

### 结合注意力机制的多重引导点云配准网络

刘旭珩, 柏正尧, 许祝, 杜佳锦, 肖霄

引用本文

刘旭珩, 柏正尧, 许祝, 杜佳锦, 肖霄. 结合注意力机制的多重引导点云配准网络[J]. 计算机科学, 2024, 51(2): 142-150.

LIU Xuheng, BAI Zhengyao, XU Zhu, DU Jiajin, XIAO Xiao. [Multi-guided Point Cloud Registration Network Combined with Attention Mechanism](#) [J]. Computer Science, 2024, 51(2): 142-150.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于改进自注意力机制和表示学习的分层文档分类方法](#)

Hierarchical Document Classification Method Based on Improved Self-attention Mechanism and Representation Learning

计算机科学, 2024, 51(2): 238-244. <https://doi.org/10.11896/jsjcx.221100266>

#### [基于Depth-wise卷积和视觉Transformer的图像分类模型](#)

Novel Image Classification Model Based on Depth-wise Convolution Neural Network and Visual Transformer

计算机科学, 2024, 51(2): 196-204. <https://doi.org/10.11896/jsjcx.221100234>

#### [LNG-Transformer:基于多尺度信息交互的图像分类网络](#)

LNG-Transformer: An Image Classification Network Based on Multi-scale Information Interaction

计算机科学, 2024, 51(2): 189-195. <https://doi.org/10.11896/jsjcx.221100218>

#### [基于扩张卷积条件生成对抗网络的红外小目标检测](#)

Infrared Small Target Detection Based on Dilated Convolutional Conditional Generative Adversarial Networks

计算机科学, 2024, 51(2): 151-160. <https://doi.org/10.11896/jsjcx.221200045>

#### [基于自注意力机制和多尺度输入输出的医学图像分割算法](#)

Medical Image Segmentation Algorithm Based on Self-attention and Multi-scale Input-Output

计算机科学, 2024, 51(2): 135-141. <https://doi.org/10.11896/jsjcx.221100260>

# 结合注意力机制的多重引导点云配准网络

刘旭珩 柏正尧 许 祝 杜佳锦 肖 霄

云南大学信息学院 昆明 650221

(liuxuheng@mail.ynu.edu.cn)

**摘 要** 针对点云配准过程中仅仅利用点云特征寻求对应关系使得离群点多、配准精度不高的问题进行研究,提出了一种使用点云之间匹配点概率矩阵和点云空间信息特征矩阵共同搜寻对应关系,并且相互配合确定对应点权重的点云配准网络——AMGNet。首先使用点云特征提取网络获得两片待配准点云的高维特征;然后采用 Transformer 对独立特征进行上下文信息融合,之后利用关键点提取模块选取特征更强的点,使用 SoftBBS 方法获得点云匹配点概率矩阵后,结合点云空间特征矩阵搜索到最终的对应关系,同时,权重分配也使用了双重矩阵共同决定的策略;最后使用奇异值分解获得需要的刚性变换矩阵。在 ModelNet40,7Scenes 等人工合成数据集和真实场景数据集上进行了多次实验。结果表明,在 ModelNet40 目标未知实验中的旋转矩阵和平移向量的均方误差分别降低至 0.025 和 0.0046。AMGNet 配准精度较高,抗干扰能力强,泛化能力强。

**关键词**:点云配准;注意力机制;多重矩阵引导;加权 SVD

**中图分类号** TP391.41

## Multi-guided Point Cloud Registration Network Combined with Attention Mechanism

LIU Xuheng, BAI Zhengyao, XU Zhu, DU Jiajin and XIAO Xiao

School of Information Science and Engineering, Yunnan University, Kunming 650221, China

**Abstract** This paper proposes a point cloud alignment network, AMGNet, which uses the probability matrix of matching points between point clouds and the spatial information feature matrix of point clouds to search for correspondence and determine the weights of corresponding points with each other. First, the point cloud feature extraction network is used to get the high-dimensional features of the two unaligned point clouds and then the Transformer is used to fuse the independent features with the contextual information. Also, the weight assignment uses the strategy of double matrix co-determination. Finally, the singular value decomposition is used to obtain the required rigid transformation matrix. Several experiments are conducted on synthetic datasets, such as ModelNet40, 7Scenes and real scenes. The results show that the mean square error of rotation matrix and translation vector in ModelNet40 target unknown experiments is reduced to 0.025 and 0.0046, respectively. AMGNet alignment has high accuracy, high interference resistance, and good generalization ability.

**Keywords** Point cloud registration, Attention mechanism, Multiple matrix guidance, Weighted SVD

### 1 引言

三维数据是一种在实际应用中十分普遍的数据表现形式,具有蕴含信息丰富、表现形式多样等优点,其中一种表现形式为点云。在计算机视觉日益发展的今天,传感器获取到的点云精度和质量也越来越高,点云数据也得到了越来越多的使用<sup>[1]</sup>,例如自动驾驶、机器人同步定位与建图(Simultaneous Localization and Mapping, SLAM)、三维重建等都有点云的影子<sup>[2]</sup>。三维重建的目的在于恢复物体的三维结构,但在获取物体点云时,受物理遮挡、噪声影响和采样距离不连贯等因素的限制,其不能一次性获取物体完整的点云,需要从

多个角度不断采样,获得的点云为片面点云而非完整点云。为了解决此问题,需要获取变换矩阵,即旋转矩阵和平移矢量构成的矩阵,将不同坐标系下的点云变换到同一坐标系下,这一过程称为点云配准<sup>[3]</sup>。

端到端点云配准方法是通过点对点云特征求内积或欧氏距离得到对应关系矩阵,求取虚拟点对,去除离群点,最终获取变换矩阵<sup>[4]</sup>。这种方法的特点在于,输入两片点云后,得到的便是需要的刚性变换矩阵,不需要其他步骤。这顺应了当前人工智能、神经网络发展的大势。然而,现有的端到端点云配准模型多是针对两片待配准点云的特征直接进行处理,没有利用其他现有条件,造成了配准

到稿日期:2023-02-20 返修日期:2023-06-20

基金项目:云南省重大科技专项课题(202002AD080001);云南大学第十四届研究生科研创新项目(KC-22222543)

This work was supported by the Yunnan Provincial Major Science and Technology Special Plan Projects(202002AD080001) and 14th Postgraduate Research Innovation Project of Yunnan University(KC-22222543).

通信作者:柏正尧(baizhy@ynu.edu.cn)

效率不高、耗时较长、鲁棒性差等问题。

针对上述问题,本文采用一种注意力机制多重引导的点云配准网络——AMGNet(Attention Mechanism Multi-guided Point Cloud Registration Network),利用点云匹配点概率矩阵、点云空间信息特征矩阵共同搜索对应关系和确定权重信息。本研究的灵感来自 IDAM<sup>[5]</sup>,MFGNet<sup>[6]</sup>和 DeepBBS<sup>[7]</sup>等方法。具体地,DeepBBS 利用 SoftBBS 得到匹配点概率矩阵,再与点云欧氏距离相结合计算权重,但是其并未充分利用点云的空间信息,因此配准时间稍长、精度偏低。Li 等提出了一种含有丰富点云的空间信息提取方法,即考虑点云欧氏距离又兼顾点云方向信息,利用多层感知机(Multilayer Perceptron,MLP)进行空间特征提取。MFGNet 中联合点云空间坐标矩阵和点云空间特征矩阵共同搜索点云对应关系和点对之间的权重值。

本文提出使用 Transformer 进行点云特征交互,通过关键点提取模块提取关键信息,利用 SoftBBS 计算两片点云匹配点概率矩阵,并将点云欧氏距离、点云方向向量、源点云坐标的点云空间信息聚合,最后通过 MLP 进行特征提取,形成点云空间信息矩阵。通过双重矩阵的结合,确定对应关系,并确定相应的权重,使用加权奇异值分解(Singular Value Decomposition,SVD)求解点云配准需要的变换矩阵。并采用与 DCP<sup>[8]</sup>,RPMNet<sup>[9]</sup>等网络相似的迭代思想,设计了一种精度高、鲁棒性好、泛化能力强的点云配准网络。

在人工合成数据集、真实场景数据集上进行了多项指标的对比实验与消融实验。数据显示,相比以其他数学迭代方法为基础的点云配准算法和传统端对端的点云配准网络,AMGNet 在各项指标上都得到了不同程度的改善。

## 2 相关工作

点云配准又可分为基于数学迭代法、特征匹配法和端到端点云配准网络。其中,基于数学迭代的点云配准方法中最经典的点云配准方法是迭代最近点算法<sup>[10]</sup>(Iterative Closest Point,ICP),其原理为逐点迭代地计算出两片点云的点得到相应的点对,并利用奇异值分解得到变换矩阵,但是点云初始位置的优劣以及外界噪声的干扰状况对其有较大的影响。为减少以上因素对配准精度造成的影响,在 ICP 基础上先后提出了几种改进算法,例如 Go-ICP<sup>[11]</sup>,DlCP<sup>[12]</sup>等。另一种配准算法是基于正态分布变换法<sup>[13]</sup>(Normal Distributions Transform,NDT)提出的,原理是应用正态分布最优化原理,计算点云配准需要的位姿变换的变换矩阵,它的局限性与 ICP 算法相似,都对点云初始位姿有较高需求。4PCS<sup>[14]</sup>(4-Points Congruent Sets)也属于点云数学迭代法中的一类算法,它是基于 RANSAC<sup>[15]</sup>(Random Sample Consensus)算法设计的。该算法在处理初始姿态不佳的情况时性能较好,少量的噪声对其性能影响也较小,但是其计算耗时较长。因此,许多研究都集中于如何加快配准的速度,比如基于特征学习的配准方法 super4PCS<sup>[16]</sup>采用对点云中特征较明显的点进行配准的方法。对于这一类配准方法来说,特征检测和特征描述以及特征匹配就显得尤为重要。在特征检测方面,目前有最远点采样法<sup>[17]</sup>(Farthest Point Sampling,FPS)、法向

空间采样法<sup>[18]</sup>(Normal Space Sampling,NSS)、HoNO<sup>[19]</sup>(Histogram of normal orientations)等。此步骤的目的在于精炼点云信息,提升点云特征描述的效率和质量。在特征描述方面,文献[20]提出了应用主成分分析法(Principal Component Analysis,PCA),文献[21]提出了 3D 形状上下文描述符(3D shape context,3DSC),文献[22]介绍了点特征直方图(Point Feature Histogram,PFH),文献[23]提出了快速点特征直方图(Fast Point Feature Histogram,FPFH)。文献[24]提出了基于自适应图卷积的局部特征描述符方法,用于提升点云特征描述精度。文献[25]提出了一种基于超体素的双向最近邻距离比匹配的配准方法。点云特征匹配和基于数学迭代法中的求解变换矩阵类似,都使用 SVD 或其他刚性变换矩阵求解算法求解刚性变换。

端到端的点云配准网络是目前很多专家学者研究的方向,随着深度学习普及度越来越高和 GPU 性能的高速发展,点云配准效率越来越快,精度也越来越高。其工作原理也较为简单,输入两片待配准的点云最终得到的便是刚性变换矩阵。具有代表性的配准网络有 DCP(Deep Closest Point),RPMNet(Robust Point Matching Network),PointnetLk<sup>[26]</sup>,DeepBBS(Deep Best Buddies),DeepVCP<sup>[27]</sup>(Deep Virtual Corresponding Points),MFGNet,IDAM 等。

## 3 本文方法

本文模型结构如图 1 所示,由点云特征信息交互模块、关键点提取模块、对应关系搜索模块和位姿变换求解模块等组成。其中点云特征交互模块包括点云特征提取模块和点云特征交互模块。

首先,使用 GNN 提取点云特征,利用 Transformer 来融合点云特征的上下文信息。经过特征提取和特征融合后的点云信息依旧有冗余存在,为提升点云配准的效率和精准度,我们使用关键点提取模块。其作用是进一步选取特征更显著的点云及其信息。

其次,采用多重矩阵引导的方式,即使用点云匹配点概率矩阵和点云空间信息矩阵双重引导的策略得到对应关系和相应的权重信息。点云匹配点概率矩阵使用 SoftBBS 方法获得,经过 Softmax 操作后可以表示为  $N \times N$  的矩阵。其表示源点云和目标点云之间每一对点对为匹配点对的概率,点云空间信息矩阵首先通过级联操作将点云空间信息聚合成 7 维矩阵,然后利用二维卷积提取特征并表示为 1 维矩阵,最后匹配点概率矩阵和点云空间特征矩阵相加即为最终的对应关系矩阵。众所周知,点云形状特征越相似、点云空间距离越接近,所分配的权重就应该越大。因此,在权重方面,本文同时考虑了两个相似矩阵。将点云匹配点概率矩阵和点云空间信息矩阵重叠后经过置信度计算模块获取置信度,利用置信度计算出对应点对的权重值。

最后,将权重值和由对应关系产生的虚拟点云和目标点云输入位姿变换求解模块进行加权 SVD 计算,得到预测的变换矩阵。同时采用迭代设计,不断优化最终得到的变换矩阵,使其更加接近真实变换值。

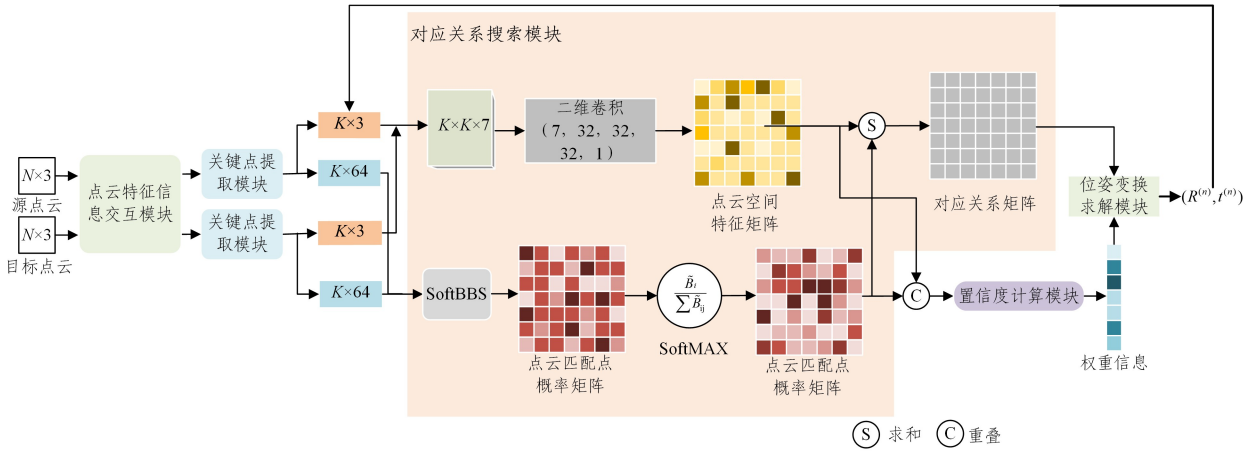


图 1 AMGNet 模型结构

Fig. 1 Network architecture of AMGNet

### 3.1 点云特征交互模块

点云特征交互模块具有点云特征提取、特征交互的功能，模型如图 2 所示。

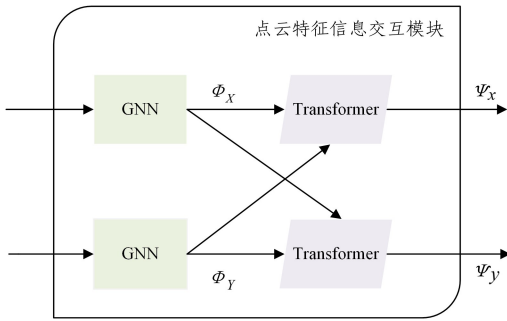


图 2 点云特征交互模块示意图

Fig. 2 Schematic diagram of point cloud feature interaction module

#### 3.1.1 点云特征提取模块

在点云特征提取方面，因点云和二维图像类型数据不同，具有输入不变性和旋转不变性两个特性，故不能使用 CNN 直接处理点云数据。目前有 GNN<sup>[28]</sup>，PointNet<sup>[29]</sup>，DGC-NN<sup>[30]</sup>和 PointNet++<sup>[31]</sup>等点云特征提取网络。点云作为三维数据，构成图结构相对简单，因此使用处理非欧氏距离数据能力较好、可直接对图进行特征提取的 GNN 作为点云特征提取网络。首先将点云中的某点作为顶点，使用  $k$  近邻算法 ( $k$ -Nearest Neighbor,  $k$ -NN) 计算出顶点附近的邻点，将邻点和顶点相互连接便形成了三维图。其次对三维图进行卷积处理，即可得到点云特征。使用特征提取网络的目的是精简点云的数量，提升点云配准的效率和精度，同时可以将稠密的原点云数据变成更具有代表性的数据，高维的特征对于神经网络学习点云特征也有着正面的作用。将目标点云  $x$  和源点云  $y$  输入点云特征提取网络得到的特征记为：

$$\Phi_x = \{x_1, x_2, x_3, \dots, x_N\}, N=64$$

$$\Phi_y = \{y_1, y_2, y_3, \dots, y_N\}, N=64$$

#### 3.1.2 点云特征信息交互

经由点云特征提取模块的特征  $\Phi_x$  和  $\Phi_y$ ，分别将源点云和目标点云的局部特征和全局特征进行融合，但此时两片

点云的特征处于相对独立的状态，不能充分学习点云内部上下文信息和两片点云之间的相互信息。考虑到 Transformer 在自然语音处理方面的贡献<sup>[32]</sup>，它在语音处理中的作用是联系上下文语料，具有联系上下文的功能，本模型也采用了 Transformer 模块。同时，4.3 节表 8 中的数据也说明，融合后的特征对于后续工作有积极作用。

本文模型融合了 DCP 网络中具有多头注意力机制的 Transformer 结构，如图 3 所示。图中  $\Phi_x$  和  $\Phi_y$  分别为源点云和目标点云的特征。 $\Theta_1$  和  $\Theta_2$  为经过注意力机制处理后的特征。文中介绍了  $\Psi_x$  的求解过程， $\Psi_y$  的求解方式与  $\Psi_x$  相同。

$$\begin{aligned} \Psi_x &= \Phi_x + \Theta_1(\Phi_x, \Phi_y) \\ \Psi_y &= \Phi_y + \Theta_2(\Phi_y, \Phi_x) \end{aligned} \quad (1)$$

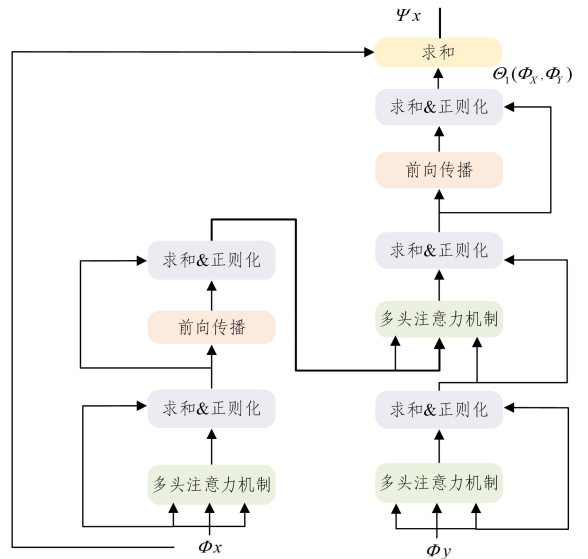


图 3 Transformer 模块

Fig. 3 Transformer module

编码器部分， $\Phi_x$  作为编码器输入通过多头注意力机制学习自身内部的上下文信息，即自注意力机制。采用残差连接并经由正则化输出到前向传播模块，再一次采用残差连接和正则化操作后输入解码器中。

解码器部分， $\Phi_y$  作为解码器的输入同样通过多头注意力

机器学习自身内部的上下文信息,经由残差结构和归一化处理输出后,其与编码器的输出再一次输入多头注意力机制中。此举是为了学习两片不同点云特征的上下文信息,即交叉注意力机制。依次通过求和、正则化操作后再一次进入前向通道模块,得到 $\Theta_1(\Phi_X, \Phi_Y)$ 。和普通的Transformer不同,本文采用残差连接,即将 $\Phi_X$ 和 $\Theta_1(\Phi_X, \Phi_Y)$ 再次求和,目的在于使最终的特征可以和输入的特征保持同步,计算式如式(1)所示。

### 3.2 关键点提取模块

点云配准过程中,若采用逐个读取点云并依次尝试配准的方法会增加配准时间,降低配准效率,占用更多GPU显存,也容易受到一些离群点的干扰,从而导致配准失败<sup>[33]</sup>。为了解决上述问题,本文使用了关键点提取模块,此模块旨在

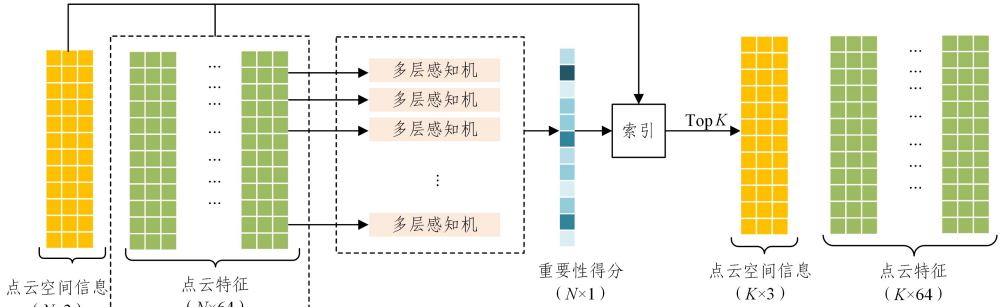


图4 关键点提取模块结构

Fig. 4 Architecture of keypoints selection module

### 3.3 对应关系搜索模块

传统的对应点寻找方法是提取特征后进行内积或其他操作,但仅仅根据特征去确定对应关系可能会导致离群点多、对应关系正确率低。本文使用多重引导方式搜索,即点云间匹配点概率矩阵和点云空间信息矩阵共同寻求对应关系的策略。下面将依次介绍两个相似矩阵的求解方法。

#### 3.3.1 点云匹配点概率矩阵

点云匹配点概率为两片点云中的某一对点为匹配点对的概率值,如果一对点为匹配点对的概率最大,则通过式(2)中的BBS(Best Buddy Similarity)方法计算的值为1。其中 $D_{ij}^* = \|\Phi_{S(i)} - \Phi_{T(j)}\|_2$ 表示点云特征的欧氏距离, $[\cdot]$ 为一个判断函数。如果括号里面为真值则为1,否则为0。故BBS方法只有在*i*和*j*一对点的特征欧氏距离互为最近时 $B_{ij}$ 才为1,此时*i*和*j*才能被称为一对匹配点对。但是式(2)并不是可微的,不能进行反向传播,因此不能直接应用到神经网络中。

$$B_{ij} = [i = \arg \min_j D_{ij}^*] \cdot [j = \arg \min_i D_{ij}^*] \quad (2)$$

因此本文使用SoftBBS方法,和BBS方法不同,SoftBBS增加了参数 $\alpha$ 作为程度控制参数。在BBS中,只有当两个点互为特征距离最近时其值才会为1。但在SoftBBS中,如果是第二相近或者第三相近的点特征,其得分可表示为非零的,这个弹性范围就由 $\alpha$ 来控制。当最佳匹配点得分未知时,使用特征值之间最小距离的中位数计算,表示为 $\xi \cdot \text{median}_j(\min_i \|\Phi_{S(i)} - \Phi_{T(i)}\|)$ 。 $\xi$ 为常量,此处和

提取特征代表性更强的点云,从而减少配准的时间,提升配准的效率。模块的具体框架如图4所示。经过上述章节提取后的特征经由MLP将64维的特征逐渐缩小到1维向量,用于描述重要性得分。其中MLP由全连接层(Fully Connected, FC)实现,层数为(64, 32, 1),激活函数为leakyRelu,每一层都经过归一化(Batch Normalization, BN)处理。得分越高表示点的代表性越强,反之代表性越弱。选取排名较高的*K*个点作为参与后续步骤的点,此时得到前*K*个点的索引,就可以通过索引得到想要的*K*个点的空间信息和特征信息。经过此模块之后,原来的点云和点云特征分别从 $(N \times 3)$ 到 $(K \times 3)$ 、 $(N \times 64)$ 到 $(K \times 64)$ ,并用 $p_{S(i)}$ 和 $p_{T(j)}$ 表示提取完关键点后的点云空间坐标。 $\Phi_{S(i)}$ 和 $\Phi_{T(j)}$ 表示关键点的特征信息。

文献[7]一样设置为0.4。

$$\tilde{B}_{ij} = \frac{e^{-\frac{D_{ij}^*}{\alpha}}}{\sum_i e^{-\frac{D_{ij}^*}{\alpha}}} \cdot \frac{e^{-\frac{D_{ij}^*}{\alpha}}}{\sum_j e^{-\frac{D_{ij}^*}{\alpha}}} \quad (3)$$

式(3)展现的是 $\tilde{B}$ 中第*i*行第*j*列个元素的计算方法,即源点云中的第*i*点和目标点云中的*j*点为匹配点的概率。

$$\tilde{\pi}(p_i) = \frac{\tilde{B}_i}{\sum_{j=1}^M \tilde{B}_{ij}} \quad (4)$$

式(4)为Softmax操作,旨在将SoftBBS求出的概率矩阵进行归一化。其中 $\tilde{B}_i$ 是 $\tilde{B}$ 的第*i*行,最终得到的便是点云间匹配点概率矩阵。

#### 3.3.2 点云空间信息矩阵

点云空间信息由式(5)获取,得到的是7维矩阵,分别用来表示点云间点对距离、点和点之间的方向向量、源点云的坐标。它考虑了比点云欧氏距离更多的空间信息。之后使用多层感知机(MLP)来提取特征,在本文中使用全连接层(FC)来实现MLP,层数为(7, 32, 32, 32, 1),并且使用LeakyRelu作为激活函数,每一层都经过激活函数并且进行批量归一化(BN),最后得到点云空间信息矩阵。

$$s^{(n)}(i, j) = \left[ \|\rho_{S(i)} - \rho_{T(j)}\|; \frac{\rho_{S(i)} - \rho_{T(j)}}{\|\rho_{S(i)} - \rho_{T(j)}\|}; \rho_{S(i)} \right] \quad (5)$$

#### 3.3.3 对应关系获取

将点云间匹配点概率矩阵和点云空间信息矩阵相加便得到了最终的对应关系矩阵,利用对应关系矩阵可获得源点云和目标点云间的对应点对。然而仅仅依靠此时的对应点对有

可能会因为受到离群点或被错误计算的对应点对的影响而配准失败,所以去除离群点便成为了下一步的主要任务。另一方面,由于不同的对应点对所对应的权重大小不一,特征相近的对应点对分配的权重应该越大,反之越小。因此,正确地分配权重不但可以去掉某些离群点对配准的影响还可以提升配准成功率。故本模型也使用了置信度计算模块来计算对应点云置信度并用于计算权重。

### 3.4 置信度计算模块

前一部分采用点云匹配点概率矩阵和点云空间信息




图5 对应关系置信度求解模块

Fig. 5 Network architecture of correspondences credibility computation module

将点云匹配点概率矩阵和点云空间信息矩阵重叠成二维矩阵,通过 $1 \times 1$ 卷积运算将其映射到32维空间,然后利用最大池化和多层感知机不断缩小特征维数直到获得表示匹配结果可信度的一维向量。和关键点提取模块相似,得分高意味着可信度高,在后续使用SVD计算的过程中具有较高的权重,而得分低的点对后续变换求解过程影响很小。使用式(6)计算第*i*个对应关系的权重。

$$\omega_i = \frac{c(i) \cdot \mathbb{I}[c(i) \geq \text{median}(c)]}{\sum_j c(j) \cdot \mathbb{I}[c(j) \geq \text{median}(c)]} \quad (6)$$

其中, $c$ 表示置信度值; $\mathbb{I}$ 作为一个判断函数,用来决策权重值是否大于得分中位数。得到了置信度之后就可以进行最后一步,即求解刚性变换。

### 3.5 位姿变换求解模块

文中变换矩阵求解模块使用加权SVD实现,先介绍SVD求解刚性变换的过程。设 $y$ 是由 $x$ 通过刚性变换获取得到,其旋转矩阵和平移向量表示为 $\mathbf{R}_{xy} \in \text{SO}(3)$ 和 $t_{xy} \in \mathbb{R}^3$ ,利用最小二乘法思想最小化误差 $E(\mathbf{R}_{xy}, t_{xy})$ 求得刚性变换矩阵,其中 $E(\mathbf{R}_{xy}, t_{xy})$ 可表示为:

$$E(\mathbf{R}_{xy}, t_{xy}) = \sum_{i=1}^N \|\mathbf{R}_{xy} x_i + t_{xy} - y_i\|^2 \quad (7)$$

定义 $x$ 和 $y$ 的质心为:

$$\begin{cases} \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \\ \bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \end{cases} \quad (8)$$

定义协方差矩阵 $\mathbf{H}$ 为:

$$\mathbf{H} = \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})^T \quad (9)$$

使用SVD将协方差矩阵分解为 $\mathbf{H} = \mathbf{U}\mathbf{S}\mathbf{V}^T$ ,并最小化 $E(\mathbf{R}_{xy}, t_{xy})$ 可以求得:

$$\begin{cases} \mathbf{R}_{xy} = \mathbf{V}\mathbf{U}^T \\ t_{xy} = -\mathbf{R}_{xy}\bar{x} + \bar{y} \end{cases} \quad (10)$$

矩阵共同引导的对应搜索策略,获得了对应关系。在本节中,这两个匹配矩阵将被用来计算点云配准的置信度。一般来说,当形状特征匹配结果与点云空间匹配结果一致时,匹配结果正确率是非常高的。相比之下,当两个匹配结果不一致时,要考虑它们与配准阶段的冲突程度从而判断匹配结果是否可信。因此,为了减少不正确匹配点的影响,本模型引入了可信度计算模块来评估匹配结果的可靠性。

置信度计算模块如图5所示。

使用SVD计算 $x$ 到 $y$ 所需要的刚性变换过程,如式(8)一式(10)所示。

在点云配准中,将 $x$ 和 $y$ 分别替换成 $pS$ 和 $pT$ 。与SVD不同,AMGNet使用加权SVD求解法,将3.4节所求的置信度 $\omega_i \in [0, 1]$ 加入SVD求解过程中,如式(11)所示:

$$\mathbf{R}, t = \arg \min_{\mathbf{R}, t} \sum_i \omega_i \|\mathbf{R}pS(i) + t - pT(j^*)\| \quad (11)$$

### 3.6 损失函数

本文的损失函数由两部分组成,第一部分为迭代损失函数 $L_{\text{iter}}$ ,第二部分损失函数为 $L_{\text{global}}$ ,具体组成情况如图6所示。

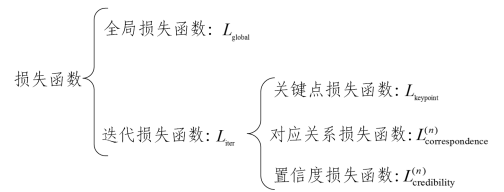


图6 损失函数组成

Fig. 6 Structure of loss function components

迭代损失函数 $L_{\text{iter}}$ 由3部分组成:关键点损失函数 $L_{\text{keypoint}}$ 、对应关系的损失函数 $L_{\text{correspondence}}^{(n)}$ 和置信度损失函数 $L_{\text{credibility}}^{(n)}$ 。其中,关键点的选择只是在提取特征后的工作,并不参与到迭代计算中。因此,选择关键点的损失函数只计算一次即可。式(12)中 $s(i)$ 表示第*i*个点云的关键点得分,使用相互监督损失来训练网络。

$$L_{\text{keypoint}} = \frac{1}{K} \sum_{i=1}^K (s(i) - \sum_{j=1}^K M(i, j) \log(M(i, j)))^2 \quad (12)$$

对应关系的损失函数 $L_{\text{correspondence}}^{(n)}$ 和其第*n*次迭代的损失函数如式(13)所示:

$$L_{\text{correspondence}}^{(n)} = \frac{1}{K} \sum_{i=1}^K -\log(M^{(n)}(i, j^*)) \quad (13)$$

对应关系的置信度损失函数 $L_{\text{credibility}}^{(n)}$ 如式(14)所示:

$$L_{\text{credibility}}^{(n)} = \frac{1}{K} \sum_{i=1}^K -\hat{m}_i \log(c(i)) - (1 - \hat{m}_i) \log(1 - c(i)) \quad (14)$$

其中,  $\hat{m}_i$  代表在真实变换下的对应点距离是否小于所设阈值的标记。最终的迭代损失函数  $L_{\text{iter}}$  如式(15)所示:

$$L_{\text{iter}} = \sum_n (\lambda(n) L_{\text{keypoint}} + L_{\text{correspondence}}^{(n)} + L_{\text{credibility}}^{(n)}) \quad (15)$$

$$\lambda(n) = \begin{cases} 1, & n=1 \\ 0, & n \neq 1 \end{cases} \quad (16)$$

第二部分损失函数是为了计算真实刚性变换和经由神经网络预测得到的刚性变换的差距,称作全局损失函数  $L_{\text{global}}$ ,如式(17)所示:

$$L_{\text{global}} = \|R_{\text{GT}}^T R - I\|^2 + \|t_{\text{GT}} - t\|^2 \quad (17)$$

其中,  $R_{\text{GT}}$  和  $t_{\text{GT}}$  分别代表真实的旋转矩阵和平移矢量,  $R$  和  $t$  表示预测的旋转矩阵和平移矢量。最终的损失函数便由  $L_{\text{iter}}$  和  $L_{\text{global}}$  两部分组成。

## 4 实验

本文的实验在搭载 GeForce GTX 3090 GPU 和 GeForce GTX 2080Ti GPU 的服务器上使用 Pytorch 框架实现。所有实验采用 SGD 优化器,具体实验参数如下:学习率为 0.0001, 衰减率为 0.0001, Dropout 设置为 0.5。使用 ModelNet40<sup>[34]</sup> 和 7Scenes<sup>[35]</sup> 数据集。

Modelnet40 包含来自 40 个人造类别的 12311 个 CAD 模型,其中,训练集包含 9843 个模型,测试集包含 2468 个模型。数据预处理方式同文献[6]。首先从模型中随机抽取 2048 个点,并将它们归一化为一个单位球面。出于一致性考虑,采样 1024 个点的点云,随机生成刚性变换(沿每个轴在  $[0, 45^\circ]$  内旋转,在  $[-0.5 \text{ m}, 0.5 \text{ m}]$  内平移)。7Scenes 是一个广泛使用的室内环境配准的数据集,包括 Chess, Fires, Heads, Office, Pumpkin, RedKitchen 等 7 个场景。使用 296 个样本进行训练,57 个样本用于测试。

### 4.1 合成点云数据配准实验

使用 ModelNet40 数据集进行合成点云数据配准实验。将本文提出的模型与基于数学迭代法的点云配准算法(包括 SAC-IA, ICP, FGR, SAC-IA)和端到端的点云配准网络(包括 PointNetLK, DCP, PRNET, IDAM, DeepBBS, MFGNet)进行了比较。本文均使用 ModelNet40 作为训练集和测试集,设计了点云目标未知、点云类别未知、加入高斯噪声这 3 个实验并多方验证 AMGNet 的性能。评价指标使用了旋转矩阵和平移向量的均方根误差(RMSE)以及平均绝对误差(MAE)。


#### 4.1.1 点云目标未知实验

在点云目标未知实验中,我们在完整的官方训练/测试集上评估模型。其中 9843 个数据用于训练网络,2468 个数据用于测试。将 AMGNet 和多个模型进行了对比,实验结果如表 1 所列。可以看出,AMGNet 在各项指标上均优于其他配准算法。使用 Open3D<sup>[36]</sup> 库可视化配准结果,配准结果如图 7 所示,表中数据来源于文献[6-7]。

表 1 点云目标未知的实验结果

Table 1 Results of unseen point clouds

Model	RMSE(R)	MAE(R)	RMSE(t)	MAE(t)
ICP	34.990	25.4600	0.29600	0.25300
FGR	8.720	1.8600	0.01700	0.00500
Go-ICP	11.850	2.5800	0.02500	0.00700
SAC-IA	6.040	1.9000	0.01600	0.01200
PointNetLK	16.740	7.5500	0.04500	0.02500
DCP	6.710	4.4500	0.02700	0.02000
PRNet	3.200	1.4500	0.01600	0.01000
IDAM	2.950	0.7600	0.02100	0.00500
MFGNet	1.560	0.7600	0.00600	0.00200
DeepBBS	0.041	0.0210	0.00070	0.00040
Ours	<b>0.025</b>	<b>0.0046</b>	<b>0.00058</b>	<b>0.00002</b>



注:选择了 ModelNet40 数据集中的花盆、椅子、马桶、瓶子、碗、飞机作为可视化结果图。在每一对对比图中,左侧为配准前的结果,右侧为配准后的结果。

图 7 配准结果图

Fig. 7 Diagram of registration results

#### 4.1.2 点云类别未知实验

为了测试模型在不同方法上的泛化性,设计了点云类别不可见实验。在训练集中的前 20 个类别上训练模型,同时在测试集中的其他 20 个类别上测试模型,结果如表 2 所列。可以发现,AMGNet 在各项指标上依然优于其他的模型。表中的其他数据来源同表 1。

表 2 点云类别未知实验结果


Table 2 Results of unseen point cloud categories

Model	RMSE(R)	MAE(R)	RMSE(t)	MAE(t)
ICP	34.270	25.630	0.2940	0.2500
FGR	8.320	1.210	0.0130	0.0040
Go-ICP	13.860	2.910	0.0220	0.0060
SAC-IA	3.890	1.710	0.0190	0.0130
PointNetLK	22.940	9.660	0.0610	0.0330
DCP	9.770	6.950	0.0340	0.0250
PRNet	4.990	2.330	0.0210	0.0150
MFGNet	1.470	0.430	0.0080	0.0020
DeepBBS	0.075	0.040	0.0011	0.0006
Ours	<b>0.062</b>	<b>0.035</b>	<b>0.0008</b>	<b>0.0004</b>

#### 4.1.3 高斯噪声

在实际应用中,点云不可避免地会受到各种噪声的影响。为了验证模型在噪声下的抗干扰性,本文通过在点云数据中加入高斯噪声进行点云配准实验,配准结果图如图 8 所示。本实验将均差为 0,标准差为 0.01 的高斯噪声加到点云中,并将噪声剪裁到  $[-0.05, 0.05]$  的范围内。实验参数与第一个实验保持一致。实验结果如表 3 所列。可以看到,加入高斯噪声之后所有的网络配准性能均有一定程度的下降,但本文模型在 RMSE 上依然有着良好的表现,MAE(t) 指标上

不如 Go-ICP。这也说明了本文模型具有一定程度的抗干扰能力。表中其他模型实验数据来源同表 1 和表 2。



注:从左到右依次是飞机、马桶、人的点云。在每对点云中,左侧为配准前的结果,右侧为配准后的结果。

图 8 ModelNet40 加入高斯噪声的配准结果

Fig. 8 Registration results of adding Gaussian noise to ModelNet40

表 3 点云数据中加入高斯噪声的结果

Table 3 Results on point clouds data with Gaussain noise

Model	RMSE(R)	MAE(R)	RMSE(t)	MAE(t)
ICP	33.86	25.07	0.292	0.249
FGR	27.13	12.06	0.064	0.036
Go-ICP	11.45	2.53	0.023	<b>0.004</b>
SAC-IA	11.95	3.32	0.027	0.016
PointNetLK	19.94	9.08	0.057	0.032
DCP	6.88	4.53	0.028	0.021
PRNet	4.32	2.05	0.017	0.012
MFGNet	3.56	1.52	0.019	0.008
DeepBBS	4.19	1.75	0.044	0.023
Ours	<b>2.79</b>	<b>1.14</b>	<b>0.011</b>	<b>0.006</b>

## 4.2 真实场景下配准实验

上述 ModelNet40 数据集是人工制作的模型,为了验证模型在真实数据集上的表现,在 7Scenes 数据集上做了训练与测试,配准效果图如图 9 所示。因实验数据预处理方式和文献[37]一致,故表中其他网络实验数据、评价指标均与文献[37]一致,且文献[37]中的数据也表明 Modelnet40 数据集在 MIE 指标上已经降低至 0.0001 或 0.0000。为方便将 AMGNet 与其他模型做对比,本文仅在真实场景数据集上使用 MIE 做为评价指标。在参数设置方面,提取的特征维度为 256,学习率为 0.01。评价指标为 MAE(R), MAE(t), MIE(R), MIE(t)。MIE 的计算方法如式(18)所示:

$$Error(R) = \angle(R_{GT}^{-1}\hat{R}), Error(t) = \|t_{GT} - \hat{t}\|_2 \quad (18)$$

其中,  $\{R_{GT}, t_{GT}\}$  和  $\{\hat{R}, \hat{t}\}$  分别代表真实变换值和预测变换值。 $\angle(X)$  是将旋转矩阵变为以度为单位的角度值,计算式如式(19)所示:

$$\angle(X) = \arccos\left(\frac{tr(X) - 1}{2}\right) \quad (19)$$



注:从左到右的 3 个场景分别为 stairs, heads, offices。在每对点云图中,左侧为配准前的图,右侧为配准之后的效果图。

图 9 7Scence 数据集上的配准结果

Fig. 9 Registration results on 7Scence dataset

在对比实验方面,与传统的点云配准方法,即无监督配准方法、有监督配准方法进行对比。结果如表 4 所列,其中 ICP, Go-ICP, Super4PCS, RANSAC 为传统的点云配准方法; IDAM 和 RPMNet 为基于学习的点云配准网络; FMR 为半监督的点云配准网络。结果表明,本文方法在 MAE(R),

MAE(t), MIE(t) 这 3 项指标上均达到了优良的效果,但是在 MIE(R) 指标上不如 RPMNet。

表 4 7Scenes 数据集上的实验结果

Table 4 Results on 7Scenes dataset

Model	MAE(R)	MAE(t)	MIE(R)	MIE(t)
ICP	6.0091	0.0130	13.04840	0.0260
Go-ICP	7.0968	0.0136	14.97010	0.0274
Super4PCS	1.6567	0.0081	2.93880	0.0162
RANSAC	1.2325	0.0062	2.18750	0.0124
RPMNet	0.3885	0.0021	<b>0.07649</b>	0.0042
IDAM	5.6727	0.0303	11.59490	0.0629
FMR	2.5438	0.0072	4.90890	0.0150
Ours	<b>0.1502</b>	<b>0.0006</b>	0.28980	0.0013

## 4.3 消融实验

本节进行了消融实验,以验证该模型各个部分以及各个变量对模型性能的影响。首先,改变模型的迭代次数,迭代次数按 6, 5, 4, 3 顺序排列,实验结果如表 5 所列。接着改变点云特征提取的维度,按顺序设定维度分别为 128, 64 和 32,得到的结果如表 6 所列。表 7—表 9 分别列出了损失函数、注意力机制以及不同点云特征提取网络对该模型指标的影响。对于实验参数的设计,均选择给数据集加入高斯噪声,与上一节合成点云配准实验中心点云高斯噪声实验的参数设置相同。

表 5 点云迭代次数对实验数据的影响

Table 5 Effect of number of point cloud iterations on experimental data

Num_iter	RMSE(R)	MAE(R)	RMSE(t)	MAE(t)
6	<b>2.79</b>	1.14	<b>0.011</b>	0.006
5	2.96	<b>1.08</b>	0.013	<b>0.005</b>
4	3.31	1.59	0.021	0.011
3	3.27	1.51	0.014	0.008

表 6 点云特征维度对实验数据的影响

Table 6 Effect of point cloud feature dimension on experimental data

dims	RMSE(R)	MAE(R)	RMSE(t)	MAE(t)
128	3.23	1.21	0.0141	<b>0.0060</b>
64	<b>2.79</b>	<b>1.14</b>	<b>0.0112</b>	0.0066
32	3.11	1.26	0.0164	0.0078

表 7 损失函数对模型的影响

Table 7 Effect of loss function on model

Loss	RMSE(R)	MAE(R)	RMSE(t)	MAE(t)
$L_{iter}$	3.11	1.16	0.0162	0.0075
$L_{iter} + L_{global}$	<b>2.79</b>	<b>1.14</b>	<b>0.0112</b>	<b>0.0066</b>

表 8 注意力机制对模型的影响

Table 8 Effect of attentional mechanisms on model

Transformer	RMSE	MAE	RMSE	MAE
无注意力机制	3.05	1.11	0.0138	<b>0.0063</b>
有注意力机制	<b>2.79</b>	<b>1.14</b>	<b>0.0112</b>	0.0066

表 9 不同特征提取网络的影响

Table 9 Effect of different feature extraction networks

Transformer	RMSE	MAE	RMSE	MAE
GNN	<b>2.79</b>	<b>1.14</b>	<b>0.0112</b>	<b>0.0066</b>
DGCNN	8.25	4.93	0.0674	0.0451
PointNet	10.18	5.29	0.0693	0.0491

由表 5 可知,增加迭代次数有利于减少误差,但迭代次数超过 5 之后某些指标有所下降,并且迭代次数的增加会不可避免地导致点云配准时间的增加,这样会导致配准效率变低。因此,为了保证精度和配准效率均达到最优,本模型将模型迭代次数设为 6。在提取特征维度选择方面,随着维度升高,可以发现各项指标均有提升,但从表 6 不难看出,维数上升过多会导致模型配准精度下降,且在训练过程中还发现,维度上升会带来训练时间过长的的问题。因此从评价指标和训练时间方面来看,64 维的特征维度是最优选择。

为了验证本文提出的两部分损失函数可以达到最好的效果,设计了关于损失函数的消融实验,将损失函数模块中的全局损失函数去掉,仅仅留下迭代损失函数和使用全部的损失误差做比较,结果如表 7 所列。可以看到,加入全局损失函数的效果更好。这也证明了本文提出的两部分损失函数对于训练模型有更好的优化效果。

由表 8 可知,注意力机制在模型中起到了一定的优化作用,这也证明了通过注意力机制对特征进行进一步处理对模型性能提升有正面作用。表 9 中的实验结果表明,AMGNet 可以适应除 GNN 之外的点云特征提取网络,如 DGCNN 和 PointNet,并且使用 GNN 效果最佳。

**结束语** 本文提出了一种结合注意力机制的多重矩阵联合搜索对应关系以及确定对应点对权重的配准方法 AMG-Net。经实验验证,在人工合成数据集的各个评价指标中所提模型性能均有一定提升。同时,在添加高斯噪声的条件下,与其他模型相比,其各项指标也有所提高。说明 AMGNet 具有鲁棒性强、配准精度高等优点。同时,在消融实验部分还验证了添加 Transformer 模块对点云特征进行上下文信息融合后,对于模型的性能有着积极作用;并且该模型具有优良的适配性,能够适配多个点云特征提取网络,如 DGCNN 和 Pointnet。但模型在加入高斯噪声的情况下对模型效果的提升程度不及点云目标未知、点云类别未知两种情形,并且加大噪声范围后影响更大。而且,所提方法在 7Scene 数据集上的实验指标数值也不如在 ModelNet40 数据集上的实验数值,说明模型在抗干扰能力方面以及在真实数据集上的表现稍有不足。因此,下一步的工作重点在于如何提升模型的抗干扰能力。另一方面,可以发现,在配准结果上旋转方面的误差比平移方面的误差更大,因此可以将如何缩小旋转和平移方面的误差间的差距作为进一步的研究目标。

## 参 考 文 献

- [1] LI Z M, ZHANG Y P, LIU Y J, et al. Deformable Graph Convolutional Networks Based Point Cloud Representation Learning [J]. *Computer Science*, 2022, 49(8): 273-278.
- [2] HUANG X, MEI G, ZHANG J, et al. A comprehensive survey on point cloud registration[J]. *arXiv:2103.02690*, 2021.
- [3] QIN H X, LIU Z T, TAN B Y. Review on deep learning rigid point cloud registration[J]. *Journal of Image and Graphics*, 2022, 27(2): 329-348.
- [4] LI J W, ZHAN J W. Review on 3D point cloud registration method[J]. *Journal of Image and Graphics*, 2022, 27(2): 349-367.
- [5] LI J, ZHANG C, XU Z, et al. Iterative distance-aware similarity matrix convolution with mutual-supervised point elimination for efficient point cloud registration[C]// *European Conference on Computer Vision*. Berlin: Springer, 2020: 378-394.
- [6] WANG H, LIU X, KANG W, et al. Multi-features guidance network for partial-to-partial point cloud registration[J]. *Neural Computing and Applications*, 2022, 34(2): 1623-1634.
- [7] HEZRONI I, DRORY A, GIRYES R, et al. DeepBBS: Deep Best Buddies for Point Cloud Registration[C]// *2021 International Conference on 3D Vision (3DV)*. Piscataway, NJ: IEEE, 2021: 342-351.
- [8] WANG Y, SOLOMON J M. Deep closest point: Learning representations for point cloud registration[C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. Piscataway, NJ: IEEE, 2019: 3523-3532.
- [9] 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)*. Piscataway, NJ: IEEE, 2020: 11821-11830.
- [10] BESL P J, MCKAY N D. Method for registration of 3-D shapes [C]// *Sensor Fusion IV: Control Paradigms and Data Structures*. Spie, 1992: 586-606.
- [11] YANG J, LI H, CAMPBALL D, et al. Go-ICP: A globally optimal solution to 3D ICP point-set registration[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 38(11): 2241-2254.
- [12] HEXSEL B, VHAVLE H, CHEN Y. DICP: Doppler Iterative Closest Point Algorithm[J]. *arXiv:2201.11944*, 2022.
- [13] MAGNUSSON M, LILIENTHAL A, DUCKETT T. Scan registration for autonomous mining vehicles using 3D-NDT[J]. *Journal of Field Robotics*, 2007, 24(10): 803-827.
- [14] AIGER D, MITRA N J, COHEN-OR D. 4-points congruent sets for robust pairwise surface registration[J]. *ACM Transactions on Graphics*, 2008, 27(3): 1-10.
- [15] FISCHLER M A, BOLLES R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography[J]. *Communications of the ACM*, 1981, 24(6): 381-395.
- [16] MELLADO N, AIGER D, MITRA N J. Super 4PCS Fast Global Pointcloud Registration via Smart Indexing [J]. *Computer Graphics Forum*, 2014, 33(5): 205-215.
- [17] KAMOUSHI P, LAZARD S, MAHESHWARI A, et al. Analysis of farthest point sampling for approximating geodesics in a graph[J]. *Computational Geometry*, 2016, 57: 1-7.
- [18] RUSINKIEWICZ S, LEVOV M. Efficient variants of the ICP algorithm[C]// *Proceedings third International Conference on 3-D Digital Imaging and Modeling*. Piscataway, NJ: IEEE, 2001: 145-152.
- [19] PRAKHYA S M, LIU B, LIN W. Detecting keypoint sets on 3D point clouds via Histogram of Normal Orientations[J]. *Pattern Recognition Letters*, 2016, 83: 42-48.
- [20] CHUA C S. Point Signatures: A New Representation for 3D Object Recognition[J]. *International Journal of Computer Vision*, 1997, 25: 63-85.

- [21] FROME A, HUBER D, KOLLURI R, et al. Recognizing objects in range data using regional point descriptors[C] // European Conference on Computer Vision. Berlin: Springer; 2004: 224-237.
- [22] RUSU R B, BLODOW N, MARTON Z C, et al. Aligning point cloud views using persistent feature histograms[C] // 2008 IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway, NJ: IEEE; 2008: 3384-3391.
- [23] RUSU R B, BLODOW N, BEETZ M. Fast point feature histogram (FPFH) for 3D registration[C] // 2009 IEEE International Conference on Robotics and Automation. Piscataway, NJ: IEEE; 2009: 3212-3217.
- [24] ZHANG W L, CHENG L, REN M F, et al. Point Cloud Registration Based on AGConv Local Feature Descriptors[J]. Computer Engineering, 2023, 49(11): 231-237.
- [25] LI X M, WANG C Y, LIU X L, et al. Point cloud registration method based on supervoxel bidirectional nearest neighbor distance ratio [J]. Journal of Jilin University(Engineering and Technology Edition), 2022, 52(8): 1918-1925.
- [26] AOKI Y, GOFORTH H, SRIVATSAN R A, et al. Pointnetlk: Robust & efficient point cloud registration using pointnet[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE; 2019: 7163-7172.
- [27] LU W, WAN G, ZHOU Y, et al. Deepvcv: An end-to-end deep neural network for point cloud registration[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ: IEEE; 2019: 12-21.
- [28] MONTI F, BOSCAINI D, MASCI J, et al. Geometric deep learning on graphs and manifolds using mixture model cnns[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway, NJ: IEEE; 2017: 5425-5434.
- [29] CHARLES R Q, SU H, KAICHUN M, et al. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway, NJ: IEEE; 2017: 77-85.
- [30] WANG Y, SUN Y, LIU Z, et al. Dynamic graph cnn for learning on point clouds[J]. ACM Transactions on Graphics (TOG), 2019, 38(5): 1-12.
- [31] QI C R, YI L, SU H, et al. Pointnet++: Deep hierarchical feature learning on point sets in a metric space[J]. arXiv:1706.02413, 2017.
- [32] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. arXiv:1706.03762, 2017.
- [33] LI J, ZHANG C, XU Z, et al. Iterative distance-aware similarity matrix convolution with mutual-supervised point elimination for efficient point cloud registration[C] // Computer Vision-ECCV 2020; 16th European Conference, Part XXIV 16. Springer International Publishing, 2020: 378-394.
- [34] WU Z R, SONG S, KHOSLA A, et al. 3D ShapeNets: A deep representation for volumetric shapes[C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE; 2015: 1912-1920.
- [35] SHOTTON J, GLOCKER B, ZACH C, et al. Scene coordinate regression forests for camera relocalization in RGB-D images [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE; 2013: 2930-2937.
- [36] ZHOU Q Y, PARK J, KOLTUN V. Open3D: A modern library for 3D data processing[J]. arXiv:1801.09847, 2018.
- [37] SHEN Y, HUI L, JIANG H, et al. Reliable Inlier Evaluation for Unsupervised Point Cloud Registration[C] // Proceedings of the AAAI Conference on Artificial Intelligence. California: Association for the Advancement of Artificial Intelligence (AAAI), 2022: 2198-2206.



**LIU Xuheng**, born in 1998, postgraduate. His main research interests include point cloud registration and three-dimensional reconstruction.



**BAI Zhengyao**, born in 1967, Ph.D., professor, master supervisor. His main research interests include signal processing, image processing, pattern recognition and machine learning, etc.

(责任编辑:何杨)