

文章编号 1004-924X(2024)11-1759-14

## 面向低重叠率点云匹配的多层级过滤网络

贺敏琦<sup>1,2</sup>, 刘俐<sup>1,2</sup>, 李尚<sup>1,2</sup>, 吴浩<sup>1,2\*</sup>, 朱大虎<sup>1,2</sup>

- 武汉理工大学 现代汽车零部件技术湖北省重点实验室, 湖北 武汉 430070;
- 武汉理工大学 汽车零部件技术湖北省协同创新中心, 湖北 武汉 430070)

**摘要:**针对点云测量过程中由于结构遮挡、视场约束、拼接误差等导致的匹配失真问题,提出一种多层级过滤网络(Multi-level Filter Network, MulFNet)用于实现单次测量点云低重叠率下的精确配准。通过特征金字塔编码网络提取点云的多层级特征,获得不同尺度的语义信息,同时嵌入注意力模块和信息编码模块以增强特征显著性。基于多尺度一致性决策机制对多层级特征进行过滤,筛选离群点并保留点云突出特征,获得初始对应关系。最后,将初始对应结点基于几何信息自适应分组,由局部至全局进行加权转换估计,获得基于多层级过滤筛选后的预测矩阵。实验结果表明,MulFNet网络在标准3DMatch公共数据集上的匹配效果明显优于FCGF, PREDATOR等主流网络,在平均重叠率为10%的测量数据集上的匹配精度比ICP算法和GeoTransformer网络分别提高40.9%和85.4%,有效解决了低重叠率点云匹配失真的问题。

**关键词:**点云匹配;匹配失真;低重叠率;多层级过滤;局部测量

**中图分类号:**TP391 **文献标识码:**A **doi:**10.37188/OPE.20243211.1759

## Multi-level filter network for low-overlap point cloud registration

HE Minqi<sup>1,2</sup>, LIU Li<sup>1,2</sup>, LI Shang<sup>1,2</sup>, WU Hao<sup>1,2\*</sup>, ZHU Dahu<sup>1,2</sup>

- Hubei Key Laboratory of Advanced Automotive Components Technology,  
Wuhan University of Technology, Wuhan 430070, China;
  - Hubei Collaborative Innovation Center for Automotive Components Technology,  
Wuhan University of Technology, Wuhan 430070, China)
- \* Corresponding author, E-mail: wuhao2023@whut.edu.cn

**Abstract:** Aiming at the problem of matching distortion caused by structural occlusion, field of view constraints, and stitching errors during point cloud reconstructed, a multi-level filter network (MulFNet) is proposed to achieve single-shot scanning point clouds for low-overlap registration. Firstly, the multi-level features of the point clouds are extracted through the feature pyramid coding network to obtain semantic information at different scales, and the attention module and the location module are embedded to enhance the feature significance; secondly, the multi-level features are filtered based on the multi-scale consistency voting mechanism, outliers are screened out and prominent features of the point clouds are retained to obtain the initial correspondence; and finally, the initial corresponding nodes are adaptively grouped based on the geometric relationships, and weighted estimation conversion is performed from local to global to obtain

收稿日期:2023-11-06;修订日期:2023-12-12.

基金项目:国家自然科学基金资助项目(No. 52375509);湖北省重点研发计划资助项目(No. 2022BAA067)

a prediction matrix based on the multi-level filtering. The experimental results show that the MulFNet is better than the popular networks such as FCGF and PREDATOR on the standard 3DMatch. The registration accuracy of the MulFNet on the scanning dataset with an average overlap rate of 10% is 40.9% and 85.4% higher than the ICP and the GeoTransformer, respectively. It is verified that the proposed network can effectively solve the problem of low-overlap point cloud matching distortion.

**Key words:** point cloud registration; matching distortion; low-overlap point cloud; multi-level filter; partial measurement

## 1 引言

点云匹配是机器视觉中的一项关键技术,广泛应用于三维定位、三维重建和位姿估计等任务场景<sup>[1-2]</sup>。视觉测量定位的匹配目标是将标准点云与测量点云对齐,其匹配精度直接影响后续各项工作。然而在点云匹配过程中,由于受到噪声、传感器精度等多种因素的影响,匹配结果与真实值或期望值之间易产生偏差,即匹配失真。同时,由于传感器视角的局限性,测量点云之间通常仅有部分重叠或存在遮挡,造成某些区域点云缺失对应关系,进一步增大了匹配失真概率。因此,在低重叠条件下减少点云匹配失真是点云配准领域亟待解决的难题。近年来,国内外学者基于传统算法和深度学习网络提出了多种方法用于减少点云匹配失真。

传统算法主要聚焦于最近点迭代(Iterative Closest Point, ICP)<sup>[3]</sup>及其变体<sup>[4-6]</sup>算法,通过构建不同的欧式距离约束以实现几何误差的迭代优化,但这些方法在处理异常值和离群点时较为敏感。为此,研究者相继提出Robust-ICP<sup>[7]</sup>, WP-MAVM<sup>[8]</sup>, DPWVM<sup>[9]</sup>等算法,旨在提高配准的稳定性,但在配准时需依赖于良好的初始位姿,并且收敛时间普遍较长。为处理点云噪声及局部重叠问题,基于随机采样一致性<sup>[10]</sup>的算法采用多次迭代以保证匹配精度,但同时增加了时间复杂度。文献[11]在4PCS<sup>[12]</sup>的基础上通过引入特征描述子和三维集合距离,实现了不同重叠率下的点云处理。然而,以上算法在针对低重叠率点云时匹配结果不稳定,仅适用于重叠率高于30%的匹配任务<sup>[13]</sup>。此外,通过手工设计特征描述子,如SliceLRF<sup>[14]</sup>, FPFH<sup>[15]</sup>, TPSH<sup>[16]</sup>等,亦可实现点云匹配。Zhou等<sup>[17]</sup>提出了一种针对部分重叠点云的全局匹配算法,

但当关联噪声较高时,算法稳定性显著下降。传统算法的匹配效果依赖于准确点对关系的构建,其性能极易受到异常点、离群点影响,因此面对点云重叠率低、噪声含量大等问题时,传统算法匹配效果不佳且稳定性差,限制了它在特定任务场景中的应用。

随着深度学习技术的发展,基于学习的配准方法近年来取得了较大进展,主要可分为基于特征提取<sup>[18-20]</sup>和端到端<sup>[21-23]</sup>两种。PREDATOR网络<sup>[18]</sup>添加了重叠注意力模块,以实现点云间信息的早期交换。Huang等<sup>[19]</sup>设计了一种多模态融合特征描述子,同时考虑了点云的结构和纹理信息,提高了特征的区分度。Choy等<sup>[20]</sup>采用3D全卷积网络,通过单次计算即可得到点云的全卷积几何特征。上述基于特征提取的配准网络在完成特征编码后,通常使用RANSAC估计变换矩阵,因此对异常值和重复几何非常敏感<sup>[24]</sup>。端到端网络则在其结构中加入了转换估计部分,无需进一步的后处理即可实现变换矩阵的获取。Wang等<sup>[21]</sup>提出了ICP的学习网络版本DCP,利用点对特征之间的软对应关系计算刚性变换。后续通过添加松弛项<sup>[25]</sup>进一步解决了DCP在处理部分重叠点云时的局限性。GeoTransformer网络<sup>[22]</sup>和REGTR网络<sup>[23]</sup>分别通过使用几何Transformer和直接预测最终对应关进行匹配。深度学习方法在质量较好的公共数据集上匹配效果较优,但不能很好解决重叠率低、噪声多、密度不均的复杂零件测量点云匹配问题。

实际上,复杂零件测量点云匹配还存在以下显著问题:(1)零件型面复杂,存在结构遮挡或视场约束等因素,造成部分测量点云缺失;(2)采用多视角扫描拼接点云的精度高度依赖于拼接算法,测量结果会引入拼接误差且采集耗时较长;(3)扫描过程中受环境干扰,不可避免会出现噪

声、密度不均等问题。以上问题导致难以获得目标对象的高精度完整测量重建,对利用复杂零件单次测量点云实现低重叠率精确匹配提出了迫切需求。

本文提出一种解决低重叠率点云匹配失真的多层级过滤网络模型(Multi-level Filter Network, MulFNet),有效实现在低重叠率、多噪声、密度不均等因素干扰下复杂零件单次测量的点云配准。该网络主要基于多层级过滤筛选,利用点云的多层级特征实现离群点、误匹配点对的过滤,利用分组结点实现局部至全局最优转换关系的筛选。通过结合语义信息和位置信息提取点云的显著特征,同时网络嵌入转换矩阵估计模

块,实现预测结果的端到端求解。

## 2 原理

MulFNet网络的整体结构如图1所示,主要分为特征提取模块和对应关系提取模块。输入源点云 $X$ 与目标点云 $Y$ ,使用3D稀疏卷积提取点云的多层级特征,将高层级特征输入由多头注意力、交叉注意力和位置编码组成的信息交互Transformer模块,实现特征全局聚合并嵌入位置编码信息;通过一致性决策算法获取初始对应关系,利用自适应分组后的点群计算局部转换矩阵,完成局部-全局转换矩阵的提取与过滤,输出最终预测结果。

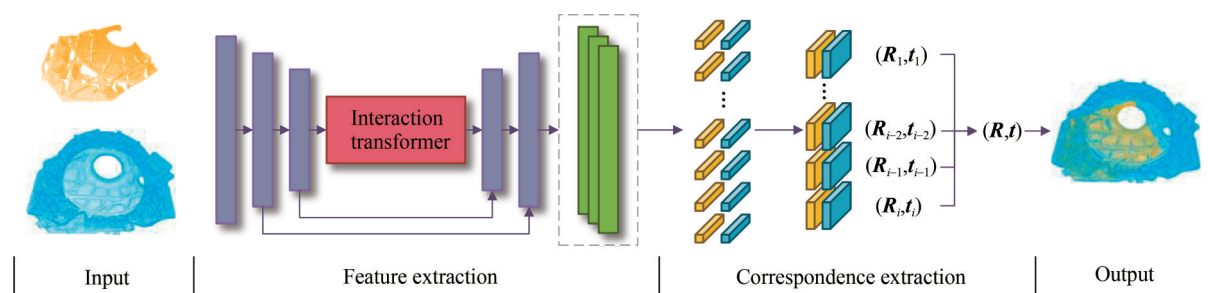


图1 MulFNet的整体结构

Fig. 1 Overall network structure of MulFNet

### 2.1 特征提取及筛选

零件模型点云与局部测量点云仅部分区域重叠,且构件表面存在重复几何结构,同时特征区分度较差,导致提取显著特征的难度增大并容易产生误匹配。因此,MulFNet采用权值共享的特征金字塔编码器-解码器结构提取多尺度特征,并基于一致性决策机制过滤对应关系中的外点。

#### 2.1.1 特征金字塔

MulFNet使用特征金字塔编码器-解码器(图2)提取点云的多层级分辨率特征<sup>[26]</sup>,以增强低重叠率点云匹配的稳定性。由于点云具有稀疏性,即大部分三维空间没有存储数据,所以通过稀疏卷积<sup>[27]</sup>提取点云特征。稀疏张量可以表示为点云坐标和对应特征的集合,仅当集合中对应坐标存在时稀疏张量才具有相应特征。因此相较于常规3D卷积,基于稀疏张量的稀疏

卷积更加节省空间。编码器对点云 $X$ 的3个子采样层进行处理,生成多分辨率点云 $(X_1, X_2, X_3)$ 及其特征 $(F_{X_1}^{\text{en}}, F_{X_2}^{\text{en}}, F_{X_3}^{\text{en}})$ 。解码器逐级向上采样多分辨率点云,将解码器基本单元运算定义为:

$$\phi(F_1, F_2) = MLP\left(\text{cat}\left[UP\left(MLP(F_1)\right), F_2\right]\right), \quad (1)$$

其中: $(F_1, F_2)$ 为输入特征,UP( $\cdot$ )为最近邻上采样,cat $[\cdot, \cdot]$ 为特征联合操作。3级全尺寸点云特征 $(F_X^1, F_X^2, F_X^3)$ 计算如式(2)所示:

$$\begin{aligned} F_x^1 &= \phi(\phi(\phi(F_{X_3}^{\text{de}}, F_{X_3}^{\text{en}}), F_{X_2}^{\text{en}}), F_{X_1}^{\text{en}}) \\ F_x^2 &= \phi(\phi(F_{X_3}^{\text{en}}, F_{X_2}^{\text{en}}), F_{X_1}^{\text{en}}) \\ F_x^3 &= \phi(F_{X_3}^{\text{en}}, F_{X_1}^{\text{en}}) \end{aligned} \quad (2)$$

最终获得的全尺寸点云特征 $(F_X^1, F_X^2, F_X^3)$ 是由不同分辨率点云上采样所得,因此各层级特征具有不同的感受野,为准确估计对应关系提供了更全面的特征信息

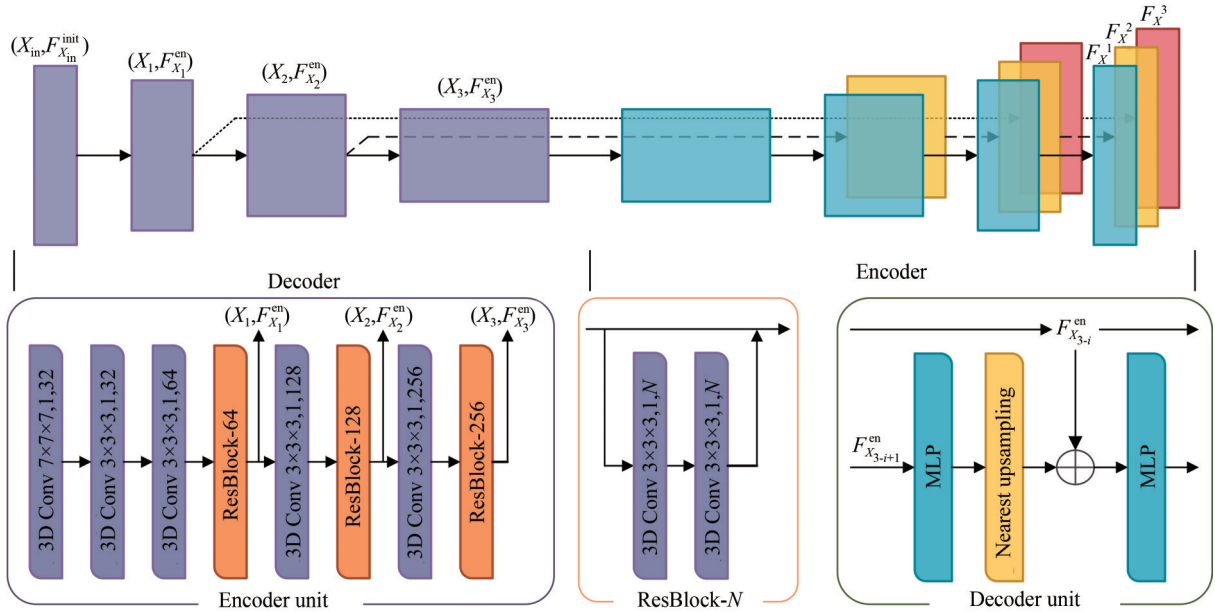


图2 特征金字塔编码器-解码器

Fig. 2 Encoder-decoder with feature pyramid

### 2.1.2 多尺度一致性决策机制

受尺度不变特征变换<sup>[28]</sup>启发,使用多尺度特征引导的一致性决策机制构建稳定的对应关系(图3),从而实现过滤外点的目的,同时点云中每个点将保留最具显著性的特征。输出为一致性较高的对应点对集合  $C = \{(x_i, y_{\sigma(i)}) \mid i = 1, 2, \dots, n\}$ , 其中  $\sigma(i)$  为点云  $X'$  中点  $x_i$  在点云  $Y'$  中对应点的索引。以点  $x_i$  为例,一致性决策机制对点云  $X'$  的多层级特征逐级如式(3)进行查找,检查不同层级间候选点 ( $y^l, y^k$ ) 是否相同,当至少有两层级间候选点相同时  $\sigma(i) = y^l$ , 否则点  $x_i$  为外点。

$$y^l = NN_F^l(x_i, Y'), l = 1, 2, \dots, L, \quad (3)$$

其中:  $l$  为特征对应级数, 函数  $NN_F^l(x, Y')$  为寻找点  $x_i$  在点云  $Y'$  第  $l$  级特征空间中的最邻近点, 返回  $y^l$  为该点最邻近点的索引, 若  $x_i$  判定为外点,




图3 多尺度特征一致性决策机制

Fig. 3 Multi-scale consistency voting mechanism

则舍弃该点及其对应特征。

### 2.1.3 信息交互 Transformer

低重叠点云之间存在大量潜在的错误对应关系, 这增加了特征匹配的难度。并且编码器-解码器提取的仅为点云局部特征, 未包含全局尺度上的结构自相关信息和点云间互相关信息。因此, 在编码器和解码器之间加入信息交互 Transformer 模块(图4), 将编码器输出特征 ( $F_{X'}^en, F_{Y'}^en$ ) 转化为具有交互信息的特征 ( $F_{X'}^{inter}, F_{Y'}^{inter}$ ), 使网络在聚焦关键全局特征信息的同时抑制无关噪声。

信息交互 Transformer 模块包括自注意力模块、交叉注意力模块和位置编码模块。注意力模块中每层多头注意力操作为  $MHAttn(Q, K, V)$ , 其中 ( $Q, K, V$ ) 分别为查询(Query)、键(Key)和价值(Value)。自注意力模块中每层 ( $Q, K, V$ ) 均源于相同点云, 交叉注意力模块中的 ( $K, V$ ) 源于另一点云, 二者分别实现了特征的自相关及互相关交互。

位置编码模块通过在 Transformer 层中添加三维正弦位置编码<sup>[23]</sup>获取点位置信息, 位置编码与注意力模块输入特征 ( $F_{X'}^en, F_{Y'}^en$ ) 具有相同维度  $d$ 。对于点  $x_i = (x, y, z)$ , 将每个坐标分别变换至其嵌入表达  $\{p_x^{x_i}, p_y^{x_i}, p_z^{x_i}\} \in \mathbb{R}^{2[d/6]}$ , 其中  $x$  轴坐标变换如式(4), 其余坐标轴以相同方式进行变换。






图 4 信息交互 Transformer 模块

Fig. 4 Info-interaction transformer module

$$\begin{aligned}
 p_x^r[2i] &= \sin\left(\frac{x}{10\,000^{2i/\lfloor d_F/d_p \rfloor}}\right) \\
 p_x^r[2i+1] &= \cos\left(\frac{x}{10\,000^{2i/\lfloor d_F/d_p \rfloor}}\right)
 \end{aligned} \tag{4}$$

其中:  $d_F$  为特征维度,  $d_p$  为点云坐标维度。

### 2.2 对应关系提取及过滤

零件结构特点决定其表面通常包含许多特征相似的点,同时低重叠率点云中包含大量离群

点,以上会造成对应关系缺失或产生干扰对应关系,最终导致匹配失真。因此,如图 5 所示, MulFNet 基于局部-全局进行对应关系提取及过滤,首先利用局部一致性估计得到的初始对应关系,然后基于几何近邻完成点群分组并将可微加权奇异值分解 (Singular Value Decomposition, SVD) 集成至网络中,最终实现全局变换矩阵估计。

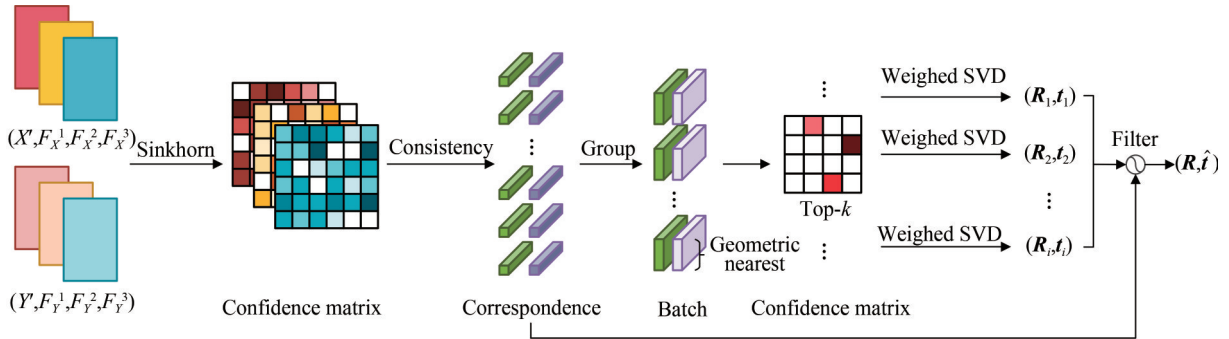


图 5 对应关系提取模块

Fig. 5 Correspondence extraction module

#### 2.2.1 初始对应关系

初始对应关系的建立是基于多尺度特征之间的相似矩阵。由于点云噪声、密度变化等因素,特征中可能出现不匹配节点,因此计算相似矩阵前先分别用  $m'$  和  $n'$  松弛行列<sup>[29]</sup>,以  $(F_X^1, F_Y^1)$  为例,其相似矩阵  $S^1$  如下:

$$S^1 = \begin{bmatrix} F_X^1 F_Y^{1T} & z \\ z^T & z \end{bmatrix}, S^1 \in \mathbf{R}^{(m'+1) \times (n'+1)} \tag{5}$$

其中  $z$  为设置的松弛项可学习参数。

利用 Sinkhorn 算法<sup>[30]</sup>可获得相似矩阵  $S^1$  的高维度匹配问题的最优解,记为匹配置信度矩阵

$Z', Z'$  中元素  $(i', j')$  表示  $X'$  中点  $x_i$  与  $Y'$  中对点  $y_j$  之间的匹配置信度。为了增大初始配对可能性,即获得更稳定的对应关系,设置最高和最低匹配置信度阈值<sup>[31]</sup>。接着基于一致性决策算法,获得点云初始对应集合  $C^{init} = \{(X'(i'), Y'(j'))\}$ ,其中,  $X'(i')$  表示点云  $X'$  中索引为  $i'$  的点  $x_{i'}$ 。

#### 2.2.2 点群自适应分组

为过滤错误点对,将单个点对分组聚类得到点群组批,从而实现局部-全局对应关系提取与过滤。采用基于几何近邻的点到结点分组策略,

相较于  $k$  近邻和球半径分组,点到结点分组的优势在于对于多尺度点云具有自适应性<sup>[38]</sup>,并且每个点都能恰好分配至一个结点,而其他策略则可能存在遗漏。在点到结点的分组过程中,初始对应集合  $C^{\text{init}}$  分别在几何空间  $C_D = \{(G_X^D(i'), G_Y^D(j'))\}$  及特征空间  $C_F = \{(G_X^F(i'), G_Y^F(j'))\}$  进行了拓展,最终得到点云对应组批批  $\{(N_X^F(i'), N_Y^F(j'))\}$ ,其中组批  $N_X^F(i')$  所包含点群  $G_X^D(i')$  及其对应特征  $G_X^F(i')$  可表示为:

$$G_X^D(i') = \{p \in X' \mid \|p - X'(i')\| \leq \|p - X'(j')\|, \forall j' \neq i'\}$$

$$G_X^F(i') = \{F \in F_X \mid f \leftrightarrow p \text{ with } p \in G_X^D(i')\}, \quad (6)$$

其中  $p$  与点  $X'(i')$  的距离小于于任意其他点。

### 2.2.3 转换关系估计

分组完成后,以组批为单位进行局部对应关系提取及全局转换估计。为提取组批  $(G_X^D(i'), G_Y^D(j'))$  之间的局部对应关系,首先构建代价矩阵  $C_i \in \mathbb{R}^{n_i \times m_j}$ :

$$C_i = G_X^F(i')_i G_Y^F(j')_j^T / \sqrt{\bar{d}}, \quad (7)$$

$$\bar{C}_i = \begin{bmatrix} C_i & \alpha \\ \alpha^T & \alpha \end{bmatrix}, \quad \bar{C}_i \in \mathbb{R}^{(n_i+1) \times (m_j+1)}, \quad (8)$$

其中:  $n_i = |G_X^F(i')|$ ,  $m_j = |G_Y^F(j')|$ ,  $\bar{d}$  为对应特征维度,  $\bar{C}_i$  为  $C_i$  的增广矩阵,  $\alpha$  为所有松弛项可学习参数。利用 Sinkhorn 算法获得匹配置信度矩阵  $\bar{Z}_i$ , 通过双向 top- $k$  提取局部对应点集  $\bar{C}_i$ , 利用加权 SVD 求解变换  $T_i = (R_i, t_i)^{[22]}$ :

$$(R_i, t_i) = \min_{R, t} \sum_{(\bar{p}_{x_j}, \bar{p}_{y_j}) \in \bar{C}_i} w_j^i \left\| R \cdot \bar{p}_{x_j} + t - \bar{p}_{y_j} \right\|_2^2, \quad (9)$$

其中:  $w_j^i$  为匹配置信度矩阵  $\bar{Z}_i$  中对应匹配置信度, 作为计算权重。选择所有对应关系中内点率最高的作为全局转换关系:

$$(R, t) = \max_{(R, t)} \sum_{(\bar{p}_{x_j}, \bar{p}_{y_j}) \in C} \left[ \left\| R_i \cdot \bar{p}_{x_j} + t_i - \bar{p}_{y_j} \right\|_2 < \tau_d \right], \quad (10)$$

其中:  $\llbracket \cdot \rrbracket$  为 Iverson 括号,  $\tau_d$  为接受半径。

### 2.3 损失函数

MulFNet 使用对应关系损失  $L_C$ 、特征损失  $L_F$ 、点匹配损失  $L_P$  作为联合损失函数  $L$ :

$$L = L_C + L_F + L_P, \quad (10)$$

其中, 对应关系损失  $L_C$  使用最大对比损失<sup>[20]</sup>, 能

够帮助网络更好的查找特征最大差异对比。特征损失  $L_F$  为多级特征损失之和, 计算如式(11)所示:

$$L_F(F) = \sum_{h=1}^3 \frac{1}{2} (L_X^h(F) + L_Y^h(F)), \quad h = \{1, 2, 3\}, \quad (11)$$

其中  $(L_X^h(F) + L_Y^h(F))$  分别为点云  $(X, Y)$  的第  $h$  级特征的圆损失<sup>[33]</sup>。最后通过计算真实对应组批匹配矩阵的负对数似然损失<sup>[29]</sup>作为点匹配损失  $L_P$ 。

## 3 实验与结果分析

### 3.1 实验环境

实验基于 Ubuntu20.04 操作系统, 使用 CPU Intel Xeon Platinum 8358P 和 GPU NVIDIA RTX A5000, 使用 Pytorch 1.11 作为深度学习框架, 基于开源 Open3D 点云库和 Minkowski Engine 稀疏张量自动微分库配置软件环境。训练网络使用 SGD 优化器, 初始学习率为  $1 \times 10^{-4}$ , 权重衰减为  $1 \times 10^{-6}$ , 动量为 0.9, 训练 60 epoch。考虑到点云复杂程度及分布特征, 本文选取主流公开数据集中的室内数据集 3DMatch<sup>[34]</sup>, 同时使用汽车飞轮壳及车身测量数据集进行实验评估。

### 3.2 公开数据集

3DMatch 室内数据集包含 62 个场景。其中 46 个用于训练, 8 个用于验证, 8 个用于测试, 使用文献[18]预处理训练数据, 同时遵循其在 3DMatch (点云对重叠率大于 30%) 和 3DLoMatch (点云对重叠率为 10%~30%) 上进行评估, 使用内点率 (Inlier Ratio, IR)、特征召回率 (Feature Matching Recall, FMR)、配准召回率 (Registration Recall, RR) 作为评价指标, 同样遵循文献[18, 22]设置相关阈值参数。

#### 3.2.1 评价指标

$(R^*, t^*)$  和  $(\hat{R}, \hat{t})$  分别表示真实值及预测值。根据真实转换矩阵, 将所提取的对应点对集合转换至同一坐标系下, 点对距离小于内点距离阈值的点即为内点。内点率的计算公式如下:

$$IR = \frac{1}{|\Omega_s|} \sum_{(x, y) \in \Omega_s} \llbracket \|R^* x_i + t^* - y_j\| < \tau_1 \rrbracket. \quad (12)$$

多对点云中, 内点率高于一定阈值的比例

即为特征召回率。特征召回率一般用于评估点云匹配质量,多对点云中能以高置信度完成匹配的比例,其计算公式如下:

$$FMR = \frac{1}{|M|} \sum_{i=1}^{|M|} \mathbb{1}[IR_i > \tau_2], \quad (13)$$

其中: $M$ 为所有点云对, $\tau_2$ 为内点阈值。

多对点云中,成功配准的比例即为配准召回率,通常使用真实对应点对之间的距离误差衡量配准是否成功。真实对应点对之间的距离误差计算公式如下:

$$E_{RMSE^*} = \sqrt{\frac{1}{|\Omega^*|} \sum_{(x,y) \in \Omega^*} \|\hat{R}x^* + \hat{t} - y^*\|^2}, \quad (14)$$

其中: $\Omega^*$ 为真实值下点云对中的对应点集合。

配准召回率的计算公式如下:

$$R_R = \frac{1}{|M|} \sum_{i=1}^{|M|} \mathbb{1}[E_{RMSE^*} < \tau_3], \quad (15)$$

其中 $\tau_3$ 为 $E_{RMSE^*}$ 阈值。

### 3.2.2 实验结果

实验将 MulFNet 与 FCGF<sup>[20]</sup>, PREDATOR<sup>[18]</sup>, CoFiNet<sup>[31]</sup>, GeoTransformer<sup>[22]</sup> 网络进行比较,对比网络的实验数据和数据处理方式均参考文献[22],表2为不同网络的测试结果。在 3DMatch 上, MulFNet 特征召回率和配准召回率分别为 97.6% 和 91.2%, 在 3DLoMatch 上分别为 85.7% 和 61.7%。当采样点数量下降时, MulFNet 的匹配效果基本保持稳定,表明该网络提取的对应关系具有较好的稳定性。MulFNet 内点率优于大部分方法,即估计的对应点对接近真实值。此外, MulFNet 的配准召回率较高,该项指标最能反应点云配准的最终效果,意味着 MulFNet 的整体匹配效果较好,并且对采样点数的敏感性较低。3DLoMatch 重叠率远低于标准 3DMatch,而当点云对重叠区域减小时离群点数

表 1 不同网络在室内数据集 3DMatch 和 3DLoMatch 上的实验结果

Method	3DMatch FMR					3DLoMatch FMR				
	5000	2500	1000	500	250	5000	2500	1000	500	250
FCGF <sup>[20]</sup>	97.4	97.3	97	96.7	96.6	76.6	75.4	74.2	71.7	67.3
PREDATOR <sup>[18]</sup>	96.6	96.6	96.5	96.3	96.5	78.6	77.4	76.3	75.7	75.3
CoFiNet <sup>[31]</sup>	98.1	98.3	98.1	98.2	98.3	83.1	83.5	83.3	83.1	82.6
GeoTransformer <sup>[22]</sup>	97.9	97.9	97.9	97.9	97.6	88.3	88.6	88.8	88.6	88.3
MulFNet(Ours)	97.6	97.4	97.1	96.7	96.8	85.7	84.6	84.7	82.4	79.4
Method	3DMatch IR					3DLoMatch IR				
	5000	2500	1000	500	250	5000	2500	1000	500	250
FCGF <sup>[20]</sup>	56.8	54.1	48.7	42.5	34.1	21.4	20	17.2	14.8	11.6
PREDATOR <sup>[18]</sup>	58	58.4	57.1	54.1	49.3	26.7	28.1	28.3	27.5	25.8
CoFiNet <sup>[31]</sup>	49.8	51.2	51.9	52.2	52.2	24.4	25.9	26.7	26.8	26.9
GeoTransformer <sup>[22]</sup>	71.9	75.2	76	82.2	85.1	43.5	45.3	46.2	52.9	57.7
MulFNet(Ours)	66.5	63.6	70.8	67.2	65.3	38.1	38.6	35.2	36.1	30.8
Method	3DMatch RR					3DLoMatch RR				
	5000	2500	1000	500	250	5000	2500	1000	500	250
FCGF <sup>[20]</sup>	85.1	84.7	83.3	81.6	71.4	40.1	41.7	38.2	35.4	26.8
PREDATOR <sup>[18]</sup>	89	89.9	90.6	88.5	86.6	59.8	61.2	62.4	60.8	58.1
CoFiNet <sup>[31]</sup>	89.3	88.9	88.4	87.4	87	67.5	66.2	64.2	63.1	61
GeoTransformer <sup>[22]</sup>	92	91.8	91.8	91.4	91.2	75	74.8	74.2	74.1	73.5
MulFNet(Ours)	89.4	91.2	90.4	88.2	89.6	68.5	69.7	66.3	67.6	66.8

量增加,导致误匹配概率增大,因此在 3DLoMatch 上匹配效果整体有所降低,但 MulFNet 仍能保持较优水平。

表 2 比较了不同网络在 3DMatch 数据集上的运算速度。MulFNet 将 SVD 模块嵌入至网络中,因此相较于 FCGF, PREDATOR 等使用

RANSAC 进行后处理的网络, MulFNet 在位姿估计阶段用时较少,整体运算速度分别提升了 46.8% 和 65.6%。而由于本文网络需要提取点云的多层级特征,因此特征提取阶段耗时较长。图 6 为 MulFNet 在 3DMatch 上部分匹配可视化结果。

表 2 不同网络在室内数据集 3DMatch 和 3DLoMatch 的运行时间

Tab. 2 Running time of different methods on indoor 3DMatch and 3DLoMatch datasets (s)

Method	3DMatch			3DLoMatch		
	Feature	Pose	Total	Feature	Pose	Total
FCGF <sup>[20]</sup>	0.055	3.492	3.547	0.054	3.404	3.458
PREDATOR <sup>[18]</sup>	0.034	5.376	5.410	0.033	5.207	5.239
CoFiNet <sup>[31]</sup>	0.121	1.897	2.018	0.117	1.820	1.936
GeoTransformer <sup>[22]</sup>	0.079	1.636	1.715	0.076	1.598	1.674
MulFNet(Ours)	0.146	1.857	2.003	0.138	1.796	1.915

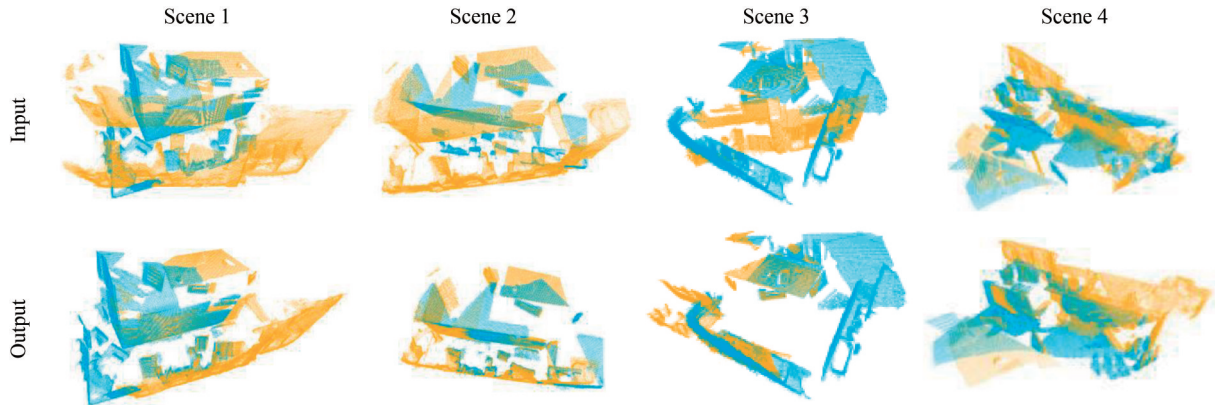


图 6 室内数据集 3DMatch 匹配结果可视化

Fig. 6 Visualization of indoor 3DMatch registration result

### 3.3 测量数据集

测量数据集的采集对象分别为汽车飞轮壳保护罩及汽车车门框,采集设备为面结构光扫描仪(PowerScan-Pro2-3M,测量精度 $\pm 0.02$  mm),使用添加噪声的模型离散点云作为训练集和验证集,使用零件实际采集测量点云作为测试集。由于 FMR 和 RR 不适用于评估小数量数据集匹配结果,因此,采用转换矩阵误差、距离误差和匹配有效率作为测量数据集的评价指标。

#### 3.3.1 转换矩阵误差

各向同性的旋转误差和平移误差为:

$$E_R = \left| \angle(\hat{R}^{-1}R^*) \right|, E_t = \|\hat{t} - t^*\|, \quad (16)$$

其中函数 $\angle(R)$ 将旋转矩阵转换为欧拉角。

距离误差。计算经过预测矩阵转换后,最近点对之间的距离误差:

$$E_{RMSE} = \sqrt{\frac{1}{n_{src}} \sum_{i=1}^{n_{src}} \|\hat{R}x_i + \hat{t} - y_{j^*}\|^2}, \quad (17)$$

其中: $n_{src}$ 为源点云中的点云数量; $y_{j^*}$ 为将点云对转换至同一坐标系下后,目标点云中距离源点云中 $x_i$ 最近的点。

匹配有效率。预测矩阵中非单位阵的比例:

$$valid = \frac{n}{|N|}, \quad (18)$$

其中: $n$ 为非单位阵数量, $N$ 为所有点对。



### 3.3.2 实验结果

采用传统算法 4PCS<sup>[12]</sup>, Super4PCS<sup>[35]</sup>, FGR<sup>[34]</sup>, FPFH<sup>[15]</sup>, ICP<sup>[3]</sup>, DPWVM<sup>[9]</sup>, 以及 FC-GF<sup>[20]</sup>, PREDATOR<sup>[18]</sup>, CoFiNet<sup>[31]</sup>, GeoTransformer<sup>[22]</sup>网络模型与本文算法进行比较。设置粗配准和精配准两种初始状态,目标点云为模型完整离散点云,源点云为零件局部测量点云,且所有源点云初始偏置相同。

飞轮壳测试集使用单次测量局部点云,由于

车身构件单次扫描点云重叠率过低,因此采用多视角拼接点云。此外,网络训练集未添加车身点云,因此,车身测试集的匹配效果表现了网络对于不同零部件配准的泛化性。

测量数据集实验结果分别为表 3、表 4,为简化表述, $Error(R)$ ,  $Error(t)$ ,  $Error(RMSE)$ ,  $Error(RMSE^*)$ 分别简化为  $ER$ ,  $ET$ ,  $RMSE$ ,  $RMSE^*$ 。由实验结果可见,本文网络在任意初始条件下的匹配效果均优于其他算法,表明它在处理低重叠

表 3 飞轮壳数据集实验结果(重叠率为 10.49%)

Tab. 3 Experimental results of flywheel shell dataset (overlap ratio of 10.49%)

Method	Coarse					Fine				
	Valid /%	RMSE /mm	RMSE /mm	ER /(°)	ET /mm	Valid /%	RMSE /mm	RMSE* /mm	ER /(°)	ET /mm
4PCS <sup>[12]</sup>	29	21.003	26.655	2.248	6.597	36	4.868	27.808	2.972	0.617
Super4PCS <sup>[35]</sup>	100	20.882	26.466	2.902	6.347	100	8.149	27.176	2.620	0.829
FGR <sup>[17]</sup>	100	9.510	13.901	0.790	3.368	100	3.390	9.047	0.346	0.409
FPFH <sup>[15]</sup>	21	26.064	31.703	2.978	7.538	21	7.736	23.031	2.960	0.925
ICP <sup>[3]</sup>	—	—	—	—	—	100	1.749	3.816	0.169	0.147
DPWVM <sup>[9]</sup>	—	—	—	—	—	100	1.601	4.690	0.312	0.134
FCGF <sup>[20]</sup>	14	7.781	31.886	3.613	0.610	9	2.082	3.399	0.377	0.154
PREDATOR <sup>[18]</sup>	99	19.283	23.571	2.424	5.737	100	6.041	25.949	2.421	0.820
CoFiNet <sup>[31]</sup>	100	9.202	11.804	1.035	2.846	100	1.501	7.704	0.789	0.189
GeoTransformer <sup>[22]</sup>	100	7.587	31.794	3.163	1.130	100	7.071	28.133	2.775	1.009
MulFNet(Ours)	78	1.385	5.419	1.097	0.248	65	1.032	1.649	0.151	0.078

表 4 车身数据集实验结果(重叠率 14.56%)

Tab. 4 Experimental results of car body dataset (overlap ratio of 14.56%)

Method	Coarse					Fine				
	Valid /%	RMSE /mm	RMSE* /mm	ER /(°)	ET /mm	Valid /%	RMSE /mm	RMSE* /mm	ER /(°)	ET /mm
4PCS <sup>[12]</sup>	20	25.719	27.682	3.573	6.684	20	7.689	33.365	4.863	0.843
Super4PCS <sup>[35]</sup>	100	30.458	32.661	2.828	6.597	98	10.555	25.859	2.899	0.931
FGR <sup>[17]</sup>	100	13.942	18.226	2.034	4.583	100	7.687	13.409	1.233	0.688
FPFH <sup>[15]</sup>	58	24.045	27.767	3.427	6.859	53	8.200	16.515	1.982	0.959
ICP <sup>[3]</sup>	—	—	—	—	—	90	1.837	3.352	0.143	0.123
DPWVM <sup>[9]</sup>	—	—	—	—	—	100	1.043	2.605	0.157	0.137
FCGF <sup>[20]</sup>	78	6.322	24.845	3.296	1.009	80	1.183	1.703	0.169	0.093
PREDATOR <sup>[18]</sup>	98	8.263	10.051	1.002	2.526	100	4.300	9.788	0.748	0.215
CoFiNet <sup>[31]</sup>	100	6.894	9.194	0.900	2.223	100	3.333	7.433	0.581	0.161
GeoTransformer <sup>[22]</sup>	100	7.672	33.404	2.651	1.083	100	6.811	28.089	3.103	1.059
MulFNet(Ours)	67	3.171	12.464	1.121	0.343	82	0.958	1.379	0.274	0.151

点云匹配失真问题时具有显著优势。飞轮壳测试集的平均重叠率为 10.49%，数据集的整体匹配误差为 1.032 mm，由于不同测量区域点云匹配效果存在差异，样本中最小匹配误差仅为 0.649 mm。相较于 ICP 和 PREDATOR，本文网络在飞轮壳数据集的匹配精度 RMSE\* 分别提升 56.79% 和 93.64%，在车身上分别提升 58.86% 和 85.9%。本文网络的 RMSE 与 RMSE\* 相差较小，说明 MulFNet 网络在处理具有重复几何结构的低重叠率点云时，能结合特征信息和位置信息过滤错误点对，有效解决匹配失真，正确还原点云位置。

本文网络模型与现有方法的配准结果对比如图 7 所示，大部分方法在进行低重叠率点云匹配时均易产生匹配失真。点云匹配网络 (Cofinet, FCGF) 主要依赖点云特征进行对应关系

搜索，虽然小范围强特征区域匹配成功，但整体匹配效果较差；DPWVM, ICP 等算法则基于几何空间距离进行迭代优化，点云整体匹配均匀但最终误差较大；其余算法因重叠率过低，或需要手动逐个调整相关参数，最终均匹配失效。从图 8 观察可得，针对局部重叠点云的匹配问题，最近距离误差 RMSE 存在一定局限性，不能很好地反映匹配发生整体偏移失真的现象，因此，真实点对之间的距离误差 RMSE\* 能更准确地评价最终匹配效果。相同初始偏置下改变扫描区域和重叠率的匹配结果如图 9 所示，表明扫描区域选择与重叠率均会对点云匹配精度造成影响，当选择强特征、低重叠率区域时，有可能获得较好的匹配效果，但总体上匹配效果的稳定性随着重叠率的提升而提升。

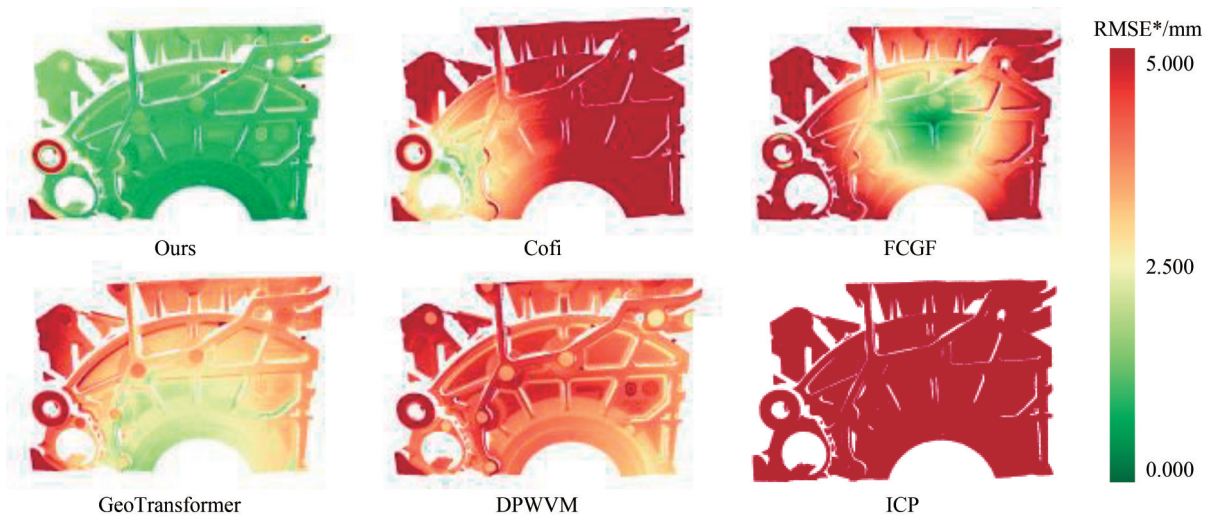


图 7 飞轮壳单次测量点云匹配误差色谱

Fig. 7 Registration error chromatogram in single scanning of flywheel shell




图 8 最近对应点与真实对应点的评价指标差异

Fig. 8 Difference of evaluation index between nearest correspondence and positive correspondence




图 9 车身数据集 3DMatch 匹配结果

Fig. 9 Registration results of car body dataset by 3D Match with different overlap ratios

### 3.4 消融实验

本文将网络分为多层级特征、信息交互、对应关系筛选三个模块,为评估每个模块对于提升网络匹配精度的有效性,在飞轮壳测量数据集上进行消融实验,其中“√”表示在网络中保留该模块作用,“×”反之,实验结果如表 5 所示。

多尺度一致性利用多层级特征初步构建对应关系,修剪错误点对(图 10)完成特征筛选;信息交互模块通过特征交互实现显著特征提取,同时引入位置刚性约束纠正错误点对,除去该

模块则会导致内点率大幅下降;对应关系筛选模块基于局部至全局的方法进行转换矩阵估计,实现转换矩阵过滤,除去该模块则会影响到过滤外点的能力,影响网络匹配的鲁棒性。复杂零件局部测量点云的低重叠率匹配任务重点在于如何在有限区域内提取显著特征并排除零件重复结构的干扰,在大量外点中正确寻找真实对应关系,因此对应关系筛选模块对于网络匹配精度的提升效果最为显著,信息交互模块次之。

表 5 MulFNet 各模块消融实验结果

Tab. 5 Ablation experiment result of MulFNet architecture

Multi-level	Info-Interaction	Filter	Valid/%	RMSE/mm	RMSE*/mm	ER/mm	ET/(°)
×	√	√	38	1.706 2	5.946 2	0.354 9	0.237 2
√	×	√	47	2.336 8	7.286 4	0.601 1	0.247 9
√	√	×	83	2.521 4	11.113 4	1.107 0	0.371 2
√	√	√	65	1.031 5	1.649 0	0.150 6	0.077 8




图 10 飞轮壳多尺度特征一致性决策

Fig. 10 Consistency voting of multi-scale features in flywheel shell

## 4 结 论

本文针对低重叠率点云匹配失真的问题,提出了一种多层次过滤网络模型 MulFNet,结合点云多级语义特征信息和几何位置信息,在高维特征空间预测变换并通过多层次过滤筛选,使得网络在任意初始位姿下均能取得较优且稳定的匹配结果。在 3DMatch 和 3DLoMatch 公共数据集上, MulFNet 的特征召回率分别为 97.6% 和 85.7%, 配准召回率分别为 91.2% 和 61.7%, 均

优于 FCGF, PREDATOR 等主流网络, 同时运算速度明显提升。在零部件测量数据集上, MulFNet 相较于 ICP 和 FPFH 等传统算法的匹配误差分别降低了 40.9% 和 86.6%, 与 PREDATOR 和 GeoTransformer 等学习网络相比分别降低了 82.9% 和 85.4%, 能有效实现 10% 低重叠率下单次测量点云的精确配准。

针对复杂零部件表面不同区域的测量点云, 匹配精度有所波动, 后续工作可考虑几何特征、点云尺度等影响因素, 进一步提升匹配稳定性。

### 参考文献:

- [1] 林森, 张强. 应用邻域点信息描述与匹配的点云配准[J]. 光学精密工程, 2022, 30(8): 984-997.  
LIN S, ZHANG Q. Point cloud registration using neighborhood point information description and matching[J]. *Opt. Precision Eng.*, 2022, 30(8): 984-997. (in Chinese)
- [2] YIN M, ZHU Y Y, YIN G F, *et al.* Deep feature interaction network for point cloud registration, with applications to optical measurement of blade profiles [J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(8): 8614-8624.
- [3] BESL P J, MCKAY N D. A method for registration of 3-D shapes[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1992, 14(2): 239-256.
- [4] PAVLOV A L, OVCHINNIKOV G W, DERBY-SHEV D Y, *et al.* AA-ICP: iterative closest point with Anderson acceleration[C]. 2018 *IEEE International Conference on Robotics and Automation (ICRA)*. May 21-25, 2018. Brisbane, QLD. IEEE, 2018: 3407-3412.
- [5] 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)
- [6] 刘跃生, 陈新度, 吴磊, 等. 混合稀疏迭代最近点配准[J]. 光学精密工程, 2021, 29(9): 2255-2267.  
LIU Y SH, CHEN X D, WU L, *et al.* Mixed sparse iterative nearest point registration [J]. *Opt. Precision Eng.*, 2021, 29(9): 2255-2267. (in Chinese)
- [7] ZHANG J Y, YAO Y X, DENG B L. Fast and robust iterative closest point [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3450-3466.
- [8] LV R, LIU H D, WANG Z J, *et al.* WPMVM: weighted plus-and-minus allowance variance minimization algorithm for solving matching distortion [J]. *Robotics and Computer-Integrated Manufacturing*, 2022, 76: 102320.
- [9] 吴浩, 冯晓志, 华林, 等. 基于去伪加权方差最小化算法的大型复杂零部件局部配准全局方法研究 [J]. 中国科学: 技术科学, 2024, 54(3): 422-442.  
WU H, FENG X ZH, HUA L, *et al.* Local-to-global registration method of large complex components based on a de-pseudo-weighted variance minimization algorithm [J]. *Scientia Sinica (Technologica)*, 2024, 54(3): 422-442. (in Chinese)
- [10] FISCHLER M A, BOLLES R C. *Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography* [M]. Readings in Computer Vision. Amsterdam: Elsevier, 1987: 726-740.
- [11] YANG Z F, WANG X G, HOU J. A 4PCS coarse registration algorithm based on ISS feature points [C]. 2021 *40th Chinese Control Conference (CCC)*. July 26-28, 2021. Shanghai, China. IEEE, 2021: 7371-7375.
- [12] 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.
- [13] STECHSCHULTE JM AHMED N, HECKMAN C. Robust low-overlap 3-D point cloud reg-




- istration for outlier rejection[C]. 2019 *International Conference on Robotics and Automation (ICRA)*, 2019: 7143-7149.
- [14] ZHONG B, LI D. SliceLRF: a local reference frame sliced along the height on the 3D surface[J]. *Sensors*, 2023, 23(7): 3483.
- [15] RUSU R B, BLODOW N, BEETZ M. Fast point feature histograms (FPFH) for 3D registration[C]. *Proceedings of the 2009 IEEE international conference on Robotics and Automation*. May 12-17, 2009, Kobe, Japan. ACM, 2009: 1848-1853.
- [16] LIU X S, LI A H, SUN J F, *et al.* Trigonometric projection statistics histograms for 3D local feature representation and shape description [J]. *Pattern Recognition*, 2023, 143: 109727.
- [17] ZHOU Q Y, PARK J, KOLTUN V. *Fast Global Registration* [M]. Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 766-782.
- [18] HUANG S Y, GOJCIC Z, USVYATSOV M, *et al.* PREDATOR: Registration of 3D point clouds with low overlap[C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021: 4265-4274.
- [19] HUANG X S, QU W T, ZUO Y F, *et al.* IMF-Net: interpretable multimodal fusion for point cloud registration[J]. *IEEE Robotics and Automation Letters*, 2022, 7(4): 12323-12330.
- [20] 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.
- [21] 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.
- [22] 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.
- [23] YEW Z J, LEE G H. REGTR: end-to-end point cloud correspondences with transformers[C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 18-24, 2022. New Orleans, LA, USA. IEEE, 2022: 6667-6676.
- [24] ZHANG X Y, YANG J Q, ZHANG S K, *et al.* 3D registration with maximal cliques [C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023. Vancouver, BC, Canada. IEEE, 2023: 17745-17754.
- [25] 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.
- [26] QIU S, ANWAR S, BARNES N. Semantic segmentation for real point cloud scenes via bilateral augmentation and adaptive fusion[C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 20-25, 2021. Nashville, TN, USA. IEEE, 2021: 1757-1767.
- [27] CHOY C, GWAK J, SAVARESE S. 4D spatio-temporal ConvNets: minowski convolutional neural networks[C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019. Long Beach, CA, USA. IEEE, 2019: 3070-3079.
- [28] LOWE D G. Object recognition from local scale-invariant features[C]. *Proceedings of the Seventh IEEE International Conference on Computer Vision*. September 20-27, 1999. Kerkyra, Greece. IEEE, 1999: 1150-1157.
- [29] SARLIN P E, DETONE D, MALISIEWICZ T, *et al.* SuperGlue: learning feature matching with graph neural networks[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020. Seattle, WA, USA. IEEE, 2020: 4937-4946.
- [30] CUTURI M. Sinkhorn distances: lightspeed computation of optimal transport [C]. *Proceedings of the 26th International Conference on Neural Information Processing Systems-Volume 2*. December 5-10, 2013, Lake Tahoe, Nevada. ACM, 2013: 2292 - 2300.
- [31] YU H, LI F, SALEH M, *et al.* CoFiNet: reli-

- able coarse-to-fine correspondences for robust point cloud registration[J]. *arXiv. arXiv*:2110.14076.
- [32] LI J X, CHEN B M, LEE G H. SO-Net: Self-organizing network for point cloud analysis[C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018: 9397-9406.
- [33] SUN Y F, CHENG C M, ZHANG Y H. Circle loss: a unified perspective of pair similarity optimization [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020: 6397-6406.
- [34] ZENG A, SONG S R, NIESSNER M, *et al.* 3DMatch: learning local geometric descriptors from RGB-D reconstructions[C] 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017: 199-208.
- [35] 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.

**作者简介:**

贺敏琦(1999—),女,湖南株洲人,硕士研究生,主要从事机器视觉方面的研究。E-mail: heminqi2021@whut.edu.cn

**通讯作者:**

吴浩(1999—),男,河南商丘人,博士研究生,主要从事机器人视觉伺服技术的研究。E-mail: wuhao2023@whut.edu.cn