文章编号:1674-2974(2026)04-0052-10 DOI:10.16339/j.cnki.hdxbzkb.2026266

基于AFAM机制的鲁棒点云配准方法

林俊亭[1,2†],陈宇[1],邹吉平[1]
(1. 兰州交通大学 自动化与电气工程学院,甘肃 兰州 730070;
2. 中国铁道科学研究院集团有限公司国家铁路智能交通系统工程技术研究中心,北京 100081)

摘 要:针对点云配准现有方法在处理含噪声点云时鲁棒性不足、特征表达不准确以及对初始对齐敏感等问题,提出了一种新型点云配准网络结构(robust point matching with adaptive feature aggregation module network, RPM-AFAMNet),该网络是在RPM-Net网络上集成自适应特征聚合模块(adaptive feature aggregation module, AFAM)构建而成的.其中,AFAM由批次注意力机制(batch attention mechanism transformer, BatchFormer)和动态重聚合特征表示模块(dynamic re-aggregated feature representation, DRFR)组成,在优化点云特征表达的同时,增强了网络的鲁棒性.BatchFormer通过对点云特征进行批量加权学习,从而缓解噪声点的干扰;DRFR模块则通过动态特征重组策略,增强了对点云空间关系的理解,进一步提升了点云配准的精度.最后,在ModelNet40数据集上对网络进行实验,与RPM-Net相比,旋转均方误差降低32.05%,旋转平均绝对误差降低75.86%,平移均方误差降低33.33%,平移平均绝对误差降低77.78%,旋转角度误差降低33.03%,平移距离误差降低36.36%.实验结果表明,该方法能够有效提升含噪声点云的配准性能.

关键词:三维点云配准;深度学习;空间对齐;特征重聚合;噪声过滤
中图分类号:TP391 **文献标志码**:A

Robust point cloud registration method based on AFAM mechanism

LIN Junting[1,2†], CHEN Yu[1], ZOU Jiping[1]
(1. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;
2. Center of National Railway Intelligent Transportation System Engineering and Technology, China Academy of Railway Sciences Corporation Limited, Beijing 100081, China)

Abstract: In addressing the shortcomings of the existing methodologies for point cloud registration, including inadequate robustness, inaccurate feature representation and sensitivity to initial registration, particularly in the context of noisy point clouds, a novel point cloud registration network structure, RPM-AFAMNet, is proposed. This structure is constructed by integrating an adaptive feature aggregation module (AFAM) within the RPM-Net network. The AFAM is comprised of two modules: the batch attention mechanism transformer (BatchFormer) and the dynamic re-aggregated feature representation (DRFR) module. The purpose of the AFAM is twofold: firstly, to

* **收稿日期**:2025-02-24
基金项目:国家铁路智能运输系统工程技术研究中心开放课题基金资助(RITS2025KF07), Centre of National Railway Intelligent Transportation System Engineering and Technology (RITS2025KF07);国家自然科学基金资助项目(52162050), National Natural Science Foundation of China(52162050)
作者简介:林俊亭(1978—),男,河北海兴人,兰州交通大学教授,博士
† 通信联系人,E-mail:linjt@lzjtu.edu.cn

enhance the robustness of the network, and secondly, to optimise the representation of point cloud features. The BatchFormer is designed to mitigate the interference of noisy points by batch-weighted learning of point cloud features. The DRFR module, meanwhile, enhances the understanding of point cloud spatial relationships through a dynamic feature reorganisation strategy. This, in turn, improves the accuracy of point cloud alignment. Finally, the network is tested on the ModelNet40 dataset and significant improvements are achieved in six evaluation metrics, such as rotational and translational mean square error. Compared with RPM-Net, the following reductions are achieved: 32.05% for rotational mean square error, 75.86% for rotational mean absolute error, 33.33% for translational mean square error, 77.78% for translational mean absolute error, 33.03% for rotation angle error, and 36.36% for translation distance error. The experimental results demonstrate the efficacy of the proposed method in enhancing the registration performance of noise-containing point clouds.

Key words: 3D point cloud registration; deep learning; spatial alignment; feature re-aggregation; noise filtering

近年来，随着微软 Kinect、英特尔 RealSense 和谷歌 Tango 等低成本小型三维传感器的广泛应用，获取高精度三维场景信息的门槛显著降低[1-3]. 这些设备主要包括深度相机、激光雷达和结构光传感器，能够高效捕捉三维信息，为智能设备感知真实世界提供支持，同时也催生了对高效三维数据处理技术的需求[4-6]. 智能设备广泛应用于自动驾驶、医学研究和机器人导航等领域[7-9].

点云作为三维数据的高效表达形式，相较于传统二维图像，能够直接记录物体或场景的三维坐标信息，并具有无规则和无拓扑连接约束的特点. 随着 GPU 计算能力的提升和点云数据规模的扩展，深度学习在点云数据处理中的潜力逐渐显现，尤其是在点云配准领域，深度学习为解决噪声干扰、视角差异及缺失问题提供了新思路.

点云配准是三维点云数据处理中一个基础而关键的问题，其目标是通过求解刚性变换将两组点云对齐，为三维重建、多视图融合等任务提供支持.

例如，最早的经典方法之一是迭代最近点(iterative closest point，ICP)算法，通过迭代优化点对的最近距离来求解刚性变换. 然而，该算法对初始位姿敏感，容易陷入局部最优解[10-12]. 特征度量配准(feature-metric registration，FMR)基于传统的匹配策略，采用优化算法提高点云对齐的精度[13]. 然而，随着应用场景的复杂化，尤其是点云数据中噪声的存在，传统的点云配准方法逐渐暴露出诸多局限性. 因此，如何在噪声干扰、初始对齐精度不高的条件下保持配准的精度和鲁棒性，成为当前点云配准研究的难点之一.

随着深度学习算法的应用，研究者开始探索利用神经网络解决点云配准问题[14]. 例如，鲁棒点匹配(robust point matching，RPM)算法通过引入软分配机制和退火技术，有效提高了配准的鲁棒性[15]. 迭代全局相似点(iterative global similarity point，IGSP)算法，结合点的空间坐标和手工设计的几何特征来计算点对相似度. PointNet-卢卡斯-卡纳德(PointNet-Lucas-Kanade，PointNetLK)算法利用 PointNet 对点云进行全局编码，通过迭代优化全局特征距离实现配准[16]. 点云配准网络(point cloud registration network，PCRNet)进一步用深度网络替代 Lucas-Kanade 算法步骤以增强对噪声的鲁棒性[17]. 此外，深度最近点(deep closest point，DCP)算法提出了基于深度特征提取的点对匹配策略，并通过可微分的奇异值分解(singular value decomposition，SVD)模块求解刚性变换[18]. 重叠掩模网络(overlapping mask network，OMNet)算法能够提升对噪声点的鲁棒性，但依赖于大量的训练数据[19]. 鲁棒图匹配(robust graph matching，RGM)方法引入了几何约束来提升性能，但在噪声数据的情况下，RGM 未能增强模型的适应性[20]. 特征交互网络(feature interaction network，FINet)通过自适应特征融合来提高点云配准的精度，然而在高噪声的环境中性能存在较大的波动[12].

近年来，RPM-Net 的提出为点云配准领域带来了新的突破[21-23]，通过引入端到端的优化方法，在点云配准精度上有所提升，但其缺乏针对噪声的有效处理机制，在实际应用中的鲁棒性仍有待提高.

为了解决上述问题,本文提出了一种新型的网络结构 RPM-AFAMNet. 该网络在 RPM-Net 的基础上,集成了自适应特征聚合模块(adaptive feature aggregation module, AFAM),通过对特征的多层次处理,进一步增强了点云配准的鲁棒性.

1 AFAM模块概述

在点云配准过程中,异常点和噪声会显著降低配准精度.如何在噪声环境下实现高精度点云对齐,已成为学术界和工业界的研究难点.本文提出的AFAM模块,旨在显著提升噪声条件下的点云配准鲁棒性和精度.

AFAM通过深度学习框架内的特征对齐与特征重构机制,减少点云中的噪声点对配准结果的影响.本模块包含两个关键部分:批次注意力机制(batch attention mechanism transformer, BatchFormer)模块和动态重聚合特征表示(dynamic re-aggregation feature representation, DRFR)模块.AFAM不仅注重特征对齐与重构的效果,还特别考虑了点云配准任务中不同特征的显著性.通过在点云特征提取和对齐过程中引入自适应性机制,AFAM能够动态调整对不同特征的权重分配,从而在含噪场景下实现更高的配准精度.实验结果表明,与现有方法相比,AFAM模块在多种噪声条件下均表现出了更强的鲁棒性和更高的配准精度.

1.1 批次注意力机制

为了增强点云特征表达的鲁棒性,本文使用BatchFormer模块来实现批量特征的自适应学习和局部归一化.BatchFormer的核心思想是通过批次级别的特征注意力机制,对点云数据进行局部特征的动态调整,适配不同的点云场景[24].BatchFormer作为AFAM模块的关键组成部分,旨在优化点云特征的表达能力,并为点云配准的后续任务提供更具鲁棒性的特征支持,具体结构如图1所示.

为实现批次特征的自适应学习和局部归一化,BatchFormer模块通过多层次的机制对点云的特征进行处理.源点云和目标点云的混合特征$\boldsymbol{F}\tilde{\boldsymbol{X}}$和$\boldsymbol{F}\tilde{\boldsymbol{Y}}$作为输入被送入BatchFormer.首先,这些特征被划分为包含点云数据的局部几何信息和空间坐标信息的若干小批次$\boldsymbol{F}_1,\boldsymbol{F}_2,\cdots,\boldsymbol{F}_n$,以便在批次维度上更高效地执行后续操作.随后,通过Transformer编码器(Transformer encoder)进行处理.该编码器利用多头注意力机制,在批次维度上建模点云特征之间的全局关系.给定输入特征矩阵$\boldsymbol{F}_x\in\mathbb{R}^{N\times d}$,其中$N$表示点的数量,$d$表示每个点的特征维度.通过线性变换生成查询、键和值矩阵:

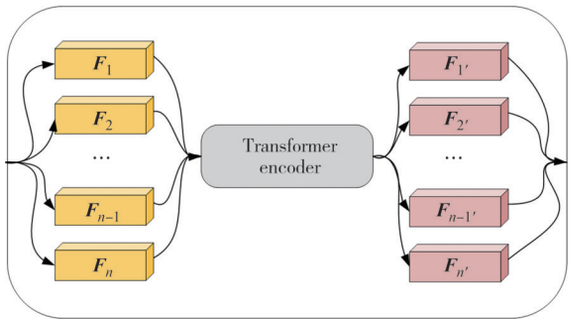

图1 BatchFormer内部结构图

Fig.1 Internal structure of BatchFormer

$$\boldsymbol{Q}_x=\boldsymbol{F}_x\boldsymbol{W}_{Q_x},\boldsymbol{K}_x=\boldsymbol{F}_x\boldsymbol{W}_{K_x},\boldsymbol{V}_x=\boldsymbol{F}_x\boldsymbol{W}_{V_x} \tag{1}$$

式中:$\boldsymbol{Q}_x,\boldsymbol{K}_x,\boldsymbol{V}_x\in\mathbb{R}^{N\times d_k}$,分别表示从输入特征$\boldsymbol{F}_x$通过可学习的权重矩阵$\boldsymbol{W}_{Q_x},\boldsymbol{W}_{K_x},\boldsymbol{W}_{V_x}$映射后的结果;$d_k$是注意力特征的维度.

具体来说,编码器通过计算每个点与其他点的相似性,生成注意力权重矩阵$\boldsymbol{A}$.基于这些权重,编码器能够动态调整每个点在整体特征中的重要性,从而有效捕捉局部特征的全局依赖关系.点与点之间的相似性由$\boldsymbol{Q}$和$\boldsymbol{K}$的点积计算得出:

$$\boldsymbol{A}=\mathrm{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}}\right) \tag{2}$$

式中:$\boldsymbol{A}\in\mathbb{R}^{N\times N}$;$\frac{1}{\sqrt{d_k}}$是缩放因子,用于防止注意力得分过大导致梯度不稳定;Softmax函数作用在每一行,将注意力得分归一化,使得每一行的权重和为1.

通过调整矩阵$\boldsymbol{A}$,噪声点的注意力权重会被显著降低,因此编码后的特征在噪声点附近表现出更强的鲁棒性.随后,这些特征被分流至多个独立的处理路径,每条路径分别对分流的特征进行进一步的局部归一化操作,最后重新汇聚在一起,形成输出.利用注意力权重矩阵$\boldsymbol{A}$和值矩阵$\boldsymbol{V}$,生成编码后的输出特征:

$$\boldsymbol{O}=\boldsymbol{A}\boldsymbol{V} \tag{3}$$

式中:$\boldsymbol{O}\in\mathbb{R}^{N\times d_k}$是每个点的编码特征.

1.2 动态重聚合特征表示

为进一步提升点云特征表达的鲁棒性和适应

性，本文在BatchFormer模块的基础上，同时使用了DRFR模块，旨在动态调整点云特征的聚合方式，以消除噪声点的干扰并突出关键特征，从而增强点云数据的全局一致性和局部表达能力[25]. 其主要包含三个阶段:多尺度卷积特征提取、特征调制和特征重聚合. 其结构图如图2所示.

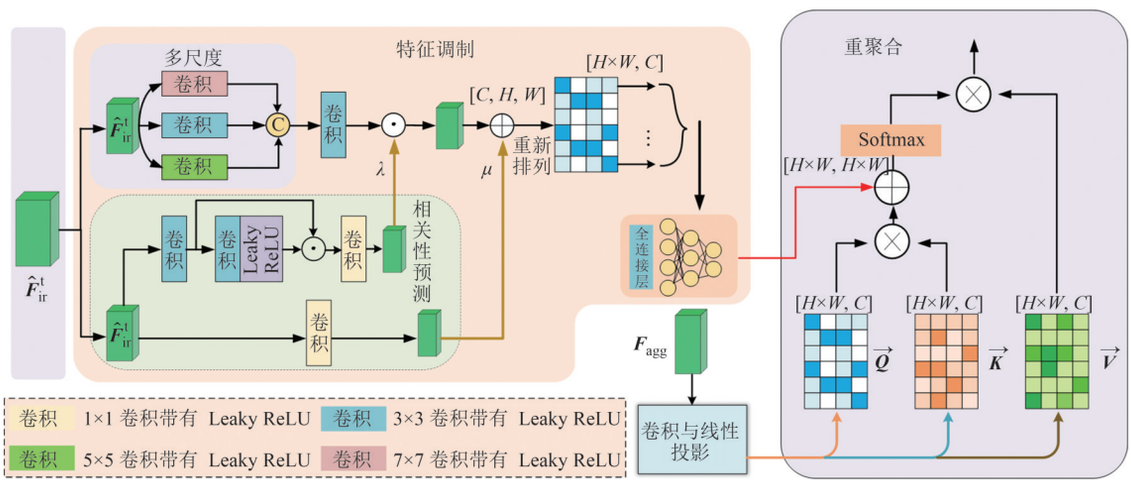

图2　DRFR内部结构图

Fig.2　Internal structure of DRFR

首先，来自BatchFormer模块的输出特征 $\hat{\boldsymbol{F}}_{\mathrm{ir}}^{\mathrm{t}}$ 被输入多尺度卷积模块，采用不同大小的卷积核捕获点云在不同尺度下的几何信息. 这一步采用多种卷积核，旨在捕获点云数据在不同尺度下的几何特性. 小尺度卷积适用于提取细粒度的局部几何特征，而大尺度卷积则有助于捕获更广泛的上下文信息. 同时，BatchFormer模块输出的特征被送入特征相关性预测模块，将卷积操作与非线性激活函数Leaky ReLU结合，通过两个并行分支动态生成调制参数 λ、μ，分别表示特征的缩放和偏移操作. 其中:

$$\mathrm{LeakyReLU}(x)=\begin{cases}x, & x\geqslant 0\\ ax, & x<0\end{cases} \tag{4}$$

式中:a 为负斜率系数，通常取值为0.01，用于引入非线性能力并避免死神经元问题. 这种调制机制有效突出点云的关键特征，同时抑制噪声点的干扰.

其次，多尺度特征进入特征调制模块. 该模块通过逐元素操作对特征进行自适应调整，包括缩放和偏移. 通过可学习的调制参数进行归一化与动态调制. 具体来说，调制单元会对每个特征通道进行归一化，并结合预测的调制系数 λ 和偏移量 μ 调整特征的重要性. 随后，特征被送入全连接层(fully connected layer，FC)，进一步学习点云特征的全局线性关系，为后续特征的动态聚合提供更强大的表达能力.

最后，经过调制的特征被送入重聚合模块，进一步强化点云特征的表达. 通过线性变换和权重分配将关键特征放大，而对噪声或无关特征进行抑制. 全连接层处理后输出的特征被分解为查询向量($\vec{\boldsymbol{Q}}$)、键向量($\vec{\boldsymbol{K}}$)和值向量($\vec{\boldsymbol{V}}$)，由点云特征通过线性变换得到. 这些向量通过注意力机制进行交互，形成一个动态权重分布，用于特征的最终重聚合，这使得点云特征之间的相似性可以被精确建模. 这些向量的维度均为[H×W，C]，其中 H×W 表示特征的空间分辨率，C 表示特征的通道数. 此过程中，特征首先被分配权重，然后利用加权机制完成聚合，生成新的全局特征表示. 这样的设计确保了点云特征表达的完整性和一致性，为后续的点云配准提供了基础.

2　算法流程

本文点云配准模型整体的结构如图3所示，该网络主要由特征提取、参数预测、刚性变换、自适应特征聚合四部分组成. 本文提出的自适应特征聚合部分集成了混合特征，用于生成与匹配矩阵计算之间的桥梁. 其内部的BatchFormer和DRFR模块通过与RPM-AFAMNet中其他部分的协同作用，实现了配准性能的提升.

在特征提取阶段，源点云和参考点云的特征被提取后传递至BatchFormer，该模块通过多尺度学习优化特征表示，减小噪声影响. 接下来，DRFR模块通过动态重组点云特征，加强了空间关系理解. 之后，参数预测模块生成旋转和平移参数，用于源点

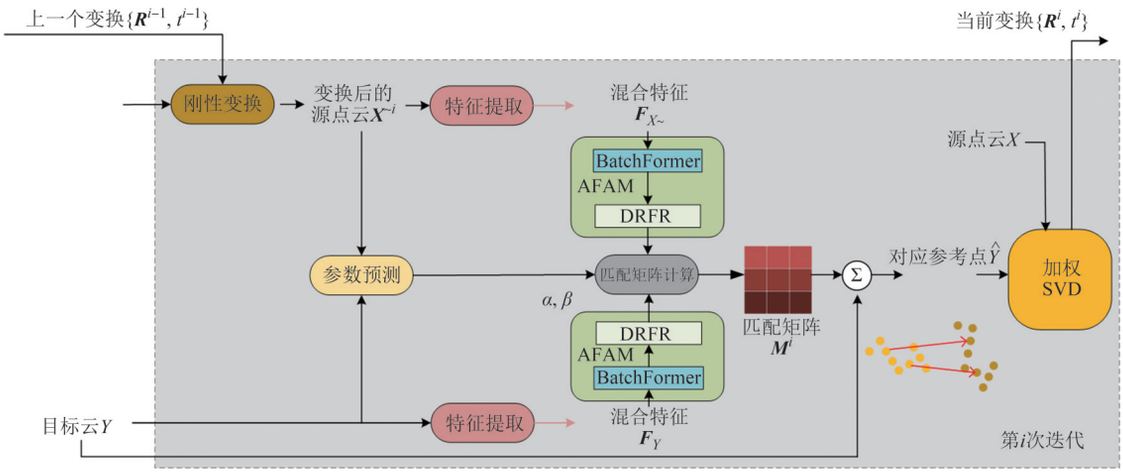

图 3 RPM-AFAMNet 网络结构图

Fig.3 Network diagram of RPM-AFAMNet

云的变换.最终,通过计算匹配矩阵,实现点云配准.

BatchFormer 和 DRFR 与其他模块的结合,增强了特征的表达能力和空间关系理解,改善了噪声点云的处理,从而提高了配准精度和鲁棒性.

2.1 特征提取

在特征提取的实现上,采用了基于 PointNet 的深度学习模型.核心思想是结合点云的空间坐标和局部几何特征,通过深度神经网络生成混合特征表示[13].为了确保特征的旋转不变性和对局部形状的敏感性,使用了点对特征描述子(point pair features,PPF),其通过计算点对之间的法向量夹角、相对方向等参数来表征局部表面特性.具体来说,特征提取过程中以混合特征 $\boldsymbol{F}_{\tilde{x}_j}$ 和 $\boldsymbol{F}_{y_k}$ 替代传统的欧几里得距离,用于点云配准中的点对匹配.混合特征中的距离被定义为:

$$m_{jk} \leftarrow \mathrm{e}^{-\beta\left(\left\|\boldsymbol{F}_{\tilde{x}_j}-\boldsymbol{F}_{y_k}\right\|^2-\alpha\right)} \tag{5}$$

式中:$\boldsymbol{F}_{\tilde{x}_j}$ 和 $\boldsymbol{F}_{y_k}$ 分别表示点云 $\tilde{X}$ 和 Y 的特征;α 是离群点比例;β 是用于控制退火进程的参数.通过该定义,算法能够更好地捕获点云的局部几何信息,避免陷入局部最小值.在具体实现中,为了生成 $\boldsymbol{F}_{\tilde{x}_j}$ 和 $\boldsymbol{F}_{y_k}$,首先对每个点 x_c 的邻域内点计算其相对坐标 $\Delta x_{c,i}$ 和点对特征 PPF,进而构造包含 10 维信息的输入特征向量.这些输入特征向量经过若干层共享的全连接层(FC),并在每层后引入非线性激活函数 Leaky ReLU 来增强特征表达能力.之后,使用最大池化操作对局部邻域的特征进行全局整合,从而生成固定长度的特征向量.最后,通过特征归一化步骤,确保输出的特征具有稳定的数值范围,并避免特征在不同尺度的点云中出现不一致性.

2.2 参数预测

在参数预测部分使用了一个独立的子网络,用于接收点云对的特征输入,并根据当前配准的状态,预测出适合本次迭代的 α 和 β.为了实现这一点,首先将源点云和目标点云的特征进行连接,形成一个 $(J+K)\times 3$ 的矩阵,J 和 K 分别表示源点云和目标点云的点数.在此基础上,为矩阵附加 1 列标识符,标记每个点属于源点云还是目标点云(用 0 和 1 表示),生成一个 $(J+K)\times 4$ 的特征矩阵.该矩阵被输入到一个基于 PointNet 架构的神经网络中,该网络通过一系列共享的多层感知机(MLP)和池化操作,提取点云对的全局特征,并在输出层预测出参数 α 和 β.参数预测模块结构图如图 4 所示.

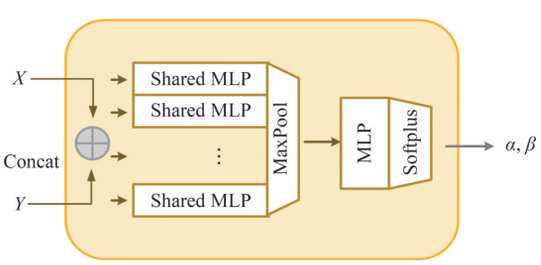

图 4 参数预测模块结构图

Fig.4 Internal structure of parameter prediction

2.3 刚性变换估计

对于 X 中的每个点 x_j,计算 Y 中的相应坐标:

$$\hat{y}_j = \frac{1}{\sum_k^K m_{jk}} \sum_k^K m_{jk} \cdot y_k \tag{6}$$

式中:$\hat{y}_j$ 表示源点云中第 j 个点 $\hat{x}_j$ 在目标点云中的对应点;y_k 表示目标点云中的第 k 个点;m_{jk} 表示源点 x_j 与目标点 y_k 之间的匹配权重,反映两点之间的对应

关系强度;$\sum_{k}^{K} m_{jk}$表示对所有目标点的匹配权重进行归一化的系数.

然后使用SVD求解刚性变换.由于并非每个点x_j都有对应关系,因此在计算刚性变换时,我们通过$w_j = \sum_{k}^{K} m_{jk}$对每个对应关系$\left(x_j, \hat{y}_j\right)$进行加权.

3　实验验证与分析

3.1　实验环境和参数

本文算法使用的硬件和软件的配置如表1所示.本实验的模型训练参数的设置情况如下:选择自适应矩估计算法(adaptive moment estimation, Adam)作为网络的优化器,将鼓励内点的权重系数设置为0.01, Batch Size训练集设置为8,验证集设置为16.初始学习率设置为0.000 1, Sinkhorn归一化内迭代次数设置为5次.邻域半径设置为0.3,邻域点数量为160,工作线程数为4.

表1　实验配置

Tab.1　Experimental configuration

设备配置	型号及参数
操作系统	Linux Ubuntu 22.04.5
CPU	Intel(R) Core(TM) i5-12500H
GPU	RTX 4090 D
CUDA	11.7
Python	3.8
Anaconda	2023.07-2
PyTorch	1.13

3.2　实验数据集

为了验证本文提出的点云配准算法的有效性,采用了由普林斯顿大学提出的ModelNet40数据集进行实验[26-27].ModelNet40数据集部分实例如图5所示.本文的实验使用采样点的(x,y,z)坐标作为输入,并通过随机旋转、平移以及逐点抖动来进行数据增强.

ModelNet40数据集包含了40个类别的3D物体数据,涵盖了现实生活中常见的物体.训练集包含9 843个样本,测试集包含2 468个样本.本文的实验将每个物体点云包含的固定点的数量设置为1 024.这些点是通过均匀或随机采样物体表面得到的.

3.3　实验结果与分析

3.3.1　配准结果分析

图6展示了本文的基准模型RPM-Net与本文方法对ModelNet40数据集进行配准的可视化效果对比图.绿色点云为目标点云,蓝色部分是变换后的点云.可见RPM-Net模型处理后的数据存在着较为明显的错位,对齐存在偏差.本文提到的方法通过优化特征提取和配准策略,使变换后的点云和目标点云对齐更加精确,轮廓整体更加贴合目标点云.

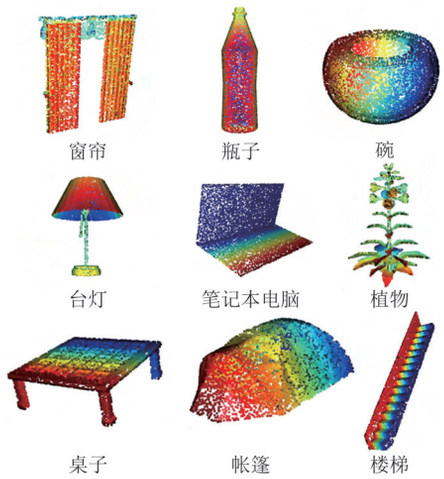

图5　三维点云模型可视化

Fig.5　3D point cloud model visualization

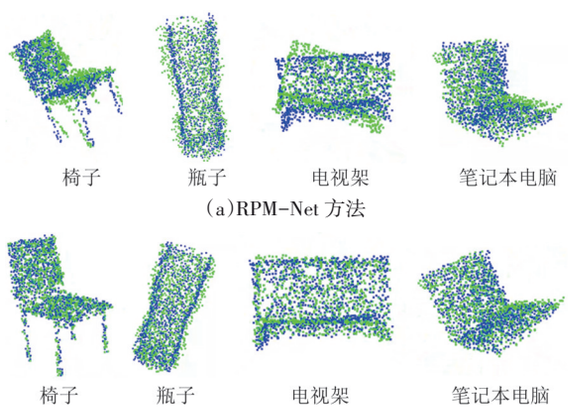

图6　点云配准可视化

Fig. 6　Point cloud registration visualization

本文算法与目前主流的点云配准模型进行了配准精度的对比.本文所采用的性能指标为点云配准常用的性能指标,即平均绝对误差(mean absolute error, MAE)和均方根误差(root-mean-square error, RMSE)等[14].对比结果见表2.

从实验结果可以看出,本文网络模型的性能在对比模型中表现均为最优.相较于原来以混合特征提取为核心、通过固定特征提取策略来描述点云局部和全局几何关系的RPM-Net网络,本文所提出模型的旋转均方误差降低32.05%,旋转平均绝对误差

表 2 不同模型在 ModelNet40 数据集上的配准误差

Tab.2 Registration error of different models on the ModelNet40 dataset

Method	RMSE (Rot)	MAE (Rot)	RMSE (Trans)	MAE (Trans)	Error (R)	Error (t)
ICP[14]	21.647	9.924	0.112	0.065	18.623	0.132
FMR[13]	3.821	2.236	0.027	0.018	4.417	0.034
OMNet[19]	3.572	1.570	0.039	0.017	3.073	0.036
RGM[20]	5.968	2.479	0.058	0.025	4.766	0.052
FINet[12]	3.676	1.363	0.033	0.013	2.673	0.027
PANet[11]	2.780	1.887	0.021	0.016	3.864	0.029
RPM-Net	3.023	1.806	0.021	0.018	1.208	0.011
本文方法	**2.054**	**0.436**	**0.014**	**0.004**	**0.809**	**0.007**

降低 75.86%，平移均方误差降低 33.33%，平移平均绝对误差降低 77.78%，旋转角度误差降低 33.03%，平移距离误差降低 36.36%，通过多头注意力机制和动态特征再聚合，使得点云的特征表达得更加细致和准确.

具体而言，本实验选取了三种常见的噪声类型，包括高斯噪声、散斑噪声和椒盐噪声. 高斯噪声是一种典型的加性噪声，模拟点云数据在采集过程中受到随机误差的影响；散斑噪声更符合激光雷达等设备中点云数据因散射效应而产生的不确定性；椒盐噪声是一种离散型噪声，常用于模拟点云数据中可能存在的离散错误或异常点. 图 7 展示了本文点云配准网络模型训练的损失函数曲线. 模型的平均损失在各个噪声条件下均呈现出快速下降的趋势，并在前 5 个训练轮数内显著降低，随后趋于平稳. 在不同噪声类型下，模型的最终损失值基本一致，均稳定在约 0.015，进一步说明本文模型具有较强的鲁棒性，能够在不同噪声条件下保持较高的配准性能.

3.3.2 消融实验

为了验证本文提出的 BatchFormer 和 DRFR 模块在网络中的具体作用和有效性，本文在 RPM-Net 模型的基础上设计了多组实验，过程中保持其他网络结构和参数设置不变. 本文在 ModelNet40 数据集上构建了 3 组模型，进行自身消融对比实验，实验结果见表 3.

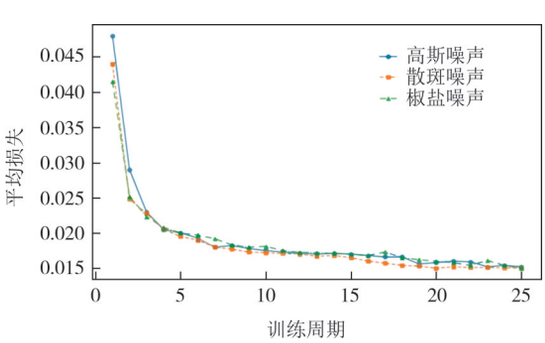

图 7 损失函数下降曲线

Fig.7 Loss function decline curves

表 3 不同模块的消融实验

Tab.3 Ablation experiment about different modules

Method	DRFR	BatchFormer	Mean (Rot)	RMSE (Rot)	Mean (Trans)	RMSE (Trans)
RPMNet	—	—	1.208	3.023	0.011	0.021
A	√	×	1.208	2.847	0.011	0.021
B	×	√	1.075	2.929	0.009	0.020
C	√	√	0.958	2.507	0.008	0.017

本文将 RPM-Net 网络结构作为基准模型. 表中的模型 A 在基准模型的基础上仅采用 DRFR 模块对提取的特征重新聚合，动态调整特征的权重分布. 模型 B 仅采用 BatchFormer 模块对特征提取阶段的输出进行全局上下文融合，经过多头注意力机制建模空间结构和全局关系. 与模型 A 相比，模型 B 的 Mean(Rot) 和 Mean(Trans) 分别比模型 A 降低了 11.01% 和 18.18%. 模型 C 是在经过原始的特征提取阶段后，特征 $\boldsymbol{F}_{\tilde{x}}$ 和 $\boldsymbol{F}_{\tilde{y}}$ 会先经过 BatchFormer 进行全局的上下文建模，再经过 DRFR 实现特征动态的聚合. 模型的 Mean(Rot) 和 Mean(Trans) 与其他模型比，均达到了最低值. 实验结果表明，本文所提出的模型可以有效提高噪声条件下点云配准的精度.

3.3.3 全连接层数测试

为了研究特征提取环节不同全连接层数对模型点云配准精度的影响，本文在 ModelNet40 数据集上设计了使用 1、2、3、4、5 层全连接层进行实验，并以高斯噪声环境(scale=0.01)下的点云配准误差作为评价指标，实验结果见表 4.

表 4 不同全连接层数实验

Tab.4 Experiments with different full connectivity layers

层数	Mean(Rot)	RMSE(Rot)	Mean(Trans)	RMSE(Trans)
1层	**0.932 0**	2.435 3	**0.008 018**	0.017 63
2层	0.996 3	2.576 1	0.008 583	0.018 11
3层	0.957 9	2.506 9	0.008 399	0.016 94
4层	0.998 2	2.661 4	0.008 484	0.018 07
5层	0.958 7	**2.390 9**	0.008 277	**0.016 57**

当全连接层数为 1 时，Mean (Rot) 和 Mean (Trans) 均达到了最优值，表明单层全连接能够捕捉到核心特征并实现较好的点云配准性能. 然而，由于

单层全连接的模型容量较低,对复杂点云数据中的精细特征表达不足,因此在RMSE(Rot)和RMSE(Trans)指标上表现稍逊.当层数增加到5时,尽管RMSE(Rot)与RMSE(Trans)最优,但过多的全连接层导致特征表示过于复杂,信息冗余显著增加,从而降低了整体的泛化性能和在不同场景下的稳定性.综合考虑模型的学习能力、对复杂点云数据的表达能力以及噪声环境下的稳健性,本文最终选择了全连接层数为3的配置.在此配置下,各项指标均接近1层和5层的性能,同时具备较高的模型复杂度,能够更全面地捕捉特征的全局性与细粒度信息.此外,3层结构在训练效率和模型参数量之间达到了较好的平衡,适合在实际场景中应用.

3.3.4　特征维度实验

在本研究中,特征维度决定了模型在特征提取过程中的表达能力,是描述点云几何特性的重要参数.为了探究特征维度对模型性能的影响,本文在ModelNet40数据集上进行测试,并在相同参数环境下,仅调整特征维度的大小,依次为64、96、128、160、192,实验结果见表5.

表5　不同特征维度实验

Tab.5　Experiments with different feature dimensions

特征维度	Mean(Rot)	RMSE(Rot)	Mean(Trans)	RMSE(Trans)
64	1.076 5	2.691 5	0.009 282	0.017 58
96	0.957 9	2.506 9	0.008 399	0.016 94
128	**0.904 2**	**2.312 6**	**0.007 750**	**0.015 04**
160	0.935 7	2.499 4	0.007 936	0.016 70
192	0.934 6	2.422 9	0.008 006	0.017 95

实验结果表明,当特征维度较低时,模型的特征表示能力受到限制,无法充分提取和表征复杂的点云几何信息,导致点云配准的误差较高.当特征维度提升至128时,模型的特征提取能力显著增强,可以捕捉到更为复杂和细致的几何信息,从而达到最优的配准性能.但当特征维度进一步增加时,配准性能未能继续提升,反而出现略微下降.这是由于特征维度过高导致了信息的冗余,同时噪声成分对特征表示的影响也会增大.因此,选择一个合适的特征维度可以发挥模型的性能,并使模型具有较强的鲁棒性.

3.3.5　邻域半径实验

为了探究邻域半径的大小对本文模型性能的影响,本文在高斯噪声环境(scale=0.01)下,选取了不同的邻域半径值(0.1、0.2、0.3、0.4、0.5)进行实验.实验结果如表6所示.

表6　不同邻域半径实验

Tab.6　Experiments with different neighborhood radius

邻域半径	Mean (Rot)	RMSE (Rot)	Mean (Trans)	RMSE (Trans)	Chamfer distance (CD)
0.1	1.366 9	3.365 9	0.011 360	0.024 81	0.000 717 8
0.2	1.075 8	2.755 0	0.009 066	0.018 55	0.000 673 1
0.3	**0.957 9**	**2.506 9**	**0.008 399**	**0.016 94**	**0.000 661 4**
0.4	1.052 7	2.632 8	0.009 069	0.017 29	0.000 675 4
0.5	1.193 3	3.007 0	0.010 230	0.020 18	0.000 695 2

从实验结果可以看出,随着邻域半径的增大,模型在不同评价指标上的性能呈现出一定的波动性.当邻域半径设置为0.3时,模型的配准性能达到了最优表现.相较于较小的半径(如0.1和0.2),半径为0.3时模型能够更充分地提取点云局部的几何信息,从而显著提升配准精度.而当半径进一步增大(如0.4和0.5)时,由于引入了更多与配准无关的冗余信息,导致性能有所下降.因此,本文采用了邻域半径为0.3的设置.

3.3.6　模型鲁棒性实验

为了验证本文模型在噪声环境中的鲁棒性,本文分别对噪声种类和噪声规模对模型性能的影响进行了实验.

噪声种类鲁棒性实验.在ModelNet40数据集中添加不同种类的噪声考察模型在多种噪声条件下的性能,从而验证其泛化能力和鲁棒性.在实验中,三种噪声类型均设置为相同的scale.实验结果如表7所示.

从实验结果可以看出,尽管不同噪声类型对点云配准任务的干扰模式各不相同,但本文模型在应对不同类型噪声均能够有效提取更加鲁棒的点云特征,显著降低配准误差,从而表现出最优的配准性能.

噪声规模鲁棒性实验.实验选定高斯噪声作为干扰源,在其他条件不变的情况下,通过调整噪声的标准差来模拟不同强度的噪声干扰.具体而言,实验中分别设置噪声scale为0.001、0.002、0.003、0.004和0.005,共进行了五组实验,以观察噪声强度变化对点云配准性能的影响.实验结果如表8所示.

从实验结果可以看出,本文模型在不同噪声强度条件下均表现出显著的鲁棒性.因为BatchFormer和DRFR的协同作用有效增强了模型对特征表达的稳定性.

表7 不同种类噪声下的点云配准误差(scale=0.01)

Tab.7 Point cloud registration errors under different kinds of noise(scale=0.01)

噪声类型	网络模型	Mean(Rot)	RMSE(Rot)	Mean(Trans)	RMSE(Trans)	Chamfer distance (CD)
高斯噪声	RPM-Net	1.208 2	3.023 2	0.010 830	0.021 19	0.000 716 1
	本文方法	**0.957 9**	**2.506 9**	**0.008 399**	**0.016 94**	**0.000 661 4**
散斑噪声	RPM-Net	1.034 7	2.609 7	0.009 721	0.018 71	0.000 290 7
	本文方法	**0.871 7**	**2.212 9**	**0.007 699**	**0.015 28**	**0.000 235 6**
椒盐噪声	RPM-Net	1.304 3	2.867 6	0.012 82	0.021 34	0.009 040 5
	本文方法	**1.253 5**	**2.430 3**	**0.010 57**	**0.017 95**	**0.009 001 7**

表8 不同规模噪声下的点云配准误差(高斯噪声)

Tab.8 Point cloud registration errors under different scales of noise(Gaussian noise)

噪声规模(Scale)	网络模型	Mean(Rot)	RMSE(Rot)	Mean(Trans)	RMSE(Trans)	Chamfer distance (CD)
0.001	RPM-Net	0.979 1	2.448 4	0.009 202	0.016 85	0.000 195 6
	本文方法	**0.875 4**	**2.204 7**	**0.007 753**	**0.014 40**	**0.000 151 9**
0.002	RPM-Net	0.995 6	2.492 1	0.009 189	0.017 45	0.000 206 9
	本文方法	**0.843 4**	**2.178 2**	**0.007 274**	**0.014 48**	**0.000 158 3**
0.003	RPM-Net	1.036 5	2.697 8	0.009 503	0.018 53	0.000 242 2
	本文方法	**0.859 3**	**2.164 4**	**0.007 363**	**0.013 93**	**0.000 188 4**
0.004	RPM-Net	1.056 2	2.695 7	0.009 794	0.019 03	0.000 289 7
	本文方法	**0.847 4**	**2.269 2**	**0.007 354**	**0.014 80**	**0.000 223 8**
0.005	RPM-Net	1.046 2	2.674 5	0.009 612	0.018 93	0.000 333 7
	本文方法	**0.883 6**	**2.235 8**	**0.007 436**	**0.014 08**	**0.000 282 8**

4 结论与展望

本文提出了一种基于混合特征提取与动态特征重聚合机制的点云配准网络RPM-AFAMNet，自适应特征聚合模块中的BatchFormer通过批次级别的特征注意力机制自适应调整点云特征表达，突出全局关键特征，抑制噪声干扰；DRFR模块则通过多尺度卷积与特征归一化策略，进一步增强点云的局部特征表达能力.这种模块化的设计实现了从特征提取到匹配矩阵计算的高效集成.在ModelNet40数据集上的实验表明，本文方法在多个点云配准误差指标上均显著优于现有主流算法，不仅验证了本文模型的有效性，也进一步证明了BatchFormer和DRFR的关键作用.此外，本文模型能够适应不同的点云输入规模，在复杂环境下依然表现出较强的鲁棒性，为后续研究提供研究借鉴.

未来的工作可以从以下方面进一步探索：一是结合更多的几何特征和语义信息，以提高网络对多类点云的适配能力；二是优化网络结构以进一步降低计算成本，满足实际应用中的实时性需求；三是针对动态场景中的点云配准问题，探索具有时序特征的模型设计.

参考文献

[1] 余加勇,杨宇驰,王昱东,等. 基于多平面分割和矩阵变换的航摄边坡点云滤波算法[J]. 湖南大学学报(自然科学版),2024,51(11):12-22.
YU J Y, YANG Y C, WANG Y D, et al. An aerial photography slope point cloud filtering algorithm based on multi-plane segmentation and matrix transformations [J]. Journal of Hunan University (Natural Sciences),2024,51(11):12-22.(in Chinese)

[2] 王佳栋, 曹娟, 陈中贵.保特征的点云骨架提取算法[J].图学学报, 2023, 44(1): 146-157.
WANG J D, CAO J, CHEN Z G. Feature-preserving skeleton extraction algorithm for point clouds [J]. Journal of Graphics, 2023,44(1):146-157.(in Chinese)

[3] WEBER M, WILD D, KLEESIEK J, et al. Deep learning-based point cloud registration for augmented reality-guided surgery[C]// 2024 IEEE International Symposium on Biomedical Imaging (ISBI), May 27-30,2024,Athens,Greece. IEEE,2024:1-5.

[4] 秦晓辉,刘硕,常灯祥, 等.基于激光点云特征的LiDAR-GNSS/IMU联合自动标定方法[J].湖南大学学报(自然科学版),2023,50(10):175-184.
QIN X H, LIU S, CHANG D X, et al. LiDAR-GNSS/IMU automatic joint calibration method based on laser point cloud features [J]. Journal of Hunan University (Natural Sciences), 2023, 50(10): 175-184.(in Chinese)

[5] 刘玉珍, 李楠, 陶志勇. 基于环查询和通道注意力的点云分类

与分割[J]. 图学学报, 2022, 43(4): 616-623.
LIU Y Z, LI N, TAO Z Y. Point cloud classification and segmentation based on ring query and channel attention [J]. Journal of Graphics, 2022, 43(4): 616-623. (in Chinese)

[6] 雷志勇. 基于双重注意力融合的三维目标检测方法[J]. 湖南大学学报(自然科学版), 2025, 52(8): 80-91.
LEI Z Y. A 3D object detection method based on dual attention fusion[J]. Journal of Hunan University (Natural Sciences), 2025, 52(8): 80-91. (in Chinese)

[7] 杨军,郭佳晨. 自适应生成卷积核的动态图注意力三维点云识别及分割[J]. 湖南大学学报(自然科学版), 2024, 51(12): 139-152.
YANG J, GUO J C. Recognition and segmentation of 3D point cloud by dynamic graph attention with adaptive generated convolutional kernel [J]. Journal of Hunan University (Natural Sciences), 2024, 51(12): 139-152. (in Chinese)

[8] 程云建,仇文革, 雷劲. 基于三维点云的隧道全局中线提取方法及应用[J]. 湖南大学学报(自然科学版), 2017, 44(9): 146-150.
CHENG Y J, QIU W G, LEI J. Application of method for global extraction of tunnel centerlines based on 3D point clouds [J]. Journal of Hunan University (Natural Sciences), 2017, 44(9): 146-150. (in Chinese)

[9] SHU Y C, CHENG L J, XIAO B, et al. Focal-guided multi-consistency for unsupervised partial-to-partial point cloud registration [C]//2024 IEEE International Conference on Multimedia and Expo (ICME), July 15-19, 2024, Niagara Falls, ON, Canada. IEEE, 2024: 1-6.

[10] 白创,陈立,闫昱. 一种基于PVDAC描述子的RGB-D三维点云配准方法[J]. 湖南大学学报(自然科学版), 2023, 50(2): 95-101.
BAI C, CHEN L, YAN Y. A RGB-D 3D point cloud registration method based on PVDAC descriptor [J]. Journal of Hunan University (Natural Sciences), 2023, 50(2): 95-101. (in Chinese)

[11] WU Y, YAO Q L, FAN X L, et al. PANet: a point-attention based multi-scale feature fusion network for point cloud registration[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-13.

[12] 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.

[13] 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.

[14] 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.

[15] YEW Z J, LEE G H. RPM-net: robust point matching using learned features [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020. Seattle, WA, USA. IEEE, 2020: 11821-11830.

[16] AOKI Y, GOFORTH H, SRIVATSAN R A, et al. PointNetLK: robust & efficient point cloud registration using PointNet [C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. IEEE, 2020: 7156-7165.

[17] SARODE V, LI X Q, GOFORTH H, et al. PCRNet: point cloud registration network using PointNet encoding[EB/OL]. 2019: arXiv: 1908.07906. [2025-02-24]. https://arxiv.org/abs/1908.07906.

[18] AO S, HU Q Y, WANG H Y, et al. BUFFER: balancing accuracy, efficiency, and generalizability in point cloud registration [C]// 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 17-24, 2023, Vancouver, BC, Canada. IEEE, 2023: 1255-1264.

[19] XU H, LIU S C, WANG G F, et al. OMNet: learning overlapping mask for partial-to-partial point cloud registration [C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. IEEE, 2022: 3112-3121.

[20] 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): 6183-6191.

[21] SHEN Q B, ZHAO Y G, YANG C, et al. 3D pairwise point cloud registration network for power equipment based on multi-scale features [C]//2024 The 9th International Conference on Power and Renewable Energy (ICPRE), September 20-23, 2024, Guangzhou, China. IEEE, 2024: 1452-1457.

[22] MA L T, BIAN W, XUE X P. Point clouds matching based on discrete optimal transport [J]. IEEE Transactions on Image Processing, 2024, 33: 5650-5662.

[23] WANG Y, ZHOU P B, GENG G H, et al. MATR: multicompound adaptive transformer for point cloud registration [J]. IEEE Transactions on Industrial Informatics, 2024, 20(11): 12903-12912.

[24] HOU Z, YU B S, TAO D C. BatchFormer: learning to explore sample relationships for robust representation learning [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18-24, 2022, New Orleans, LA, USA. IEEE, 2022: 7246-7256.

[25] LI H F, LIU J Y, ZHANG Y F, et al. A deep learning framework for infrared and visible image fusion without strict registration[J]. International Journal of Computer Vision, 2024, 132(5): 1625-1644.

[26] WU Y, ZHANG Y, MA W P, et al. RORNet: partial-to-partial registration network with reliable overlapping representations[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(11): 15453-15466.

[27] YUAN W T, ECKART B, KIM K, et al. DeepGMR: learning latent Gaussian mixture models for registration [C]//Computer Vision-ECCV 2020. Cham. Springer, 2020: 733-750.