中,本文算法相较于 IFNet^[28]算法, $RMSE(R)$ 和 $MAE(R)$ 分别减少了 19.76% 和 18.22%,反映出了本文算法对刚性变换参数估计的整体稳定性和有效性。此外,与 CEMNet^[25]算法相比,本文算法在多个指标上表现更优, $RMSE(R)$ 和 $MAE(R)$ 分别减少了 0.772 8,0.189 4;但在 $RMSE(t)$ 和 $MAE(t)$ 上略逊一筹,这一现象主要源于模型在加强旋转特征表达过程中对特征分布的敏感性增强,进而

表 1 各算法在 ModelNet40 数据集(相同类别)上的性能比较

Tab. 1 Performance comparison of various algorithms on the ModelNet40 dataset(same category)

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
ICP	33.684 2	25.053 7	0.291 2	0.252 4
FGR	3.705 5	0.597 2	0.008 8	0.002 0
SDRSAC	3.917 3	2.795 6	0.012 1	0.010 2
DCP	6.649 8	4.847 2	0.027 3	0.021 5
IDAM	2.461 2	0.561 8	0.016 7	0.003 5
FINet	1.463 1	0.642 7	0.011 2	0.006 8
FMR	9.099 7	3.649 7	0.020 4	0.010 1
CEMNet	1.501 8	0.138 5	0.000 9	0.000 1
RIENet	0.024 6	0.012 0	0.000 1	0.000 0
IFNet	0.011 1	0.008 6	0.000 0	0.000 0
Ours	0.007 2	0.005 9	0.000 0	0.000 0

表 2 各算法在 7SCENES 数据集上的性能比较

Tab. 2 Performance comparison of various algorithms on the 7SCENES dataset

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
ICP	19.916 6	7.576 0	0.112 7	0.031 0
FGR	0.272 4	0.138 0	0.001 1	0.000 6
SDRSAC	0.350 1	0.292 5	0.499 7	0.499 7
DCP	7.554 8	5.699 1	0.041 1	0.030 3
IDAM	10.530 6	5.672 7	0.053 9	0.030 3
FINet	1.782 4	0.903 8	0.009 4	0.005 1
FMR	8.699 9	3.656 9	0.019 9	0.010 1
CEMNet	0.176 8	0.043 4	0.001 2	0.000 2
RIENet	0.018 8	0.013 1	0.000 2	0.000 1
IFNet	0.011 8	0.009 0	0.000 1	0.000 1
Ours	0.009 0	0.007 1	0.000 0	0.000 0

表 3 各算法在 ICL-NUIM 数据集上的性能比较

Tab. 3 Performance comparison of various algorithms on the ICL-NUIM dataset

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
ICP	10.124 7	2.148 4	0.300 6	0.069 3
FGR	3.042 3	1.957 1	0.127 5	0.065 9
SDRSAC	9.407 4	7.862 7	0.247 7	0.207 6
DCP	9.214 2	6.582 6	0.019 1	0.013 4
IDAM	9.453 9	4.415 3	0.304 0	0.138 5
FINet	2.873 1	1.187 5	0.127 3	0.051 7
FMR	1.828 2	1.108 5	0.068 5	0.039 8
CEMNet	0.827 2	0.231 6	0.002 1	0.001 0
RIENet	0.111 5	0.079 2	0.004 8	0.003 4
IFNet	0.067 8	0.051 6	0.004 6	0.003 6
Ours	0.054 4	0.042 2	0.003 0	0.002 4

在部分样本中引发轻微的平移偏差。总体而言,该策略有效提升了旋转配准精度,在实际配准任务中具有更高的应用价值。

为了验证本算法在大规模动态场景中的配准性能,本文采用 KITTI 数据集进行实验,将序列 00-05 作为训练集,序列 06-07 作为验证集,序列 08-10 作为测试集。其中,训练集共包含 14 130 个样本,验证集包含 2 200 个样本,测试集包含 6 860 个样本。将本文算法与其他经典算法进行对比,IFNet^[28] 算法的实验结果为本文复现,ICP^[9],FGR^[42],SDRSAC^[43],DCP^[15],IDAM^[44],FINet^[29],FMR^[22]和 RIENet^[24]等算法的实验结果来自参考文献[28]。从表 4 的实验结

表 4 各算法在 KITTI 数据集上的性能比较

Tab. 4 Performance comparison of various algorithms on the KITTI dataset

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
ICP	19.736 2	4.035 5	1.849 3	0.912 4
FGR	8.259 8	1.698 6	0.079 4	0.037 5
SDRSAC	7.305 0	1.603 7	0.068 8	0.028 9
DCP	10.330 3	2.295 3	0.098 5	0.053 2
IDAM	7.412 4	1.575 1	0.062 0	0.027 1
FINet	6.210 6	1.463 8	0.057 8	0.034 8
FMR	9.736 2	1.680 9	0.084 8	0.030 5
RIENet	5.518 0	0.884 0	0.045 7	0.016 2
IFNet	2.081 9	1.016 8	0.030 1	0.019 1
Ours	1.862 7	0.935 3	0.026 7	0.017 2

果可以看出,本文算法在性能上有所提升,其中 $RMSE(R)$ 和 $MAE(R)$ 分别比 IFNet^[28] 算法减少了 10.53% 和 8.02%, $RMSE(t)$ 减少了 11.30%, $MAE(t)$ 减少了 9.95%,表明所提出方法在刚体变换估计中具有更高的配准精度和更好的鲁棒性。相较于 RIENet^[24] 算法,本文算法在 $MAE(R)$ 和 $MAE(t)$ 指标上略逊一筹,但整体误差仍处于较低水平,显示出本文算法在大规模户外动态场景中的良好适应能力与实际应用潜力。

为了充分验证本文算法的有效性,采用 ScanObjectNN 数据集进行实验,该数据集共有 2 890 个样本,其中训练集包含 2 309 个样本,测试集包含 581 个样本。将本文算法与 FMR^[22],CEMNet^[25],RIENet^[24]和 IFNet^[28] 算法进行性能对比,上述对比算法的实验结果均为本文复现,从表 5 的实验结果可以看出,本文算法的 $RMSE(R)$ 和 $MAE(R)$ 分别比 IFNet^[28] 算法减少了 21.05% 和 17.54%,在 $RMSE(t)$ 和 $MAE(t)$ 方面亦有一定幅度的下降,进一步验证了所提算法在真实场景点云配准任务中的有效性与可靠性。

表 5 各算法在 ScanObjectNN 数据集上的性能比较

Tab. 5 Performance comparison of various algorithms on the ScanObjectNN dataset

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
FMR	4.702 8	0.932 8	0.016 0	0.010 5
CEMNet	2.032 1	0.347 4	0.012 1	0.007 8
RIENet	0.109 2	0.046 9	0.001 3	0.000 6
IFNet	0.080 3	0.028 5	0.001 1	0.000 2
Ours	0.063 4	0.023 5	0.000 4	0.000 1

3.4.2 各算法的可视化效果

为了更清晰地展示不同算法的配准效果,本文通过可视化对比了所提出算法与 RIENet^[24],IFNet^[28] 在 ModelNet40, 7Scenes, ICL-NUIM 和 KITTI 等数据集部分场景中的配准结果,如图 7~图 9 和图 10 所示。以图 7 为例,展示了各算法在 ModelNet40 数据集中花瓶和马桶场景的可视化效果,第一列为输入的源点云与目标点云,其余列依次展示 RIENet^[24] 算法、IFNet^[28] 算法、本文算法和真实变换 (Ground Truth, GT) 的配准结果。




图 7 各算法在 ModelNet40 数据集上的部分样本可视化结果

Fig. 7 Visualization results of some samples from each algorithm on the ModelNet40 dataset




图 8 各配准算法在 7SCENES 数据集上的部分样本可视化结果

Fig. 8 Visualization results of some samples from each algorithm on the 7SCENES dataset




图 9 各算法在 ICL-NUIM 数据集上的部分样本可视化结果

Fig. 9 Visualization results of some samples from each algorithm on the ICL-NUIM dataset

图 7 中的结果显示,本文算法在多个场景中表现出较优的配准效果,点云轮廓与目标点云对齐较为紧密,整体视觉效果更接近 GT。与 GT 相比,RIENet^[24]与 IFNet^[28]在第一行右上角区域

均未实现准确对齐,尽管在第二行右下角区域的偏差相对较小,但与 GT 结果仍存在一定差异。相较之下,本文算法在第一行和第二行的关键区域均呈现出更为接近 GT 的配准效果。总体来




图 10 各算法在KITTI数据集上的部分样本可视化结果

Fig. 10 Visualization results of some samples from various algorithms on the KITTI dataset

看,本文算法在多个复杂场景中展现出更高的配准精度与空间对齐能力,充分验证了其有效性与鲁棒性。图8展示了本文算法在7Scenes数据集上部分样本的配准可视化结果。与GT对比可见,RIENet^[24]和IFNet^[28]算法的配准结果在左上角区域仍存在显著的点云错位,放大图进一步揭示了这些区域内的误匹配现象;相比之下,本文算法的配准结果在整体对齐精度和细节匹配方面表现更优。

图9展示了本文算法在ICL-NUIM数据集上的部分样本可视化效果。通过与GT的对比可见,RIENet^[24]和IFNet^[28]在第一行图的右下角区域和第二行图的右上角区域与GT较为接近,但在细节层面仍存在一定程度的局部错位;本文算法在这些关键区域中表现出更高的对齐精度,点云匹配效果更为贴合GT,体现了其在细粒度配准能力方面的优势。图10展示了本文算法在KITTI数据集上的部分样本配准可视化结果。该数据集点云场景复杂、动态变化显著。RIENet^[24]和IFNet^[28]在第一行图像的正上方区域和第二行图像的右下角区域存在一定配准误差;相比之下,本文算法在整体形态上与GT更为一致,配准效果优于其他对比方法,进一步验证了其在真实复杂场景下的鲁棒性与有效性。

3.4.3 各算法的泛化性实验

为了验证本文算法的模型的泛化性能,本文在具有未知类别的ModelNet40数据集上进行了实验,采用前20个类别进行训练,后20个类别进行测试,从而检测在未知类别数据中的模型表现。实验结果如表6所示,IFNet^[28]算法的实验结

果为本文复现,ICP^[9],FGR^[42],SDRSAC^[43],DCP^[15],IDAM^[44],FINet^[29],FMR^[22],CEMNet^[25],RIENet^[24]算法的实验结果来自参考文献[28]。本文算法 $RMSE(R)$ 为0.0086, $MAE(R)$ 为0.0065,相较于IFNet^[28]算法分别减少23.21%和26.96%。实验结果显示,尽管深度学习方法在处理未知类别点云数据时精度有所下降,本文算法仍能保持较好的性能,验证了其较强的泛化能力。

表6 各算法在ModelNet40数据集(未知类别)上的性能对比

Tab. 6 Performance comparison of various algorithms on the ModelNet40 dataset(unknown category)

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
ICP	34.274 4	25.637 8	0.292 4	0.251 9
FGR	3.125 1	0.446 9	0.007 4	0.001 3
SDRSAC	4.247 5	3.014 4	0.013 9	0.012 1
DCP	9.837 4	6.645 8	0.033 8	0.025 2
IDAM	3.042 5	0.616 0	0.019 7	0.004 8
FINet	2.391 5	0.801 5	0.010 5	0.004 5
FMR	9.132 2	3.859 3	0.023 3	0.011 3
CEMNet	1.101 3	0.080 4	0.002 0	0.000 2
RIENet	0.029 8	0.011 0	0.000 2	0.000 1
IFNet	0.011 2	0.008 9	0.000 1	0.000 0
Ours	0.008 6	0.006 5	0.000 0	0.000 0

3.4.4 各算法的抗噪性实验

噪声是点云配准中的常见干扰因素,通常来源于传感器误差、数据采集环境或外部环境变

化。为了评估本文算法在噪声环境下的鲁棒性,本文对模型进行了抗噪性测试。为模拟噪声影响,实验在具有相同类别 ModelNet40 数据集上进行训练,然后在测试部分中引入了标准偏差为 0.5 的随机高斯噪声,并对噪声进行裁剪,范围限定为 $[-1, 1]$ 。数据集的划分方式与相同类别的 ModelNet40 保持一致,以确保实验设置的可比性与一致性。在该噪声条件中,实验结果如表 7 所示,IFNet^[28] 算法的实验结果为本文复现,ICP^[9],FGR^[42],SDRSAC^[43],DCP^[15],IDAM^[44],FINet^[29],FMR^[22],CEMNet^[25],RIENet^[24] 算法的实验结果来自参考文献[28]。本文算法在该噪声条件下的 $RMSE(R)$ 为 0.016 2, $MAE(R)$ 为 0.006 8,相较于 IFNet^[28],本文算法的 $RMSE(R)$ 和 $MAE(R)$ 分别减少了 31.93% 和 29.89%,表明本文算法在复杂现实环境中的应用潜力。

表 7 各算法在 ModelNet40 数据集(含噪声)上的性能对比
Tab. 7 Performance comparison of various algorithms on the ModelNet40 dataset(with noise)

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
ICP	30.501 8	24.012 1	0.239 1	0.218 4
FGR	4.579 8	1.217 3	0.018 6	0.005 1
SDRSAC	3.835 1	3.061 9	0.014 2	0.012 8
DCP	16.406 8	13.356 3	0.112 0	0.088 7
IDAM	13.272 5	11.125 6	0.083 1	0.066 1
FINet	2.517 1	1.700 0	0.016 3	0.012 4
FMR	8.369 8	3.939 0	0.029 1	0.029 1
CEMNet	3.247 7	0.404 7	0.007 6	0.001 3
RIENet	0.100 3	0.038 6	0.000 4	0.000 2
IFNet	0.023 8	0.009 7	0.000 1	0.000 1
Ours	0.016 2	0.006 8	0.000 0	0.000 0

3.4.5 各算法的实时性实验

为了验证本文算法的实时性,本文在 7Scenes 数据集的测试集上进行了实验。在每个样本中提取了 1 536 个点,并使用这些提取的点云对算法进行测试。表 8 展示了不同算法的平均运行时间,其中 ICP^[9],FMR^[22],RIENet^[24] 和 IFNet^[28] 的实验结果均来自文献[36]。ICP^[9] 是传统的优化配准算法,而 FMR^[22],RIENet^[24] 和 IFNet^[28] 则是基于深度学习的无监督配准算法。从表 8 可以看出,基于深度学习的算法在推理时间

上表现出一定优势,这主要归因于其端到端的特征提取与配准机制,实现了高效且快速的点云对齐处理。本文所提出的算法在实时性方面表现优异,与当前最优算法在实时性上几乎持平。这表明,本文算法不仅在配准精度上有优势,同时在实时性方面也较好。

表 8 各算法的实时性能对比
Tab. 8 Comparison of real-time performance of various algorithms (s)

Method	ICP	FMR	RIENet	IFNet	Ours
Time	0.458 2	0.428 6	0.428 6	0.423 1	0.423 5

3.5 消融实验

为了验证本文算法各改进模块的有效性,本文在 7SCENES,ICL-NUIM 和 KITTI 数据集上进行了消融实验,实验的训练集和测试集划分与本文文 3.4.1 节相同。Method1 表示采用基准网络 IFNet;Method2 表示在 Method1 基础上,将特征融合模块应用于所提出的网络中;Method3 表示在 Method2 的基础上加入图卷积-Transformer 融合模块;Method4 即本文所提出的方法,表示在 Method3 的基础上加入点匹配增强模块。

本文在表 9~表 11 中展示了消融实验的结果。与基准模型 Method1 相比,Method2 在三个数据集上普遍表现出更好的性能。例如,在 7SCENES 数据集上,Method2 的 $RMSE(R)$ 和 $MAE(R)$ 分别较 Method1 降低了 0.000 7 和 0.000 6,这有力证明了特征融合模块在深度信息交换、扩大感受野和减少异常点干扰等方面发挥了积极作用。Method3 的各项评价指标进一步优化,尤其是在 ICL-NUIM 数据集上, $RMSE(R)$ 和 $MAE(R)$ 分别较 Method2 降低了 0.0049 和 0.003 9, $RMSE(t)$ 和 $MAE(t)$ 较 Method2 降低了 0.000 5 和 0.000 2。这表明,改进的图卷积-Transformer 融合模块能够有效捕获并充分利用局部与全局信息,从而缓解点云部分重叠导致的信息丢失问题,提升了配准精度。更值得注意的是,作为集成所有改进模块的最终方案,Method4 在三个数据集上均实现了显著的性能提升。例如,在 KITTI 数据集上, $RMSE(R)$ 和 $MAE(R)$ 分别较 Method3 降低了 0.050 9 和 0.023 3, $RMSE(t)$ 和 $MAE(t)$ 则分别降低了 0.001 2 和

表 9 在 7SCENES 数据集上的消融实验结果

Tab. 9 Results of ablation experiments on the 7SCENES dataset

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
Method1	0.011 8	0.009 0	0.000 1	0.000 1
Method2	0.011 1	0.008 4	0.000 1	0.000 1
Method3	0.009 9	0.007 8	0.000 1	0.000 0
Method4	0.009 0	0.007 1	0.000 0	0.000 0

表 10 在 ICL-NUIM 数据集上的消融实验结果

Tab. 10 Results of ablation experiments on the ICL-NUIM dataset

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
Method1	0.067 8	0.051 6	0.004 6	0.003 6
Method2	0.062 2	0.048 6	0.003 6	0.002 8
Method3	0.057 3	0.044 7	0.003 1	0.002 6
Method4	0.054 4	0.042 2	0.002 9	0.002 4

表 11 在 KITTI 数据集上的消融实验结果

Tab. 11 Results of ablation experiments on KITTI dataset

Method	$RMSE(R)$	$MAE(R)$	$RMSE(t)$	$MAE(t)$
Method1	2.081 9	1.016 8	0.030 1	0.019 1
Method2	1.972 6	0.982 7	0.029 6	0.018 9
Method3	1.913 6	0.958 6	0.027 9	0.018 1
Method4	1.862 7	0.935 3	0.026 7	0.017 2

0.000 9。这一结果表明,点匹配增强模块在度量点对相似性和减少错误匹配方面起到了关键作用,有效降低了因非对应相似点特征引起的配准误差。综上所述,本文设计的各模块在不同程度上提升了网络的整体性能,验证了每个改进模块的有效性。

参考文献:

[1] ZHOU R Q, WANG P, DAI C G, *et al.* Status and progress of deep learning-based pairwise point cloud rigid registration[J]. *National Remote Sensing Bulletin*, 2024, 28(12): 3074-3093.

[2] 许梦兵,刘先林,仲雪婷,等. 结合地面点和杆状物的车载激光点云自动配准方法[J]. *中国激光*, 2023, 50(2): 107-121.

4 结 论

本文提出了一种融合特征交互与点匹配增强的无监督点云配准算法,设计了三个关键模块以提升配准性能:特征交互融合模块通过多尺度特征引导与局部结构融合,有效抑制异常点干扰;图卷积-Transformer 融合模块获取局部几何与全局上下文信息,增强对重叠与遮挡的适应性;点匹配增强模块通过软匹配与邻域结构相结合,减少非对应相似点影响。在 ModelNet40(含噪声),7Scenes,ICL-NUIM,KITTI 与 ScanObjectNN 等数据集上验证了算法的性能,与 IFNet 算法相比,本文方法在多个指标上取得了显著提升,其中,在 7Scenes 数据集上, $RMSE(R)$ 和 $MAE(R)$ 分别下降 23.72% 和 21.11%;在 ICL-NUIM 数据集上, $RMSE(R)$ 与 $MAE(R)$ 分别下降 19.76% 和 18.22%,展现出良好的应用潜力。然而,该算法在处理大规模点云场景时仍存在计算开销大、处理效率受限等挑战。未来工作将针对大规模点云场景的要求,重点设计轻量高效的网络结构并结合动态点云处理方法,以提升算法在此类场景下的鲁棒性与实用性,进一步拓展其应用范围。

作者贡献说明:

易见兵:负责配准算法方案的整体构建,参与论文的撰写与审核工作;

熊文武:提出配准算法,负责实验设计、数据整理与分析,论文撰写;

彭鑫:参与实现论文中的部分核心代码模块;

吴欣:协助实验数据的整理与结果分析工作。

XU M B, LIU X L, ZHONG X T, *et al.* Automatic registration method of vehicle-borne laser point cloud combining ground points and rods[J]. *Chinese Journal of Lasers*, 2023, 50(2): 107-121. (in Chinese)

[3] LI Z H, WANG M N. Rigid point cloud registration based on correspondence cloud for image-to-patient registration in image-guided surgery[J]. *Medical Physics*, 2024, 51(7): 4554-4566.

- [4] 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 L, BAI F, ZHANG J, *et al.* Vehicle localization and navigation method based on LiDAR point cloud map[J]. *Opt. Precision Eng.*, 2024, 32(16): 2537-2549. (in Chinese)
- [5] BIAN X, ZHAO W Q, TANG L, *et al.* An enhanced particle filtering method leveraging particle swarm optimization for simultaneous localization and mapping in mobile robots navigating unknown environments[J]. *Applied Sciences*, 2024, 14(20): 9426.
- [6] YAN C B, FENG M T, WU Z J, *et al.* Discriminative correspondence estimation for unsupervised RGB-D point cloud registration[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2025, 35(2): 1209-1223.
- [7] GUO Y F, LIU J K, MA Y S, *et al.* Deep learning-based topology optimization for multi-axis machining[J]. *Applied Mathematical Modelling*, 2025, 138: 115738.
- [8] GAO J, ZHANG Y H, HU J H, *et al.* IOPCNet: inner and outer point classification based low overlap rate local-to-global point cloud registration[J]. *Multimedia Systems*, 2025, 31(2): 109.
- [9] HUANG J G, TAO B, ZENG F. Point cloud registration algorithm based on ICP algorithm and 3D-NDT algorithm[J]. *International Journal of Wireless and Mobile Computing*, 2022, 22(2): 125.
- [10] YI H, HU L M, CHEN F, *et al.* Iterative closest point via MultiKernel correntropy for point cloud fine registration[J]. *IEEE Signal Processing Letters*, 2025, 32: 766-770.
- [11] 汪千金, 崔海华, 张益华, 等. 面向光学测量跨源点云的多尺度采样配准方法[J]. 光学学报, 2022, 42(10): 139-148.
- WANG Q J, CUI H H, ZHANG Y H, *et al.* Multi-scale sampling registration method for optical measurement of cross-source point clouds[J]. *Acta Optica Sinica*, 2022, 42(10): 139-148. (in Chinese)
- [12] 余永维, 王康, 杜柳青, 等. 点云模型的匹配点对优化配准[J]. 光学精密工程, 2023, 31(4): 503-516.
- YU Y W, WANG K, DU L Q, *et al.* Matching point pair optimization registration method for point cloud model[J]. *Opt. Precision Eng.*, 2023, 31(4): 503-516. (in Chinese)
- [13] CHARLES R Q, HAO S, MO K C, *et al.* PointNet: deep learning on point sets for 3D classification and segmentation[C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 77-85.
- [14] QI C R, YI L, SU H, *et al.* Pointnet++: Deep Hierarchical Feature Learning on Point Sets in A Metric Space [EB/OL]. (2017-6-7)[2025-2-19]. <https://doi.org/10.48550/arXiv.1706.02413>.
- [15] WANG Y, SOLOMON J. Deep closest point: learning representations for point cloud registration[C]. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 27 - November 2, 2019, Seoul, Korea (South). IEEE, 2019: 3522-3531.
- [16] YANG X, YIN X, WANG N N, *et al.* Associative graph convolution network for point cloud analysis[J]. *Pattern Recognition*, 2025, 159: 111152.
- [17] 甄昊天, 常令琛, 祝继华, 等. 局部特征与点云配准引导下的神经元相似性度量方法[J]. 计算机辅助设计与图形学学报, 2024, 36(9): 1480-1490.
- ZHEN H T, CHANG L C, ZHU J H, *et al.* Neuron similarity measurement method guided by local feature and point cloud registration[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2024, 36(9): 1480-1490. (in Chinese)
- [18] CHOY C, PARK J, KOLTUN V. Fully convolutional geometric features[C]. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 27-November 2, 2019, Seoul, Korea (South). IEEE, 2019: 8957-8965.
- [19] BASHIR S, AHMAD D. Geometric analysis of non-degenerate shifted-knots Bézier surfaces in Minkowski space[J]. *PLoS One*, 2024, 19(1): e0296365.
- [20] DU J, BAI Z Y, LIU X H, *et al.* Fusion of Geometric attention and multi-scale feature network for point cloud registration[J]. *Computer Engineering and Applications*, 2024, 60(12): 234-244.
- [21] SARODE V, LI X Q, GOFORTH H, *et al.* Pcnnet: Point Cloud Registration Network Using Pointnet Encoding [EB/OL]. (2019-8-21)[2025-2-19]<https://doi.org/10.48550/arXiv.1908.07906>.
- [22] HUANG X S, MEI G F, ZHANG J. Feature-

- metric registration: a fast semi-supervised approach for robust point cloud registration without correspondences [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020. Seattle, WA, USA. IEEE, 2020: 11363-11371.
- [23] 易见兵, 陈鑫, 曹锋, 等. 重叠分数与匹配矩阵驱动的部分重叠点云配准网络设计[J]. 光学精密工程, 2024, 32(22): 3366-3382.
- YI J B, CHEN X, CAO F, *et al.* Design of partial overlap point cloud registration network driven by overlap score and matching matrix [J]. *Opt. Precision Eng.*, 2024, 32 (22): 3366-3382. (in Chinese)
- [24] SHEN Y Q, HUI L, JIANG H B, *et al.* Reliable inlier evaluation for unsupervised point cloud registration [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, 36 (2): 2198-2206.
- [25] JIANG H B, SHEN Y Q, XIE J, *et al.* Sampling network guided cross-entropy method for unsupervised point cloud registration [C]. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 10-17, 2021, Montreal, QC, Canada. IEEE, 2021: 6108-6117.
- [26] HEIDARI A, JABRAEIL JAMALI MALI, NAVIMIPOUR N J, *et al.* A QoS-aware technique for computation offloading in IoT-edge platforms using a convolutional neural network and Markov decision process [J]. *IT Professional*, 2023, 25(1): 24-39.
- [27] 杨佳琪, 张世坤, 范世超, 等. 多视图点云配准算法综述[J]. 华中科技大学学报(自然科学版), 2022, 50(11): 16-34, 43.
- YANG J Q, ZHANG S K, FAN S C, *et al.* Survey on multi-view point cloud registration algorithm [J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2022, 50(11): 16-34, 43. (in Chinese)
- [28] 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.
- [29] 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.
- [30] WU B L, MA J, CHEN G J, *et al.* Feature interactive representation for point cloud registration [C]. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 10-17, 2021, Montreal, QC, Canada. IEEE, 2021: 5510-5519.
- [31] ZHANG J, YE L L, GONG W W, *et al.* A novel network for low-dose CT denoising based on dual-branch structure and multi-scale residual attention [J]. *Journal of Imaging Informatics in Medicine*, 2025, 38(2): 1245-1264.
- [32] CAO H Y, CHEN D, ZHANG Y D, *et al.* MFI-Net: a multi-scale feature interaction network for point cloud registration [J]. *The Visual Computer*, 2025, 41(6): 4067-4079.
- [33] CHEN X Y, LUO J H, REN Y, *et al.* MAFNet: a two-stage multiple attention fusion network for partial-to-partial point cloud registration [J]. *Measurement Science and Technology*, 2024, 35(12): 125113.
- [34] WANG Y, ZHOU P B, GENG G H, *et al.* Low-overlap point cloud registration with transformer [J]. *IEEE Signal Processing Letters*, 2024, 31: 1469-1473.
- [35] QIN Z, YU H, WANG C, *et al.* Geometric Transformer for fast and robust point cloud registration [C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 18-24, 2022, New Orleans, LA, USA. IEEE, 2022: 11133-11142.
- [36] ZHENG C Y, MA M J, CHEN Z L, *et al.* RegFormer: unsupervised point cloud registration via geometric local-to-global transformer and self-augmentation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5705313.
- [37] WU Z R, SONG S R, KHOSLA A, *et al.* 3D ShapeNets: a deep representation for volumetric shapes [C]. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 7-12, 2015, Boston, MA, USA. IEEE, 2015: 1912-1920.
- [38] SHOTTON J, GLOCKER B, ZACH C, *et al.* Scene coordinate regression forests for camera relocalization in RGB-D images [C]. 2013 *IEEE Conference on Computer Vision and Pattern Recognition*. June 23-28, 2013, Portland, OR, USA.

- IEEE, 2013: 2930-2937.
- [39] CHOI S, ZHOU Q Y, KOLTUN V. Robust reconstruction of indoor scenes[C]. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 7-12, 2015, Boston, MA, USA. IEEE, 2015: 5556-5565.
- [40] GEIGER A, LENZ P, STILLER C, *et al.* Vision meets robotics: the KITTI dataset[J]. *The International Journal of Robotics Research*, 2013, 32(11): 1231-1237.
- [41] UY M A, PHAM Q H, HUA B S, *et al.* Revisiting point cloud classification: a new benchmark dataset and classification model on real-world data [C]. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 27-November 2, 2019, Seoul, Korea (South). IEEE, 2019: 1588-1597.
- [42] ZHOU Q Y, PARK J, KOLTUN V. Fast global registration [C]. *Proceedings of the 14th European Conference on Computer Vision, Amsterdam, The Netherlands*. Berlin: Springer, 2016: 766-782.
- [43] LE H M, DO T T, HOANG T, *et al.* SDRSAC: semidefinite-based randomized approach for robust point cloud registration without correspondences [C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019, Long Beach, CA, USA. IEEE, 2019: 124-133.
- [44] 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*[M]. Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 378-394.

作者简介:



易见兵(1980—),男,江西宜春人,博士,副教授,硕士生导师,2017年于深圳大学获得博士学位,主要从事计算机视觉、图像配准、高性能计算等方面的研究。E-mail: yijianbing8@jxust.edu.cn

作者简介:



熊文武(1999—),男,江西宜春人,硕士研究生,2023年于江西理工大学获得学士学位,主要从事计算机视觉、点云配准等方面的研究。E-mail: 1969114043@qq.com