第 53 卷第 5 期
2025 年 5 月

同济大学学报(自然科学版)
JOURNAL OF TONGJI UNIVERSITY(NATURAL SCIENCE)

Vol. 53 No. 5
May 2025

文章编号：0253-374X(2025)05-0823-08 **DOI**：10. 11908/j. issn. 0253-374x. 23344

基于偏置注意力边特征的鲁棒点云配准算法

柳先辉，葛依凡
(同济大学 电子信息与工程学院，上海 200092)

摘要：刚性点云配准已成为机器人和计算机视觉领域的一项基本任务。为了解决基于空间距离的迭代最近点(ICP)对初始姿态敏感及噪声不鲁棒的问题，提出了一种基于偏置注意力边特征的鲁棒点云刚性配准算法。该方法首先使用动态图神经网络学习混合特征，融合空间坐标、局部几何信息和全局特征。然后利用偏置注意力模块增强点云特征的显式上下文信息，有效减少了点云变换和噪声带来的影响。其次，通过定义在混合特征上的退火参数和行列交替归一化得到点云之间对应关系的软匹配矩阵。最后采用奇异值分解估计变换，实现了端到端的点云配准算法，提高了配准的精度和鲁棒性。在ModelNet40数据集上进行的大量实验表明，该方法优于传统方法和基于学习的方法，取得了较好的性能。

关键词：点云配准；混合特征；神经网络；迭代
中图分类号：TP391. 41 **文献标志码**：A

Robust Point Cloud Registration Algorithm Based on Biased Attention Edge Features

LIU Xianhui, *GE Yifan*
(College of Electronic and Information Engineering, Tongji University, Shanghai 200092, China)

Abstract: Rigid point cloud registration is a fundamental task in robotics and computer vision. To address the sensitivity of traditional spatial distance-based iterative closest point (ICP) algorithms to initial transformations and noise, this paper proposed a robust rigid registration algorithm based on bias-attention edge features. First, a dynamic graph convolutional neural network was used to extract hybrid features that fuse spatial coordinates, local geometry information and global feature. Next, a biased attention module was utilized to enhance the explicit point cloud context information, which effectively reduced the effects of point cloud noise. Then, the algorithm computed soft matching matrix for the corresponding relationship between the point clouds by defining annealing parameters on mixed features and performing alternate normalization of rows and columns. Finally, the transformation between point cloud is estimated using singular value decomposition in an end-to-end framework, enhancing both the accuracy and robustness of registration. Extensive experiments conducted on the ModelNet40 dataset show that the proposed algorithm out perform both traditional and state-of-the-art learning-based methods.

Keywords: point cloud registration; hybrid features; neural networks; iteration

高速及高精度传感器的快速发展使得点云逐渐成为3D世界中的主要数据形式。点云配准是三维数据处理的关键步骤，即将处于不同视角下的点云数据通过一定的算法计算得到旋转平移等刚性运动参数[1]，最终转换到同一坐标系中。随着点云配准技术被广泛应用于机器人、自动驾驶和增强现实等领域，配准已成为计算机视觉领域的一项基本任务。

在传统配准方法中，最典型的算法为迭代最近点算法[2](iterative closest point，ICP)及其变种[3]，ICP迭代地通过最近点对进行空间变换的计算，从而最小化两组点云之间的距离误差。尽管其通俗易用，但却对初始姿态和噪声非常敏感，容易陷入局部最优解。

随着深度学习的发展，越来越多的研究将神经网络方法运用于点云配准[1]。将深度学习的相关工具用于解决点云配准的问题，存在两个需要解决的问题。① 需要建立适应网络学习的点云表示形式；② 需要利用深度学习强大的特征分析能力来预测

收稿日期：2023-10-10
基金项目：国家自然基金项目(U1966210)；上海市科技创新行动计划项目(21511104302)
第一作者：柳先辉，副研究员，博士生导师，工学博士，主要研究方向为机器视觉、智能制造。
E-mail：lxh@tongji. edu. cn
通信作者：葛依凡，硕士生，主要研究方向为深度学习、点云配准。E-mail：geyifan@tongji. edu. cn

论文拓展介绍

可靠的对应点对,从而建立有效的迭代优化方法完成配准过程。2019年前后的配准工作[4-5],主要是基于PointNet[6]提取点云特征,以解决问题①。但PointNet无法充分捕捉点云中的局部几何特征。针对问题②,使用传统的优化方法来对齐编码后的特征向量,整个计算过程的效率会较为低下。最近几年,Kadam等[7]提出可以根据局部特征与全局特征的相似性选出点对用于估计变换,Jiang等[8]则将不匹配点对描述成为内点和外点的分类问题,深度学习为寻找点对匹配提供了更多思路。

然而,这些技术通常要求点云具有独特的几何结构或者较好的初始位姿,并且常常难以处理噪声问题,易陷入局部最优从而导致配准出现异常。针对以上问题,本文提出了一种新的深度学习模型偏置注意力动态图卷积神经鲁棒点匹配网络(offset attention dynamic graph convolutional neural network robust point matching network, OADGRPMNet),OADGRPMNet在基于学习特征的鲁棒点匹配网络[5](robust point matching network, RPMNet)的基础上改进,提出偏置注意力动态图卷积神经网络模块(offset attention dynamic graph convolutional neural network, OADGCNN),该模块既保有了边卷积操作提取局部几何信息的能力,又能够注意到多层次多规模语义信息,且具有较好的可集成性和可移植性。为了预测更为鲁棒的对应点对关系,引入二级网络控制离群值的数量和软匹配关系的概率分布。最后采用奇异值分解法(singular value decomposition, SVD)求取点云的变换参数,通过迭代的方式实现配准误差的最小化。在ModelNet40数据集[9]上进行的大量实验表明,本文提出的方法优于传统方法和基于深度学习的方法,取得了较好的性能。本文的主要工作内容有以下几点:

(1)针对实际点云数据中存在因局部几何形状相似而导致的"配不准"问题,构建了一个基于图注意力的新型局部点云特征提取网络OADGCNN用于获得鲁棒性更强的局部特征描述,通过构建局部邻域图在保证点云置换不变性的同时结合边卷积提取多维度的局部特征向量,提高了点云数据空间信息的利用率。

(2)为了解决实际点云数据中存在的噪声问题,引入了偏置注意力模块[10](offset attention, OA),该模块通过计算点云中各点的重要性权重,使得网络在动态更新图结构的过程中加强了模型对于信息丰富区域的关注,在融合多层次点云语义信息时学习识别关键匹配点,提高了配准效率。

(3)相较于现有研究,本文基于上述特征提取网络提出了一种更为有效的端到端配准算法来处理点云配准问题。在干净、不可见和添加噪声的ModelNet40数据集上的多组实验评估中,OADGRPMNet在理想和模拟真实情况下都具有不错的性能,在原模型的基础上旋转误差指标平均降低了88.95 %,平移误差指标平均降低了81.31 %。

1 算法模型

1.1 符号定义

表1为论文使用到的符号的形式化定义和说明。

1.2 算法框架

定义点云$X\in \mathrm{R}^{J\times 3}$和$Y\in \mathrm{R}^{K\times 3}$为源点云Source

表1 符号对照表

Tab. 1 Comparison of symbols

符号	符号名称	定义说明
$\boldsymbol{R}$	旋转矩阵	$\boldsymbol{R}\in \mathrm{SO}(3)$,用于描述一个点云的旋转变换
$\boldsymbol{t}$	平移向量	$\boldsymbol{t}\in \mathrm{R}^3$,用来表示点云的平移距离
X,Source	源点云	$X\in \mathrm{R}^{J\times 3}$,将要被变换的点云集合
Y,Target	目标点云	$Y\in \mathrm{R}^{K\times 3}$,作为参照的点云集合
$\boldsymbol{M}$	软匹配矩阵	$\boldsymbol{M}=\{0,1\}^{J\times K}$,表示点之间匹配关系的概率或权重矩阵
α	阈值参数	判断点对是否为对应点对的标准
β	退火参数	控制软匹配矩阵的"硬度"
n_i	迭代次数	模型迭代次数,i表示第几次迭代
$\tilde{X}_i$	中间点云	源点云经过第i次的迭代变换后的点云,是第$i+1$次的输入
$F_{(\cdot)}$	点云特征	经过特征提取模块后得到的网络特征
p_i,q_j	点云中的点	p_i表示一个点,q_j表示以p_i为中心的邻域点
$N(\cdot)$	邻域	表示以某个点为中心的邻域点的点集合
$f_e(p_i)$	边特征	$f_e(p_i)\in \mathrm{R}^{N\times d}$,表示点$p_i$上的$d$维特征
$G(p_i,N(p_i))$	邻域图	以p_i为中心,邻域集合$N(\cdot)$为节点的邻域图
$h(p_i,q_1-p_i)$	边特征函数	拟合函数用于提取边特征

和目标点云 Target。点云配准的目标就是找到一个刚性变换$\{\boldsymbol{R},\boldsymbol{t}\}\in SE(3)$使得在同一坐标系下$X$对齐$Y$，其中$\boldsymbol{R}\in SO(3)$为旋转矩阵，$\boldsymbol{t}\in R^3$为平移向量。图 1 展示了整个模型框架，整个网络参考迭代最近点算法及其变体，设定为迭代改进配准方式。在每一个迭代i中，源点云X首先经过刚体变换$\{\boldsymbol{R}_{i-1},\boldsymbol{t}_{i-1}\}$得到$\tilde{X}_i$，该刚体变换由上一个迭代估计得到。OADGCNN 特征学习网络提取两个点云的混合特征，同时一个二级神经网络用于预测最优的退火参数α和β。利用混合特征和α、β参数计算初始匹配矩阵。最后采用 SVD 计算更新后的变换$\{\boldsymbol{R}_i,\boldsymbol{t}_i\}$用于下一轮迭代。

整个模型框架的训练伪代码如下所示：

输入：源点云$X\in R^{J\times 3}$，目标点云$Y\in R^{K\times 3}$，训练轮数 N_epoches，模型迭代次数n_i。

输出：使得损失函数收敛的模型参数。

1：模型初始化

2：For epoch = 1 to N_epoches：

3：For(X, Y)in 训练数据：

4：For i = 1 to n_i：

5：$\tilde{X}_i\leftarrow$旋转平移变换$\left(\tilde{X}_{i-1},\{\boldsymbol{R}_{i-1},\boldsymbol{t}_{i-1}\}\right)$

6：$\alpha,\beta\leftarrow$参数预测网络$\left(\tilde{X}_i, Y\right)$

7：$F_{\tilde{X}_i}\leftarrow$特征提取模块OADGCNN$\left(\tilde{X}_i\right)$，

$F_Y\leftarrow$特征提取模块OADGCNN(Y)

8：$\boldsymbol{M}_i\leftarrow e^{-\beta(\|F_{\tilde{X}_i}-F_Y\|_2{}^2-\alpha)}$，Sinkhorn 归一化$\boldsymbol{M}_i$满足双随机约束

9：$\hat{Y}\leftarrow\boldsymbol{M}_i\cdot Y$ //根据匹配矩阵得到源点云变换后对应的点云位置

10：$\{\boldsymbol{R}_{i-1},\boldsymbol{t}_{i-1}\}\leftarrow$奇异值分解求解变换$\left(\tilde{X}_i,\hat{Y}\right)$

11：End for

12：计算损失函数

13：反向传播梯度并更新模型参数

14：End for

15：End for

16：保存模型参数

定义一个双重随机约束矩阵$\boldsymbol{M}=[0,1]^{J\times K}$来表示点与点之间的匹配概率，每个元素含义为：$m_{jk}$越接近 1，表示$x_j$和$y_k$是对应点对的概率越大。配准问题可以表述为寻找刚性变换$\{\boldsymbol{R},\boldsymbol{t}\}$和最能将$X$中的点映射到$Y$上的对应矩阵$\boldsymbol{M}$，即：

$$\arg\min_{\boldsymbol{M},\boldsymbol{R},\boldsymbol{t}}\sum_{j=1}^{J}\sum_{k=1}^{K}m_{jk}\left(\|\boldsymbol{R}x_j+\boldsymbol{t}-y_k\|_2{}^2-\alpha\right)\tag{1}$$

其中α是一个参数，用于控制异常对应关系的数量。首先对每个元素$m_{jk}\in\boldsymbol{M}$进行如下初始化：

$$m_{jk}\leftarrow e^{-\beta(\|\boldsymbol{R}x_j+\boldsymbol{t}-y_k\|_2{}^2-\alpha)}\tag{2}$$

β是在每个迭代步骤中增加的退火参数，较小的初始值会平均分配概率，这有助于避免陷入局部最小值。然后执行交替的行和列归一化，以满足双重随机约束，这是 Sinkhorn[11]操作的结果。一旦对应关系$\boldsymbol{M}$被估计，即可计算刚性变换$\{\boldsymbol{R},\boldsymbol{t}\}$。

当点与点之间不一定存在一一对应关系的情况下，即$J\neq K$或存在离群非匹配点时，通过引入松弛变量将式(1)中对$\boldsymbol{M}$的不等式约束重新转换成等式约束：

$$\sum_{k=1}^{K}m_{jk}\leqslant 1,\ \forall j\quad\rightarrow\sum_{k=1}^{K+1}m_{jk}=1,\ \forall j\tag{3}$$

本文对式(2)做出两个主要的改进：① 用基于学习的混合特征距离取代原本的空间距离(见 1.3 节)；②退火参数α和β使用网络进行学习而非固定不变(见 1.4 节)。

1.3　OADGCNN 特征提取网络

将式(2)中的空间距离替换成用网络学习到的特征之间的距离得到式(4)，其中F_{x_j}和F_{y_k}分别是$\tilde{x}_j\in\tilde{X}_i$，$y_k\in Y$的网络特征，用学习到的特征替换原本的空间坐标可以帮助算法更好地利用到点云信息，从

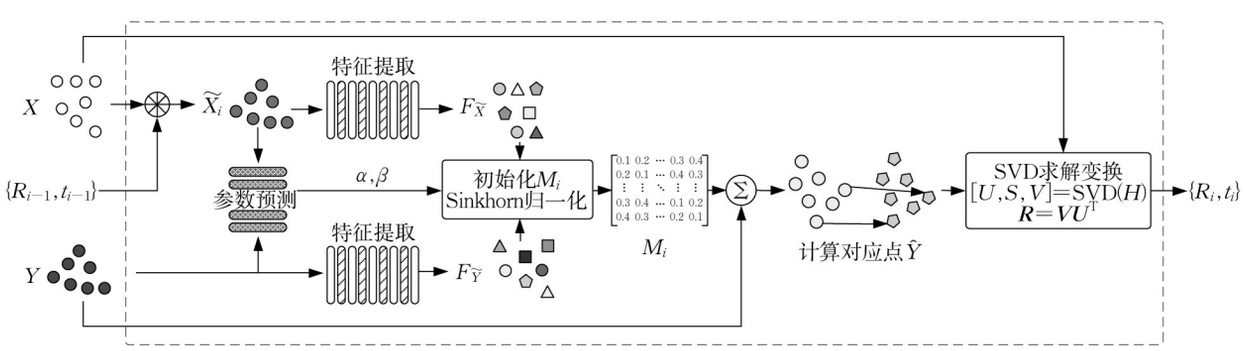

图 1　模型架构

Fig. 1　Architecture of the model

而避免陷入局部最优。在本文中$F_{(\cdot)}$使用OADGCNN网络进行特征提取,其架构如图2所示。

$$m_{jk} \leftarrow e^{-\beta(\| F_{x_j} - F_{y_k} \|_2^2 - \alpha)} \tag{4}$$

$$\begin{aligned} f_e(p_i) &= f_e(G(p_i, N(p_i))) \\ &= \max\{h(p_i, q_1 - p_i), h(p_i, q_2 - p_i), \ldots, h(p_i, q_k - p_i)\} \end{aligned} \tag{5}$$

其中:图G是以p_i为中心点构建起的局部图,有k个临近点。使用多层感知机(multilayer perceptron,MLP)拟合$h(x)$函数提取边特征,p_i维护全局结构信息,$q_j - p_i$维护局部邻域信息。最后再应用聚合函数max(•)提取所有边的主要特征,该函数与点序无关,具备置换不变性,具体流程见图3a。

f_e在经过多次计算更新每个点的特征之后,计算出的高维特征融合了全局信息和局部信息。为了提高关键点检测效率,添加OA模块来依据相似性显式增强上下文信息。该层的架构如图3b所示,引入偏置操作以此提高注意力权重并减少噪音的影响。

整个OADGCNN模块的伪代码如下所示:

输入:点云$\tilde{X}_i \in R^{J\times 3}$,特征通道Channel_list=[32, 32, 64, 128]

输出:点云特征$F_{\tilde{X}_i}$

1:For stage = 1 to 4:

//EdgeConv

2:$X_local_k \in R^{J\times k\times 3} \leftarrow$ k-NN$(\tilde{X}_i)$//对每个点建立k邻域(k-nearest neighbors,k-NN)

3:$h(X) \in R^{J\times k\times \text{channel_list}[\text{stage}]} \leftarrow$

多层感知机$(X, X_local_k - X)$

4:边卷积$f_e \in R^{J\times \text{channel_list}[\text{stage}]} \leftarrow \max(h(X))$

//Offset-Attention

5:$f_{in} \leftarrow f_e$ //边卷积特征作为偏置注意力模块的输入

6:$\boldsymbol{Q}, \boldsymbol{K} \in R^{J\times \text{channel_list}[\text{stage}]/4}$, $\boldsymbol{V} \in R^{J\times \text{channel_list}[\text{stage}]} \leftarrow$ 线性变换层(f_{in})

7: $\boldsymbol{A} \in R^{J\times J} \in \leftarrow \boldsymbol{Q}\cdot\boldsymbol{K}^T$, $f_{sa} \in R^{J\times \text{channel_list}[\text{stage}]} \leftarrow \boldsymbol{A}\cdot\boldsymbol{V}$

8: $f_{out} \in R^{J\times \text{channel_list}[\text{stage}]} \leftarrow \text{LBR}(f_{in} - f_{sa}) + f_{in}$ //得到偏置注意力

9:$f_{in} \leftarrow f_{out}$,再次重复step 6—8,然后跳至step 10

10:$f_{stage} \leftarrow f_{out}$ //留存每个阶段的特征

11:$\tilde{X}_i \leftarrow f_e$,继续循环

12:End for

13:$F_{\tilde{X}_i} \in R^{J\times 256} \leftarrow \text{MLP}(\text{Concat}[f_1, f_2, f_3, f_4])$

本文提出的OADGCNN特征提取模块使用多维度的点云特征,构建基于点云空间信息的局部邻域图,在保证点云置换不变性的同时,利用边卷积提取多层次的局部特征向量,引入偏置注意力模块增强点云的表达能力,有效压制噪声的干扰,从动态更新的语义信息中提取关键点,提高配准效率。试验结果证明,OADGCNN模块有效提升了点云的配准精度。

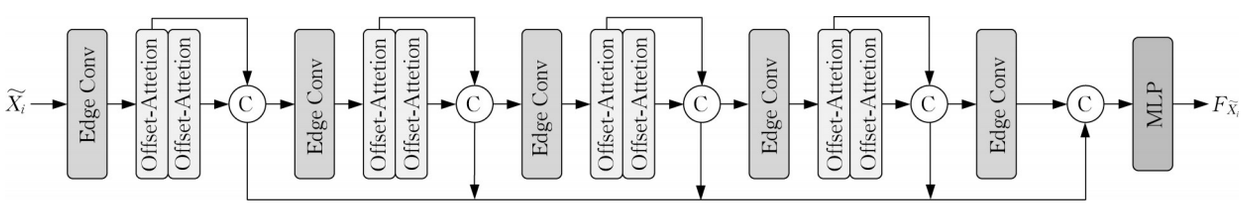

图2 OADGCNN模块

Fig. 2 OADGCNN module

1.4 参数预测网络

在每一次迭代时,本文使用了一个二级网络来学习离群参数α和退火参数β,避免网络需要针对每个数据集手动设置。如图3c所示,该网络连接输入的两个点云形成$(J+K, 3)$矩阵,增设第四列用于标明点云来源,然后使用多层感知机和Softplus激活函数进行预测。

1.5 软匹配与估计变换

为此本文通过匹配矩阵$\boldsymbol{M}$加权平均得到虚拟点来代替真实对应点,见式(6)。这不仅有效避免了传统方式中离散硬分配导致的不可微,还提高了匹配容错性,避免后续估计得到虚假的最优解。

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

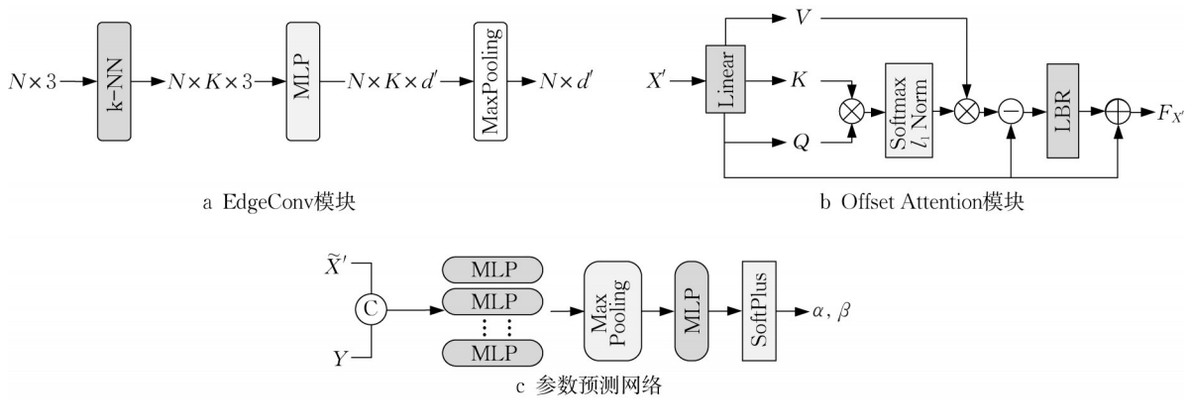

图3　OADGRPMNet模型中模块的流程

Fig. 3　Process of module in OADGRPMNet model

一旦确定点对的对应关系，可以利用SVD计算刚性变换，如式(7)所示：

$$\begin{aligned}&[\boldsymbol{U},\boldsymbol{S},\boldsymbol{V}]=\mathrm{SVD}(\boldsymbol{H})\\&\boldsymbol{R}=\boldsymbol{V}\boldsymbol{U}^{\mathrm{T}}\\&\boldsymbol{t}=-\boldsymbol{R}\bar{x}+\bar{y}\end{aligned}\tag{7}$$

1.6　损失函数

本文主要损失函数是计算应用真实变换$\{\boldsymbol{R}_{\mathrm{gt}},\boldsymbol{t}_{\mathrm{gt}}\}$的源点云和应用预测变换$\{\boldsymbol{R}_{\mathrm{pred}},\boldsymbol{t}_{\mathrm{pred}}\}$的源点云之间的$l_1$距离：

$$L_{\mathrm{reg}}=\frac{1}{J}\sum_{j}^{J}|(\boldsymbol{R}_{\mathrm{gt}}x_j+\boldsymbol{t}_{\mathrm{gt}})-(\boldsymbol{R}_{\mathrm{pred}}x_j+\boldsymbol{t}_{\mathrm{pred}})|\tag{8}$$

如果只有上述配准损失，网络有将大多数点标记为离群点的倾向。为了缓解这个问题，本文在计算出的匹配矩阵$\boldsymbol{M}$上添加一个二次损失来鼓励内点，尽可能减少离群点的出现：

$$L_{\mathrm{inlier}}=-\frac{1}{J}\sum_{j}^{J}\sum_{k}^{K}m_{jk}-\frac{1}{K}\sum_{k}^{K}\sum_{j}^{J}m_{jk}\tag{9}$$

总损失是两个损失的加权和：

$$L_{\mathrm{total}}=L_{\mathrm{reg}}+\lambda L_{\mathrm{inlier}}\tag{10}$$

考虑到配准的损失函数应当以预测损失为主，二次损失为辅的原则，本文为内点损失设置较小的权重，防止该损失主导训练过程，从而确保预测损失对模型训练有更大的影响，以实现精确配准的目标，本文在所有实验中使用$\lambda=0.01$。本文计算每个迭代i的损失，但将损失加权$1/2^{n_i-i}$以赋予后续迭代更高的权重，其中n_i是训练期间的总迭代次数。

2　实验结果与结果分析

2.1　实验参数

在训练过程中令$n_i=2$，促进网络可以更关注具有较小错误的对齐数据，从而在后续迭代中优化配准。在测试过程中令$n_i=5$来实现更精确的配准。对于特征提取和参数预测网络，在除最后一层外的所有层上使用组归一化和ReLU激活。特征提取网络令$\rho=0.3$，并输出维度为96的特征。本文使用学习率为0.000 1的自适应矩估计优化器来训练网络。训练配准网络在PyTorch V1.10框架下进行，批训练大小设置为16，在一块NVIDIA 3060图形处理器上训练共16 h。

2.2　实验数据

本文训练和测试都在ModelNet40数据集上进行，该数据集包含来自40个人造物体类别的计算机辅助设计(computer-aided design，CAD)模型。本文实验用两种不同类型的数据集训练网络：① 40个类别的所有数据；② 20个类别的所有数据。此外，实验选择三种不同类型的测试数据集来展示基于OADGCNN的配准方法在具有不同对象特异性水平的数据上的性能，分别为① 40个类别的所有数据；② 未训练的20个类别的所有数据；③ 未训练的20个类别的噪声数据。

数据预处理包括采样、归一化和应用旋转变换等。从CAD网格面随机采样2 048个点，并进行归一化。在训练和测试期间，在每个轴上[0°，45°]范围内采样三个欧拉角旋转以及在[−0.5，0.5]范围内采样平移距离作为真实变换$\{\boldsymbol{R}_{\mathrm{gt}},\boldsymbol{t}_{\mathrm{gt}}\}$。将应用了该变换的原始点云数据作为源点云$X$，原始点云数据作为目标点云$Y$。

实验将分别用ICP[2]、快速全局配准[12](fast global registration，FGR)、RPMNet[5]、基于点特征层级传递的无监督配准算法[7](registration point hop，R-PointHop)和基于深度信息交互的配准模型[13](deep information interaction，DIT)在ModelNet40数据集上进行计算对比。其中，ICP通过迭代求解最近点对以最小化点间距离，是点云配准中最基础且广泛使用的算法；FGR则使

用高效的优化技术处理点云的稀疏性,实现了快速而精确的全局点云配准;RPMNet则引入了边特征,依靠图匹配和几何约束来进行预测;R-PointHop是一种无监督学习算法,依靠局部特征与全局特征的相似性选出点对用于估计变换;DIT作为点云最新的进展,引入了Transformer用于整合点云中的依赖结构关系,通过学习深层特征来优化配准过程。选择两种传统算法和涵盖多种特征编码架构及估计变换策略的深度学习点云算法进行对比,用以客观说明本文提出的基于点云偏置注意力边特征的鲁棒匹配配准算法的优越性和适用性。

2.3 ModelNet40:所有数据

第一个实验在不知道类别标签的情况下,将ModelNet40数据集中的所有点云随机划分为训练集和测试集,在训练和测试期间使用不同的点云,实验评估真实旋转和估计旋转、真实平移和估计平移之间的均方根误差(root meansquared error,RMSE)和绝对平均误差(mean absolute error,MAE)。理想情况下如果刚性对齐为完美的,实验结果应该为0,误差越小,配准精度越高。实验结果如表2所示。其中所有旋转角度测量都以度为单位。

表2 使用ModelNet40所有数据的训练和测试

Tab. 2 Training and testing on all data of ModelNet40

算法	旋转		平移	
	均方根误差	绝对平均误差	均方根误差	绝对平均误差
ICP	29.914 835	23.544 817	0.290 935	0.248 755
FGR	9.362 772	1.999 290	0.013 939	0.002 839
RPMNet	1.472 100	0.132 300	0.008 129	0.000 826
R−PointHop	2.842 217	0.566 934	0.022 118	0.000 386
DIT	3.239 815	0.666 211	0.009 146	0.000 672
本文算法	**0.600 100**	**0.016 100**	**0.004 517**	**0.000 136**

从表2可以看到本文改进的算法OADGRPMNet配准误差明显低于传统的点云配准方法和RPMNet、R-PointHop与DIT这些基于深度学习特征的方法,至少降低了10^{-1}个量级。图4显示了各算法在ModelNet40某些对象上的定性配准结果。

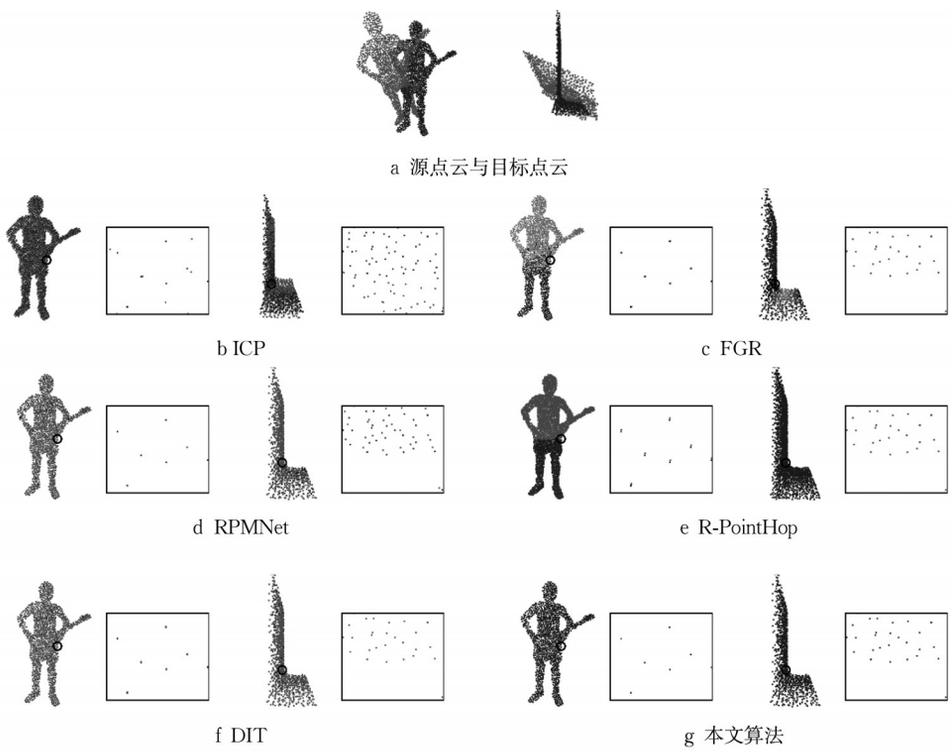

图4 各算法模型上的定性配准结果示例

Fig. 4 Qualitative registration results' examples on each algorithm model

实验分别选取人体类与电视机类中的各一个测试数据作为结果展示,其中图4a中深色点云为目标点云,浅色点云为源点云,图4b~图4g分别为采用对比算法配准的可视化结果,图4g则为采用本文算法的结果,每张子图的第1、3列为整体配准效果,第2、4列分别对应第1、3列的画圈部分的局部配准效果。配准结果越重合目标点云,表明配准精度越高。以子图的第1列人体数据为例,图4b和图4i与目标点云相比不够清晰分明,这是因为配准出现了偏差,导致源点云变换到了空隙处,而图4c、图4d和图4f点云较为清晰,说明变换

之后的位置与目标点云大致重合，但从最终重叠的颜色看来，相较于本文算法图4g仍有较小误差。第2、4列的局部精细结果直观显示了图4g在点与点的对应上都做到了最小的误差，其余算法都有一定程度的重叠不完全，进一步验证本文算法的优越性。综上所述，通过对本文改进的算法OADGRPMNet进行综合性的测试和结果可视化分析，可以发现该算法在处理特定类型数据时表现出较高精度。

2.4　ModelNet40：未知对象类别

为了测试本文算法在不同类别对象上的泛化推广能力，实验按类别将前20个类别划分为训练集，将后20个类别划分为测试集。对于需要学习的4个算法模型，在前20个类别上训练，在没有训练的20个类别上进行测试，评估其泛化性。ICP和FGR则是直接在没有进行训练的20个对象类别上直接进行测试。如表3所示，尽管学习的表示依赖于训练任务，但在未训练过的点云数据上，本文算法表现远远优于启发式的点云配准算法以及其他同行基于学习的配准方法，具有更小的误差，说明OADGRPMNet具有优良的适用性。

表 3　在ModelNet40未知对象类别的数据上测试

Tab. 3　Testing on unknown object class data of ModelNet40

算法	旋转		平移	
	均方根误差	绝对平均误差	均方根误差	绝对平均误差
ICP	29.876 431	23.626 110	0.293 266	0.251 916
FGR	9.848 997	1.445 460	0.013 503	0.002 231
RPMNet	0.399 500	0.068 700	0.001 781	0.000 486
R－PointHop	3.412 259	0.810 272	0.039 655	0.001 053
DIT	4.979 076	0.169 105	0.006 727	0.000 251
本文算法	**0.009 100**	**0.004 100**	**0.000 141**	**0.000 065**

2.5　ModelNet40：高斯噪声

实验在测试时对输入点云的每个点添加噪声，从均值为0、方差为0.01的高斯噪声进行独立采样并剪裁在[－0.05，0.05]。本次实验采用2.4节的实验模型，该模型是在ModelNet40前20个物体类别的无噪声数据上进行训练的，在后20个类别的数据上添加高斯噪声作为测试数据。

表4中的实验结果表明，ICP、FGR和RPMNet对噪声很敏感，会趋向于到一个较远的固定值，而R-PointHop和DIT对噪声数据显示出了一定的鲁棒性，OADGRPMNet对于添加噪声后的旋转估计拥有最好的鲁棒性，均方误差较之第2名R-PointHop降低了45％，在添加噪声的平移估计上效果稍逊于

表 4　在ModelNet40添加高斯噪声的数据上进行测试

Tab. 4　Testing on ModelNet40 data with added Gaussian noise

算法	旋转		平移	
	均方根误差	绝对平均误差	均方根误差	绝对平均误差
ICP	29.707 983	23.557 217	0.290 752	0.249 092
FGR	24.651 468	10.055 918	0.108 977	0.027 393
RPMNet	44.054 400	22.483 100	0.182 800	0.098 160
R－PointHop	7.734 856	4.389 318	0.062 912	0.038 724
DIT	9.113 178	7.302 423	**0.031 729**	0.025 231
本文算法	**5.227 500**	**1.874 000**	0.042 670	**0.014 340**

DIT，或许是因为OADGRPMNet通过构建动态图来捕捉局部结构信息，平移操作会改变点云的绝对位置，而高斯噪声可能掩盖这些变化的细微特征，使得网络难以准确估计平移参数。但对比于同样使用了边特征的RPMNet，本文算法仍保留优势，这是因为偏置注意力可以增强模型对关键特征的关注能力，帮助模型在对齐时更好地识别了关键结构。为了改善平移情况下的性能，可以增加对平移变换的训练样本，通过在训练集中增加更多包含平移变换的样本，可以帮助模型更好地学习处理平移。

2.6　消融实验

2.6.1 特征模块

本实验将RPMNet中使用的PointNet模块、OA模块和动态图神经网络(dynamic graph convolutional neural network，DGCNN)模块这3个特征提取模块和本文采用的OADGCNN模块在未知对象类别实验上进行比较。PointNet通过多层感知机可以有效学习到点云的全局特征；OA仅增强了输入点云的空间和法向量信息，没能从多种渠道获得丰富语义进行关键点识别，导致达到了局部最优的收敛状态；DGCNN通过构造k近邻图在动态融合点云的局部几何特征的同时通过多层堆叠连接学习全局特征。将RPMNet、仅添加OA模块的OARPMNet、仅添加DGCNN模块的DGRPMNet和本文算法OADGRPMNet最终配准结果进行比较。表5中的实验结果表明使用OADGCNN特征提取模块比仅仅使用单一的特征模块配准效果都更好。

2.6.2 损失权重

本实验将算法OADGRPMNet的损失函数权重在所有数据的训练实验上进行比较，从而获得最佳超参数。考虑到计算复杂性和对比全面性，本实验对比$\lambda=0.001$、$\lambda=0.005$、$\lambda=0.01$、$\lambda=0.05$、$\lambda=0.1$和$\lambda=0.5$六个数量级的权重比例，从收敛速度和收敛精度结果两个维度进行衡量。结果如图5所示，其中纵轴(左)表示收敛精度，纵轴(右)表示收敛速度，横轴

表5 OA、DGCNN和OADGCNN特征学习比较

Tab. 5 Comparison of feature learning among OA, DGCNN, and OADGCNN

算法	旋转		平移	
	均方根误差	绝对平均误差	均方根误差	绝对平均误差
RPMNet	0.399 500	0.068 700	0.001 781	0.000 486
OARPMNet	2.690 000	0.180 000	0.013 540	0.001 147
DGRPMNet	0.011 800	0.008 100	0.000 157	0.000 100
本文算法	**0.009 100**	**0.004 100**	**0.000 141**	**0.000 065**

是权重比例的log值,以便于均匀分布。可以发现不同量级的损失权重均可使得模型收敛,但其中$\lambda=0.01$在收敛速度最快的同时达到了最好的收敛结果,因此本文在所有实验中使用$\lambda=0.01$。

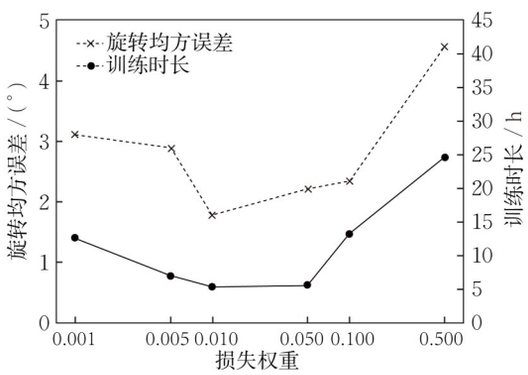

图5 不同损失权重对收敛精度和速度的影响

Fig. 5 Influence of different loss weights on convergence accuracy and speed

3 结语

本文在配准网络RPMNet的基础上进行了改进。首先,采用了增添偏置注意力机制的DGCNN取代PointNet来获取点云特性。OADGCNN不仅具有捕获点云的局部几何属性的能力,而且在动态更新图结构的过程中,能在高纬度汇集多层次上下文信息,提高局部几何信息的利用率,增强网络对点云数据的拟合能力。其次,为了预测更为鲁棒的对应点对关系,引入二级网络控制离群值的数量和软匹配关系的概率分布。实验结果表明,本文算法在配准精度和鲁棒性方面优于部分传统算法和RPMNet等同行配准网络。在未来的工作中,将继续研究如何将更好的点云配准算法应用于真实情景的配准中,以获得更广泛的应用。也将进一步改进网络的性能,使其在更复杂的场景中表现出更好的鲁棒性和适应性。

作者贡献声明:

柳先辉:提出想法,实验指导。

葛依凡:模型设计及实现,数据分析及论文撰写。

参考文献:

[1] 武越,苑咏哲,向本华,等.三维点云配准中的计算智能方法综述[J].中国图象图形学报,2023,28(9):2763.
WU Yue, YUAN Yongzhe, XIANG Benhua, *et al*. Review of computational intelligence methods in 3D point cloud registration [J]. Chinese Journal of Image and Graphics, 2023, 28(9): 2763.

[2] BESL P J, MCKAY N D. Method for registration of 3-D shapes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239.

[3] 田应仲,侯玉琴,李龙,等.基于改进的SAC-IA-SICP点云配准方法研究[J].计量与测试技术,2023,50(1):26.
TIAN Yingzhong, HOU Yuqin, LI Long, *et al*. Research on point cloud registration method based on SAC-IA-SICP [J]. Metering and Testing Technology, 2023, 50 (1): 26.

[4] 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. Seoul, Korea (South): IEEE, 2019: 3523-3532.

[5] YEW Z J, LEE G H. Rpm-net: Robust point matching using learned features[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA: IEEE, 2020: 11824-11833.

[6] QI C R, SU H, Mo K, *et al*. Pointnet: Deep learning on point sets for 3d classification and segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI: IEEE, 2017: 652-660.

[7] KADAM P, ZHANG M, LIU S, *et al*. R-pointhop: A green, accurate, and unsupervised point cloud registration method[J]. IEEE Transactions on Image Processing, 2022, 31: 2710.

[8] JIANG H, DANG Z, WEI Z, *et al*. Robust outlier rejection for 3d registration with variational bayes[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, BC: IEEE, 2023: 1148-1157.

[9] WU Z, SONG S, KHOSLA A, *et al*. 3d shapenets: A deep representation for volumetric shapes[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Boston, MA: IEEE, 2015: 1912-1920.

[10] GUO M H, CAI J X, LIU Z N, *et al*. PCT: Point cloud transformer[J]. Computational Visual Media, 2021, 7: 187.

[11] SINKHORN R. A relationship between arbitrary positive matrices and doubly stochastic matrices[J]. The Annals of Mathematical Statistics, 1964, 35(2): 876.

[12] ZHOU Q Y, PARK J, KOLTUN V. Fast global registration[C]// Proceedings of the European Conference on Computer Vision. Amsterdam, The Netherlands: Springer, 2016: 766-782.

[13] CHEN G, WANG M, ZHANG Q, *et al*. Full transformer framework for robust point cloud registration with deep information interaction [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 1: 1.