

DOI: 10.19650/j.cnki.cjsi.J2514738

基于 LGSA-HFFNet 的多尺度特征融合点云配准算法*

于智龙,高东浦,黄成,齐丽华,张彪

(哈尔滨理工大学自动化学院 哈尔滨 150080)

摘要:为了解决基于点云配准的阀门位姿估计工作中点云背景复杂、部分特征被遮挡缺失、噪声干扰等问题,提出了一种轻量化图-空间注意力机制的多尺度特征融合点云配准网络(LGSA-HFFNet)点云配准算法。该方法设计并使用多尺度并行卷积特征提取层,强化模型特征提取,避免模型训练中梯度爆炸问题并加速收敛;其次,设计结合图注意力与空间注意力机制并进行轻量化改进的轻量化图-空间注意力机制(LGSA)模块,解决由点云信息特征的无序性造成的神经网络特征提取困难的问题,使模型能够有效提取点云局部特征;最后,使用设计位姿估计实验验证系统,将模型在实际阀门位姿估计工作中进行实机部署实验。实验结果表明,LGSA-HFFNet算法在阀门点云配准实验中平均相对平移误差低至0.05 m,对旋转误差低至0.984°,且具有良好的鲁棒性,在复杂背景下平移及旋转配准性能仅下降2%、7.5%,配准耗时相较于迭代最近点(ICP)降低80.32%,配准性能远优于ICP和半正定随机化抽样一致(SDRSAC)等传统算法;在ModelNet40对比实验中的旋转、平移误差降低至2.293°和0.006 m,配准旋转误差达到比较先进的水平,平移误差较现有模型有较大优势;在噪声干扰较大的真实场景阀门位姿估计数据集实验中误差降低至2.175°和0.036 m,相较于现有模型误差至少降低28.98%和17.81%。

关键词:点云配准;图注意力;空间注意力;特征融合;轻量化网络

中图分类号: TH89 TP249 **文献标识码:** A **国家标准学科分类代码:** 413.1050

Multi-scale feature fusion point cloud registration algorithm based on LGSA-HFFNet

Yu Zhilong, Gao Dongpu, Huang Cheng, Qi Lihua, Zhang Biao

(School of Automation, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: To address challenges in valve pose estimation based on point cloud registration—such as complex backgrounds, occluded or missing features, and noise interference—the article proposes a lightweight graph-spatial attention-hierarchical feature fusion network (LGSA-HFFNet) algorithm. This approach designs and employs a multi-scale parallel convolutional feature extraction layer to enhance feature extraction, prevent gradient explosion during training, and accelerate convergence. It further incorporates a lightweight graph-spatial attention (LGSA) module, a streamlined enhancement combining graph and spatial attention, to overcome neural network difficulties in extracting features from disordered point cloud information, enabling effective extraction of local point cloud features. Finally, the system is validated through pose estimation experiments and deployed in real-world valve pose estimation tasks. Experimental results demonstrate that the LGSA-HFFNet algorithm achieves an average relative translation error of 0.05 m and a rotation error of 0.984 degrees in valve point cloud registration experiments. It exhibits excellent robustness, with translation and rotation registration performance degrading by only 2% and 7.5%, respectively, under complex backgrounds. Registration time is reduced by 80.32% compared to the iterative closest point (ICP) algorithm, with performance significantly outperforming traditional methods like ICP and semidefinite-based randomized sample consensus (SDRSAC). In ModelNet40 benchmark tests, rotational and translational errors were reduced to 2.293 degrees and 0.006 m, respectively, with rotational accuracy reaching an advanced level and translational accuracy showing a significant advantage over existing models. In experiments using real-world valve pose estimation

收稿日期:2025-12-01 Received Date: 2025-12-01

* 基金项目:黑龙江省自然科学基金(LH2023F032)项目资助

datasets with high noise interference, the proposed method achieves errors of 2.175 7 degrees and 0.036 m, representing reductions of at least 28.98% and 17.81% compared to existing models.

Keywords: point cloud registration; graph attention; spatial attention; feature fusion; lightweight network

0 引言

点云配准是指将两个或多个不同角度、不同传感器采集到的三维点云,通过旋转、平移等变换方式对齐到同一坐标系中,形成更完整点云的过程。点云配准在三维重建^[1]、自动驾驶^[2]、辅助精密装配^[3]、医学图像处理^[4]等领域有重要作用,属于三维视觉处理领域的基础性工作。随着自动驾驶和机器人技术近年来的迅猛发展,对点云配准及处理的技术提出了更高要求。

基于点云配准在点云处理工作中的重要作用,其相关算法发展已有较长历史。迭代最近点^[5](iterative closest point, ICP)算法作为点云配准传统算法中最经典的算法,其通过迭代的算法寻找源点云和输入点云之间最匹配的点对完成配准工作,但其配准效果受到点云起始位置和噪声干扰严重。文献[6]提出一种基于点云稀疏语义特征计算初值偏航角的配准算法,解决配准算法对初值的依赖问题。文献[7]提出了一种基于骨架点云配准的位姿估计算法,使用双向K维树(K-dimensional tree, KD-Tree)实现ICP算法的点到面配准。文献[8]向加速稳健特征引入几何代数构建描述子,取得了较好的配准效果,但配准速度较慢。文献[9]提出快速点特征直方图描述算子,降低配准算法时间复杂度,适合于实际应用。文献[10]提出了基于随机采样的策略的半正定随机化抽样一致(semidefinite-based randomized sample consensus, SDRSAC)方法,简化了配准计算流程,但配准结果与迭代次数强相关,计算复杂度较大。文献[11]提出一种结合目标物体表明反射率和先验信息的点云分割配准算法,针对空间非合作目标位姿配准难的问题效果较好,但结果稳定性差。文献[12]提出了一种基于旋转不变特征和稀疏矩阵匹配进行点云配准的方法,取得了较好的配准结果。文献[13]提出了一种融合多种点云几何特征,并使用协方差自适应尺度融合旋转投影和快速点特征的配准算法,但计算复杂度很高。

当前较为流行的点云配准方法是使用深度学习方法,通过神经网络提取点云数据中更易于分辨、更抽象的特征。文献[14]提出了一种基于点云的校正虚拟对应点深度学习算法,较好地解决了离群点的问题,提高了处理效率。文献[15]提出了一种基于双路并行回归目标平移向量和三维边界角点的配准算法,解决了对称物体的误配准问题。文献[16]提出的多特征引导网

络通过利用形状特征和点的空间坐标来寻找对应点,并将对应点的搜索结果融合到匹配矩阵。文献[17]提出了一种针对激光点云的特性分层提取关键点和描述子的配准算法,在大规模室外点云配准中取得了较好的效果。文献[18]提出一种融合位置自适应卷积和群等变计算的点云特征提取算法,提高了卷积网络在点云处理工作上的效率。文献[19]首次将堆叠自注意力机制应用在点云特征提取领域,极大提升了神经网络在点云处理方面的性能。文献[20]提出了深度注意机制点云重合区域配准(pointcloud registration with deep attention to the overlap region, PREDATOR)方法,在点云配准中引入重叠注意力机制,在低重叠点云配准上取得了较好的结果。文献[21]提出的Transformer配准算法(registration Transformer, REGTR),在交叉编码器模块中使用多头自-交叉注意力机制,拓展了注意力机制在点云配准中的应用。文献[22]提出了一种增强几何结构Transformer,可有效学习点云几何结构的增强特征,在简化交叉注意力机制模块方面取得了一定成果。

在实际应用中,点云采集设备操作过程中往往无法避免形变、噪声干扰、部分遮挡等问题。而现有的点云配准算法大多依赖逐点特征提取和匹配,并且依赖传统算法驱动的特征匹配,这容易导致错匹配、漏匹配、计算量大、速度慢等问题。在本文的阀门巡检场景中,阀门的检测、操作需要配准算法在保证速度的情况下引导机器人精确对齐阀门中心,并实现工具法兰与阀门的同轴,目前的算法大多难以满足要求。

针对以上问题,本文提出一种基于轻量化图-空间注意力的多尺度特征融合点云配准网络(lightweight graph-spatial attention-hierarchical feature fuse network, LGSA-HFFNet)。该网络结合卷积特征和图注意力、空间注意机制进行多尺度特征提取与融合,学习并输出融合关键点信息、点云局部特征信息的多尺度特征;最后通过多层感知机对输入点云和模板点云进行回归配准。本文主要贡献包括:

- 1) 设计多尺度并行卷积特征提取层,并在卷积特征提取过程中引入残差结构,在编码过程中更好捕获点云局部特征与全局特征并使之结合,提高模型的表达能力和泛化能力。同时避免网络出现梯度消失的问题,加速网络收敛。

- 2) 设计结合图注意力与空间注意力机制的轻量化图-空间注意力机制LGSA模块,解决由点云信息特征的

无序性造成的神经网络特征提取困难的问题,强化网络对点云局部特征的辨别能力,提升特征缺失和噪声干扰条件下的特征提取精度,同时对注意力机制进行轻量化改进,降低部署资源占用,提升计算效率。

3) 搭建阀门巡检机器人并设计阀门点云配准实验,在实际工作场景中验证 LGSA-HFFNet 的有效性;在 ModelNet40 数据集、自制真实阀门点云估计数据集上进行广泛的对比实验,验证模型的优越性。

1 基于 LGSA-HFFNet 的多尺度特征融合点云配准算法

1.1 整体网络结构

本文构建的基于图注意力机制和空间注意力机制的配准网络主要由点云特征提取模块和点云配准姿态回归模块两部分组成,网络整体结构如图 1 所示。

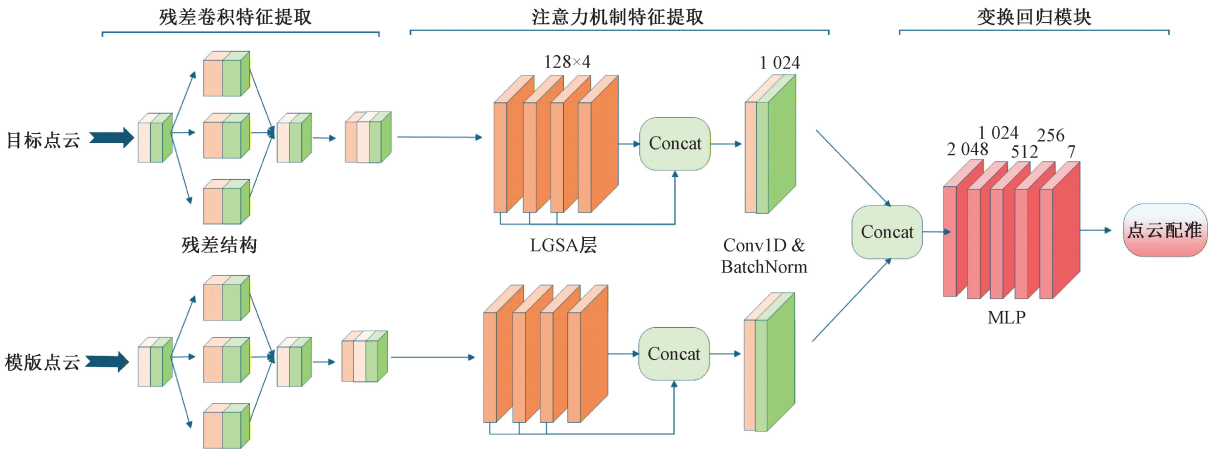


图 1 LGSA-HFFNet 结构
Fig. 1 LGSA-HFFNet architecture

残差卷积特征提取模块对模板点云和目标点云进行特征预提取,得到点云的特征并对点云特征进行输入编码,增强点云特征表达能力,加速网络收敛。基于堆叠 LGSA 模块的 Transformer 框架逐级提取点对与点对之间的语义特征和空间位置特征,并使用卷积标准化操作调整特征维度,融合点云的逐点特征、上下文信息和空间维度特征,解决由局部遮挡、形变和噪声导致的点云特征提取异常的问题。由于在特征提取与融合过程中,模板点云与目标点云各被重整为 1×1024 大小,再次使用拼接层将模板点云与目标点云拼接为 1×2048 的组合特征,最后使用基于多层感知机的点云姿态回归模块对模板点云与目标点云间的旋转矩阵和平移向量进行计算,输出层的大小为 7,代表以四元数表示旋转的 3 个旋转角度和平移向量的值,即点云配准结果。

1.2 残差卷积特征提取模块

对于给定的模板点云和目标点云,通常使用卷积网络模块提取其特征,以实现点云特征编码。相较于传统二维图像信息,三维点云的信息特征在局部相互独立,传统卷积网络可以一定程度上提取点云特征,但对局部特征不敏感。

针对以上问题,设计具有不同感受野的并行卷积层以增强特征提取模块的特征提取能力,并引入残差

结构以应对网络加深带来的梯度问题,模块结构如图 2 所示。

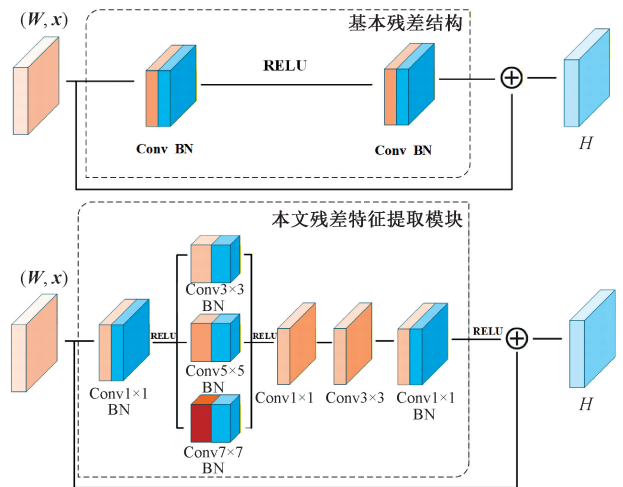


图 2 残差模块结构
Fig. 2 Structure of the residual module

LGSA-HFFNet 的残差模块先使用 1×1 的卷积层进行通道压缩,减少计算量;然后分别使用卷积核大小为 7×7 、 5×5 、 3×3 的卷积层分支处理并使用 1×1 卷积层进行分支融合,获取感受野为 3~15 的多尺度特征,大感受

野的卷积用来提取全局特征,较小感受野的卷积核支持局部点对特征的提取;最后联合使用 3×3 和 1×1 卷积进行特征增强,并调整网络的输出特征维度。为了提升网络训练的稳定性,减轻梯度消失和梯度爆炸的问题,在模型引入深度网络常用的残差连接机制,残差块的跳跃连接公式如式(1)所示。

$$H(\mathbf{W}, \mathbf{x}) = F(\mathbf{W}, \mathbf{x}) + \mathbf{x} \quad (1)$$

式中: \mathbf{x} 为网络的输入; $F(\mathbf{W}, \mathbf{x})$ 为残差函数; \mathbf{W} 为本层网络权重; $H(\mathbf{W}, \mathbf{x})$ 为残差模块期望的最终输出。经过网络训练的优化过程后, $F(\mathbf{W}, \mathbf{x})$ 会逐渐趋近于 0, 使得浅层的信息可以越过中间层直接传递给较深的层。同时在模块多个关键计算位置使用批标准化层和 ReLU 激活函数,有效保持网络训练时的稳定性,加快收敛速度。

1.3 LGSA 模块

由于点云中点相对独立的特性,传统的注意力机制模块虽然可以提取对应点对的几何特征,但在点对与点对之间的位置特征提取方面不够敏感。由于阀门点云配准时存在局部特征缺失和噪声干扰问题,点之间位置特征的缺失会导致配准结果回归计算的误差大、鲁棒性差。因此,本文提出结合图注意力与空间注意力机制的轻量化图-空间注意力机制 LGSA 模块。其使用图注意力机制获取点对与点对之间的关系性和语义特征,使用空间注意力机制提取点云的空间位置特征和几何特征,其结构如图 3 所示。

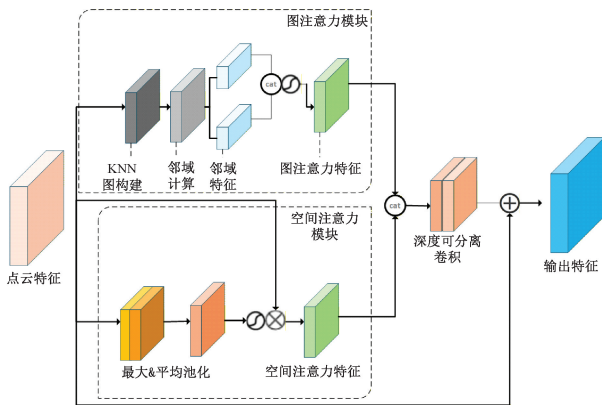


图 3 LGSA 模块结构

Fig. 3 Structure of the LGSA module

在点云特征输入阶段采用动态 K 临近算法 (K-nearest neighbor, KNN) 图构建初始图结构。动态 KNN 图通过计算特征空间中每个点与最近邻的欧氏距离,获得比坐标距离更加反映点之间语义相似性的特征图,其计算如式(2)所示。

$$d(i, j) = \sqrt{\sum (\mathbf{x}_i - \mathbf{x}_j)^2} \quad (2)$$

$$N(i) = f_{\text{topk}}(d(i, j), k) \quad (3)$$

式中: $d(i, j)$ 为每个节点与其他节点的距离; $N(i)$ 为与第 i 个节点最近的 k 个节点特征距离向量。动态 KNN 图在每次前向传播中重新计算,与静态图相比显著提升网络对点云几何结构和语义信息的感知能力。为了平衡局部特征与计算量,选择 $k = 15$ 实现局部注意力聚合。

在图注意力机制计算阶段,针对实际使用场景中点云数据量大、计算实时性要求高的需求,本模型使用了轻量化的图注意力设计。与传统图注意力机制设计相比, LGSA-HFFNet 的图注意力机制层仅使用了单头图注意力;并且抛弃了常见的位置编码信息,仅对点云特征进行拼接处理;同时仅对各节点进行共享权重的线性变换。轻量化图注意力机制表达式如式(4)~(7)所示。

$$\mathbf{h} = \mathbf{W}_g \cdot \mathbf{x}^T \quad (4)$$

$$\mathbf{e}_{ij} = f_{\text{LeakyReLU}}(\mathbf{a}^T \cdot \mathbf{h}_{ij}) \quad (5)$$

$$\alpha_{ij} = \frac{\exp(\mathbf{e}_{ij})}{\sum_{k \in N(i)} \exp(\mathbf{e}_{ik})} \quad (6)$$

$$\mathbf{G} = \sum_{j \in N(i)} \alpha_{ij} \cdot \mathbf{h}_j \quad (7)$$

式中: \mathbf{h} 为节点特征; \mathbf{h}_j 为 \mathbf{h}_i 的相邻节点特征; \mathbf{h}_{ij} 为拼接后的相邻节点特征; \mathbf{G} 为图注意力计算的每个节点的最终特征得分; \mathbf{e}_{ij} 为节点特征得分; α_{ij} 为 Softmax 归一化后的节点 i 对其他节点的注意力权重。

图注意力模块有效解决了点云邻域各点之间呈现的各向同性造成网络权重特征消失的问题,提升网络特征提取能力。同时,为了补偿轻量化图注意力机制过程中丢弃的点位置编码和几何特征信息,提升点云配准的鲁棒性, LGSA 模块中引入空间注意力机制。由于空间注意力机制主要关注点所在位置的特征信息,对包含完整信息的初始输入特征分别做平均池化和最大池化,得到全局特征和局部特征两个特征图并进行卷积拼接,最后将空间注意力特征图与输入特征相乘,得到最完整的空间注意力特征,其表达式如式(8)和(9)所示。

$$\mathbf{M} = \sigma(f_{w_c} [F_{\text{avg}}, F_{\text{max}}]) \quad (8)$$

$$\mathbf{S} = \mathbf{x} \cdot \mathbf{M} \quad (9)$$

式中: f_{w_c} 是卷积操作; \mathbf{x} 为初始输入特征; \mathbf{S} 为最终输出的空间注意力特征。

在获得了图注意力特征和空间注意力特征后,将两者拼接,并使用卷积层对拼接特征进行特征融合和通道调整。为了降低计算量保持网络轻量化,在卷积环节选择深度可分离卷积进行操作。通过深度卷积提取局部空间模式,点卷积实现跨特征通道的智能融合,并显著降低网络的计算量。最后引入残差连接机制,将初始特征与注意力融合特征相加,确保信息完整性和训练稳定性。

1.4 损失函数

在对模板点云和目标点云特征提取后,将两者特征进行拼接,形成 $1 \times 2 \times 048$ 大小的拼接特征,并输入变换回

归模块进行配准所需的姿态计算。变换回归模块使用一个多层感知神经网络对旋转矩阵 \mathbf{R} 和平移向量 \mathbf{T} 进行回归,网络包含4个全连接隐藏层,其神经元数量分别为2 048、1 024、512、7,最后解析输出层的输出向量即可得到点云变换关系,完成配准。

为了提高配准的精度和LGSA-HFFNet的可用性,使用倒角距离(chamfer distance, CD)^[23]作为本网络的损失函数,该损失以配准结果与模板点云的对应点间距离最小化为优化目标,并引导网络参数更新。其表达式如式(10)所示。

$$d_{CD}(\mathbf{P}_T^{est}, \mathbf{P}_S) = \frac{1}{P_T^{est}} \min_{y \in P_S} \| \mathbf{x} - \mathbf{y} \|_2^2 + \frac{1}{P_{Sx \in P_T^{est}}} \min_{y \in P_S} \| \mathbf{y} - \mathbf{x} \|_2^2 \quad (10)$$

式中: \mathbf{P}_S 为模板点云; \mathbf{P}_T^{est} 为经网络位姿变换后的目标点云; $\mathbf{x} \in \mathbf{P}_T^{est}$; $\mathbf{y} \in \mathbf{P}_S$ 。式(10)第1项计算模板点云中任意一点到目标点云中点的距离,第2项反过来计算,该距离小代表两片点云的差异小、重合度好,说明点云配准的结果更好。

2 实验及结果分析

2.1 阀门点云配准实验

1) 实验平台及设计

使用带有双目深度相机的阀门巡检机器人、待测目标阀门及拟真阀门管路等搭建阀门点云配准仿真验证系统。实验机器人的计算平台采用机器人中常见的NVIDIA Jetson Orin Nano嵌入式计算设备,算力约20 TOPS;机械臂使用重复定位精度 ± 0.5 mm的协作机器人;深度视觉系统采用奥比中光 Gemini 335 双目深度相机,在1 m以内的距离下深度误差 $< 1\%$,可有效降低设备精度误差对实验结果的影响。机器人结构示意图如图4所示。





图4 机器人结构


Fig. 4 Robot structure

在训练阶段,实验使用的硬件环境如下,CPU为AMD Ryzen R9-9950X,GPU为RTX4090 24 GB,内存为64 GB,系统版本为Ubuntu 22.04;使用的深度学习框架和软件版本为Python3.9,PyTorch 2.5.0,CUDA 12.4。训练阶段未使用预训练权重,输入的点云下采样至4 096个点,采用动态批次,批次大小从8开始,随训练过程逐渐提升到16;优化器使用Adam优化器,初始学习率为0.0002,总训练轮数为200轮。

在阀门点云配准实验阶段,实验环境选择在光线较为昏暗的室内车间进行以模拟真实阀门巡检工作场景,待测阀门采用不同种类的球阀和闸阀1:1搭建,阀门的直径约40 cm;机器人车体距离模拟管道距离为1 m。相机安装在协作机械臂末端执行器上,彩色图像分辨率为1 280 \times 720,深度图像分辨率设定为848 \times 480,视场角为90 $^\circ$ \times 65 $^\circ$,并通过软件配准的方式将深度图配准至与彩色图相同的分辨率,输出图像帧率设定为30 fps。设定阀门正前方为0 $^\circ$ 基准值,末端执行器按照与阀门间隔50 cm为半径,从45 $^\circ$ 到0 $^\circ$ 的弧形轨迹运动,运动速率设定为4 $^\circ$ /s。阀门目标提取使用彩色图目标识别、深度图裁切、点云生成的方式获得目标阀门区域的点云,对点云进行离群点去除滤波后,在机械臂末端执行器运动过程中不断计算阀门点云配准的结果、计算配准误差并记录。为了便于数据采集与对比实验,数据输出的频率设置为约2 Hz。阀门位姿估计实验场景及点云扫描如图5所示。



(a) 配准实验场景
(a) Calibration of experimental scenarios



(b) 实验场景点云
(b) Experimental scene point cloud

图5 实验场景及场景点云扫描

Fig. 5 Experimental scenarios and point cloud scanning

2) 阀门点云配准实验及误差分析

由于本实验在机器人平台部署,程序运行的环境为: Ubuntu22.04、Nvidia Jetpack 6.2;用于对比的 ICP 算法功能由点云处理库 PCL 提供,本文模型使用 ONNX 引擎部署;机器人控制及相机图像采集等使用 ROS2 机器人操作系统实现。在系统资源占用评估中,本模型在边缘计算板上部署时内存占用约为 1.2 GB,可轻松部署在资源有限的嵌入式计算平台上。

实验采集机械臂运动过程中约 12 s,共 24 组点云数据,使用本文模型、ICP 算法和 SDRSAC 算法进行配准计算。本文模型在机械臂运动过程中动态计算点云配准结果并记录,ICP^[5]算法和 SDRSAC^[10]算法使用运动过程中保存的点云文件和机械臂运动信息单独计算。综合对配准结果的沿各轴平移、旋转误差和算法耗时进行结果分析,其中耗时由点云预处理耗时和算法计算耗时两部分组成,由于点云数据在发布给计算节点前已做好预处理工作,只统计算法纯计算耗时。实验过程中本文模型部分点云结果可视化如图 6 所示。

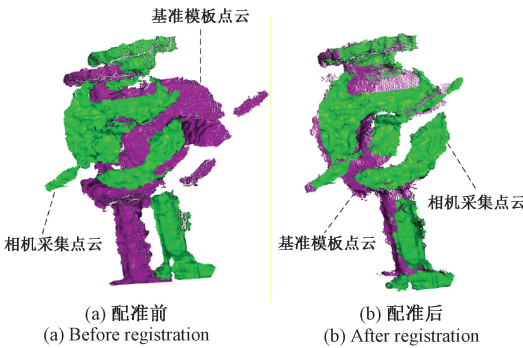
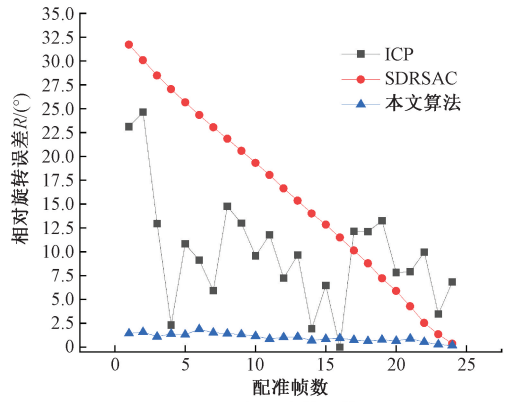


图 6 配准结果可视化


Fig. 6 Visualization results of point cloud registration

由图 6 可知,当相机与待测阀门夹角较大时,受深度相机视角造成的遮挡影响,实时采集点云与基准模板点云间的局部特征可能会具有较大差异。对于运动过程中采集到的点云,将其与预先保存的基准位置点云进行旋转、平移参数求解,配准结果的相对旋转误差 R 和相对平移误差 T 如图 7 所示。在采集点云与模板点云特征差异较大的运动前期,传统算法受特征缺失影响较大,随着运动的进行配准精度逐渐提高,但本文算法受这种特征变化的影响较小,且性能远优于对比的两种传统算法。

配准结果中绕各坐标轴的旋转误差如图 8 所示。根据阀门点云配准的任务指标要求,阀门所在位置坐标可根据深度相机采集的深度值和相机内参计算获得,影响阀门开关任务成功率的主要因素为旋转变量。由图 8 可知,部分局部特征缺失对传统算法的旋转配准精度影



(a) 相对旋转误差
(a) Relative rotational error




(b) 相对平移误差
(b) Relative translation error

图 7 配准结果误差对比

Fig. 7 Registration error comparison diagram

响较大。由于实验过程中设定的运动可近似为机械臂末端绕相机坐标系 Y 轴旋转,绕 Y 轴旋转配准误差较大地影响了相对旋转误差的统计,呈现出与相对旋转误差图像类似的变化趋势。对 3 种算法配准实验的各项误差、耗时数据进行综合分析,实验配准结果统计表如表 1 所示。



(a) X轴旋转配准误差
(a) X-axis rotational registration error

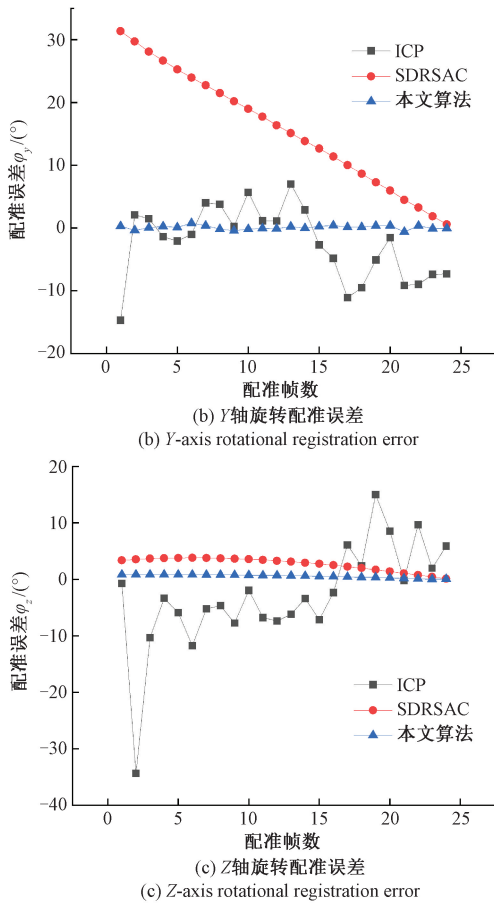


图 8 配准旋转误差

Fig. 8 Rotational registration error diagram

表 1 实验配准结果统计

Table 1 Experiment registration error statistics

误差类型	误差分量	ICP	SDRSAC	LGSA-HFFNet
平移误差/m	X 轴	0.098	-0.135	0.002 9
	Y 轴	-0.112	0.034	-0.000 2
	Z 轴	-0.163	0.003	0.000 3
	相对误差	0.253	0.276	0.005 0
旋转误差/(°)	X 轴	-1.684	0.982	0.145
	Y 轴	-1.379	15.736	0.051
	Z 轴	4.262	2.685	0.571
	相对误差	9.870	15.823	0.984
平均耗时/ms		371	4 585	73

由表 1 可知, LGSA-HFFNet 算法的平均相对平移误差低至 0.05 m, 相对旋转误差低至 0.984°, 在实际点云配准实验中效果远优于两种点云配准算法。

在配准实验过程中, 记录并统计各配准算法的耗时情况, 3 种算法配准耗时对比如图 9 所示。ICP、SDRSAC

和 LGSA-HFFNet 算法平均配准耗时为 371、458 5 和 73 ms, 本文算法较 SDRSAC、ICP 算法计算速度提升较大, 其中相较 ICP 算法提升约 80.32%, 较 SDRSAC 算法提升约 98.4%。

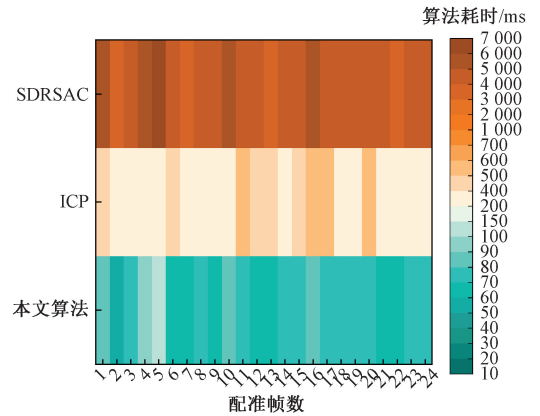


图 9 算法耗时对比

Fig. 9 Algorithm time comparison

3) 算法鲁棒性测试

在阀门旋拧工作中, 由于不同的阀门间环境可能有较大差异。为验证 LGSA-HFFNet 算法在不同背景工况下的鲁棒性, 搭建简单、复杂两种背景的点云配准实验场景并使用本文模型进行配准实验。其中简单实验场景通过在阀门后方放置平整的钢板, 使场景中的阀门后方背景因素被尽量剔除; 复杂场景使用本节第 2) 部分的常规实验场景, 其点云对比如图 10 所示。




图 10 实验场景点云对比

Fig. 10 Experimental scenario point cloud comparison

对简单和复杂两种场景的阀门重复本节第 2) 部分的实验内容并分别统计两种场景下的点云配准统计结果, 平均误差数据对比结果如表 2 所示。不同背景下的点云配准误差结果如图 11、12 所示。由于背景干扰的影响, 复杂背景实验的数据波动更明显, 但误差数据下降趋势与简单背景实验相符; 同一时刻两种背景实验的旋转误差计算结果差异均在 1° 以内, 配准结果具有较好的鲁棒性, 可以满足阀门点云配准的技术指标要求。

表2 不同实验场景配准误差统计

Table 2 Different experimental scenarios registration errors statistics

误差类型	误差分量	简单背景实验	复杂背景实验
平移误差/m	X轴	0.002 1	0.002 9
	Y轴	-0.000 1	-0.000 2
	Z轴	0.000 1	0.000 3
	相对误差	0.004 9	0.005 0
旋转误差/(°)	X轴	0.152	0.145
	Y轴	0.022	0.051
	Z轴	0.548	0.571
	相对误差	0.921	0.984

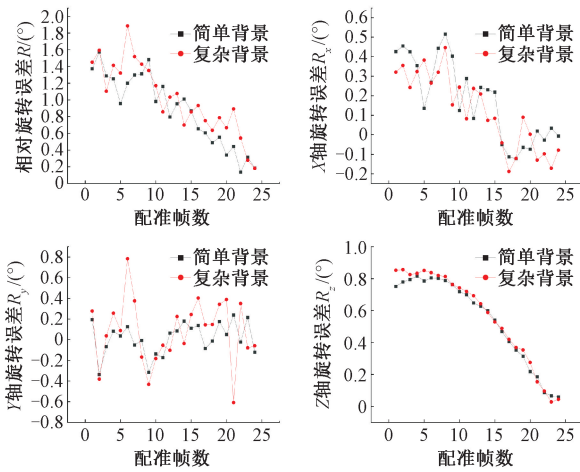


图11 不同实验场景点云旋转配准误差

Fig. 11 Rotational registration error of point clouds in different experimental scenarios

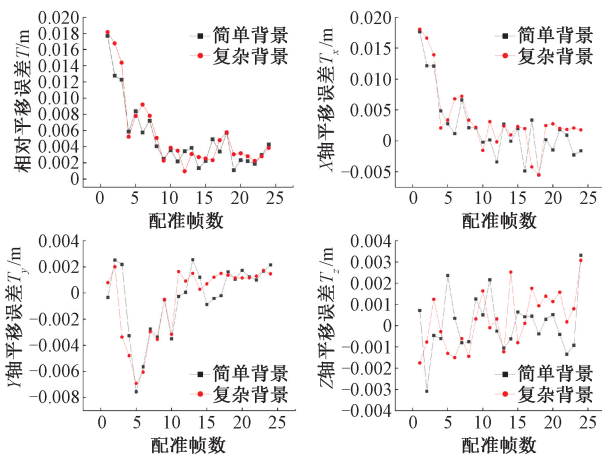


图12 不同实验场景点云平移配准误差

Fig. 12 Point cloud translation registration error in different experimental scenarios

以上实验结果显示, LGSA-HFFNet 算法在阀门旋拧工况下配准计算结果与实际情况基本相符, 配准精度受背景噪声及物体特征变化影响较小, 在运动过程中及各种背景下的配准误差方面具有较好的稳定性; 本模型可在机器人领域常用的 Jetson 等嵌入式边缘计算平台部署, 具备在工业机器人平台部署应用的价值。

2.2 对比实验

1) 实验设计

为了对比 LGSA-HFFNet 算法与现有有点云配准算法的配准效果, 本文在公开数据集和自制的阀门位姿估计数据集上设计了多组实验。公开数据集实验采用 ModelNet40 标准合成对象数据集, 该数据集包含使用 40 个不同类别的共计 12 311 个日常生活中常见的物体的三维 CAD 模型生成的对象点云, 其中训练集包含 9 843 个物体点云, 测试集包含 2 468 个物体点云。由于数据集包含的各类别样本不平衡, 且同时包含对称、非对称点云, 对模型的局部和全局特征提取能力训练效果较好。对于每个具体的模型点云, 使用最远点采样将其分布下采样到每个对象 1 024 个点, 并随机生成旋转和平移生成目标点云。

自制的阀门位姿估计数据集以闸阀为研究对象, 阀门外侧装有特制的阀门罩以便于视觉检测, 点云采集设备和响应设置与 2.1 节相同。在点云采集过程中, 拍摄相机在不同距离、位置、旋转角度下的阀门点云数据; 使用基坐标系固定的六轴协作机械臂记录双目相机的位姿变化以计算点云之间的位置关系, 得到配准标签。最终形成包含 242 个阀门点云-相机位姿和点云的阀门点云数据集。数据集中每个点云数据包含约 12 000 点, 且包含阀门的形态特征和设备采集噪声, 满足实用场景下点云采集的特点。

在模型测试实验过程中, 对各数据集的测试采用相对旋转误差 (relative rotation errors, RRE)、相对平移误差 (relative translation error, RTE)、旋转平移的均方根误差 (root mean square errors, RMSE) 和倒角距离来对模型配准性能进行全面评估。

2) ModelNet40 合成对象点云配准

为了评估 LGSA-HFFNet 网络在配准任务中的性能, 在 ModelNet40 数据集上将 LGSA-HFFNet 与 ICP^[5]、全局最优 ICP (globally optimal ICP, Go-ICP)^[24]、SDRSAC、PointNetLK^[25]、深度最近点 (deep closet point, DCP)^[26]、PREDATOR^[20]、REGTR^[21] 在无噪声和添加高斯噪声的条件下进行比较。无噪声的配准结果对比结果如表 3 所示。

由表 3 可知, LGSA-HFFNet 方法在 ModelNet40 无噪声数据集上具有较好的配准性能, 尤其在平移配准方面具有极高的准确度。对比经典点云配准算法和基于深

表 3 ModelNet40 数据集配准性能比较

Table 3 Comparison of registration performance on the ModelNet40 dataset

配准算法	RRE/(°)	RTE/m	旋转	平移
			RMSE/(°)	RMSE/m
ICP	25.051	0.251	33.682	0.289
Go-ICP	3.173	0.121	14.055	0.104
SDRSAC	2.782	0.011	3.922	0.012
PointNetLK	12.174	0.108	18.332	0.146
DCP	4.852	0.022	6.710	0.027
Predator	2.635	0.028	3.900	0.039
REGTR	1.542	0.018	2.627	0.023
LGSA-HFFNet	2.293	0.006	3.732	0.009

度学习的多阶段迭代配准算法, LGSA-HFFNet 在旋转、平移计算和配准结果稳定性上具有较大的提升幅度; 对比最新的深度学习端到端点云配准算法, LGSA-HFFNet 较 PREDATOR 在 RRE 方面提升 12.98%, 在 RTE 方面提升 78.57%; 对比 REGTR, 本方法虽然在 RRE 结果方面表现较差, 但在 RTE 计算结果方面仍有 66.67% 的提升幅度。

表 4 ModelNet40 噪声配准性能比较

Table 4 Comparative analysis of registration performance in ModelNet40 with noise

配准算法	低噪声点云				高噪声点云			
	RRE/(°)	RTE/m	旋转 RMSE/(°)	平移 RMSE/m	RRE/(°)	RTE/m	旋转 RMSE/(°)	平移 RMSE/m
ICP	25.563 1	0.248	35.075	0.248	26.124 0	0.246 0	36.821 0	0.296
Go-ICP	2.852 2	0.029	12.264	0.029	2.754 0	0.045 0	11.435 0	0.024
SDRSAC	2.921 2	0.012	3.027	0.013	3.017 0	0.013 0	3.645 0	0.014
PointNetLK	13.651 0	0.108	14.293	0.120	20.992 0	0.128 0	32.681 0	0.152
DCP	4.972 0	0.018	7.882	0.023	7.934 6	0.030 7	10.207 1	0.054
Predator	2.866 0	0.032	4.203	0.044	4.017 0	0.076 0	7.008 0	0.102
REGTR	1.894 0	0.019	2.009	0.024	2.394 0	0.021 0	2.417 0	0.026
LGSA-HFFNet	2.313 0	0.006	2.433	0.009	2.360 0	0.007 0	2.395 0	0.011

由实验结果可知, 添加标准差为 0.01 的高斯噪声时, 本文模型较无噪声情况 RRE 配准误差仅增大 0.9%, RTE 不变; 在标准差为 0.05 的高斯噪声下, 本文模型较无噪声情况 RRE 配准误差增大 2.9%, RTE 增大 1 mm, 并在配准准确率上反超了 REGTR 方法, 在 RRE 方面配准性能提升 1.42%, 在 RTE 方面配准性能提升 66.7%。

实验结果表明, LGSA-HFFNet 具有较好的鲁棒性, 能较好地应对噪声点云的干扰, 保持较好的配准稳定性, 体现出本文模型在应对点云噪声方面的优越性。

实验结果表明, 引入图注意力和空间注意力机制方法进行多尺度特征融合后, 本模型在配准性能方面具有一定的优势, 在旋转误差处于高水准的同时大幅提升了配准平移分量的准确度, 平移配准的性能大幅超过当前最新的方法。LGSA-HFFNet 模型在 ModelNet40 数据集下的局部点云配准结果可视化如图 13 所示。




图 13 ModelNet40 配准结果可视化

Fig. 13 ModelNet40 dataset registration results visualization

为了验证模型在噪声条件下的抗干扰鲁棒性, 在与无噪声实验相同的同等条件下, 向无噪声的 ModelNet40 数据集中分别加入均差为 0, 标准差为 0.01 和均差为 0, 标准差为 0.05 的高斯噪声, 形成低、高噪声数据, 进行点云配准实验。添加高斯噪声的配准对比结果如表 4 所示。

3) 真实场景阀门点云配准

真实场景阀门点云数据集是在现实车间中使用常见的双目深度视觉系统直接采集的阀门点云数据, 包含了深度相机系统采集数据时产生的系统误差、背景干扰和噪声信息。同时模板点云和源点云在采集时拍摄物体的角度不同, 会产生因视角原因造成的局部遮挡、物体形状畸变和轮廓特征变化, 这对配准模型应对噪声能力和鲁棒性是较大的挑战。真实场景阀门点云配准结果如表 5 所示。

表5 真实场景阀门点云配准结果

Table 5 Real valve point cloud registration results

配准算法	$RRE/(^{\circ})$	RTE/m	CD
ICP	28.112 3	0.352 1	0.418 5
SDRSAC	29.288 2	0.269 5	0.326 1
PointNetLK	10.618 3	0.203 7	0.167 5
Predator	6.435 0	0.060 9	0.002 2
REGTR	3.063 4	0.043 8	0.001 7
LGSA-HFFNet	2.175 7	0.036 0	0.000 9

在真实场景阀门点云数据集中, LGSA-HFFNet 在 RRE、RTE、CD 指标上较其他传统点云配准算法和深度学习方法都有更好的结果。相较于 Predator 方法, 本文方法在旋转配准精度方面提升 66.19%, 在平移配准误差方面提升 40.89%; 较 REGTR 方法提升幅度达到 28.98% 和 17.81%。由此表明, LGSA-HFFNet 应对复杂干扰的效果更好, 图-空间注意力机制对点云点间语义特征和物体空间特征提取效果较好, 对物体几何特征变化、轮廓特征的畸变等方面具有较强的鲁棒性。LGSA-HFFNet 模型在阀门位姿估计数据集下的点云配准结果可视化如图 14 所示。

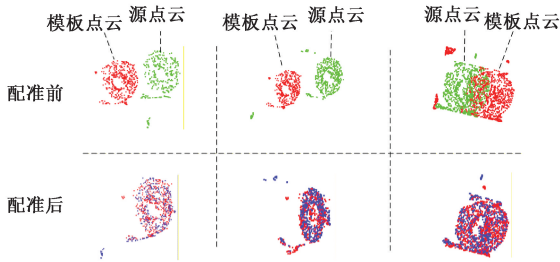


图 14 阀门配准结果可视化

Fig. 14 Valve dataset registration results visualization

2.3 消融实验

为了验证残差卷积特征提取模块和 LGSA 模块的有效性, 使用 LGSA-HFFNet 在 ModelNet40 数据集上的配准结果为基线设计消融实验进行对比研究, 分别对比不加入任何特征提取模块、仅加入残差卷积和 LGSA 特征提取模块其中之一和完整 LGSA-HFFNet 的配准结果。消融实验结果如表 6 所示。

基线 LGSA-HFFNet 在不加入残差卷积模块和 LGSA 模块、仅使用全连接层时, 模型无法正确识别点云的特征信息, 配准结果并未收敛。通过加入残差卷积特征提取模块, 模型成功收敛且配准相对旋转误差下降到接近 PointNetLK 的水平, 相对平移配准结果显著好于 PointNetLK。由于卷积网络仅能逐点提取全局特征, 无法提取点之间的语义信息和点坐标等空间特征, 故其作为

表6 ModelNet40 数据集消融实验结果

Table 6 Results of ModelNet40 dataset ablation experiment

Baseline	添加模块	$RRE/(^{\circ})$	RTE/m
LGSA-HFFNet	无特征提取器	159.799 7	0.061 7
LGSA-HFFNet	残差卷积	14.054 6	0.032 6
LGSA-HFFNet	LGSA	3.625 3	0.010 4
LGSA-HFFNet	残差卷积+LGSA	2.293 0	0.006 0

唯一特征提取器时仅能作为初步特征提取器。以上结果表明残差卷积模块在 LGSA-HFFNet 配准流程中全局特征提取方面的有效性。仅加入 LGSA 模块时, 对比仅使用残差卷积特征提取器的网络, 相对旋转、平移误差分别下降了 74.21% 和 68.1%。这表明 LGSA 模块对模型的配准精度起到关键作用, 其优势源于 LGSA 模块有效提取了点云的语义特征和空间特征。消融实验训练过程结果如图 15~17 所示。

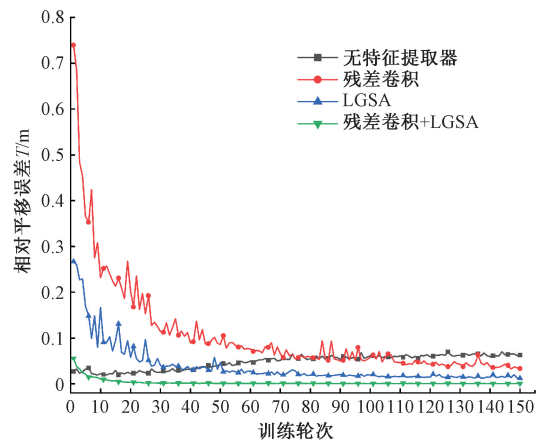


图 15 消融实验相对平移误差

Fig. 15 Ablation experiment relative translation error

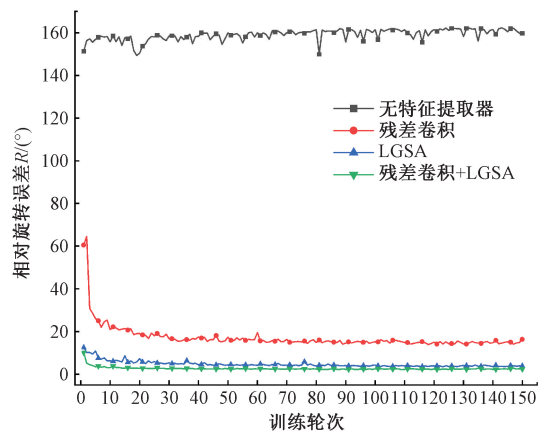


图 16 消融实验相对旋转误差

Fig. 16 Ablation experiment relative rotation error




图 17 消融实验训练损失

Fig. 17 Ablation experiment training loss

3 结 论

本研究提出了一种 LGSA-HFFNet 点云配准算法,以改善现有的点云配准算法中难以应对噪声干扰、计算量较大等问题。通过设计多尺度并行卷积特征提取层,强化模型特征提取并加速收敛。设计结合图-注意力与空间注意力机制并进行轻量化改进的 LGSA 模块,解决由点云信息特征的无序性造成的神经网络特征提取困难的问题,使模型能够有效提取点云局部特征。在阀门点云配准实验中, LGSA-HFFNet 算法平均相对平移误差低至 0.05 m, 相对旋转误差低至 0.984 m, 且在不同复杂度的背景下具有良好的鲁棒性, 在复杂背景实验下平移及旋转配准性能仅下降 2%、7.5%, 配准耗时相较于 ICP 算法降低 80.32%, 配准性能远优于 ICP 和 SDRSAC 等传统算法。在 ModelNet40 合成对象数据集和自制的阀门位姿估计数据集上的对比实验结果表明, LGSA-HFFNet 在 ModelNet40 实验中表现出良好的性能, 误差降低至 2.293° 和 0.006 m, 并在噪声干扰较大的真实场景阀门数据集实验中相较于其他模型表现出了更好的配准性能, 较现有方法性能至少提升 28.98% 和 17.81%。从而验证了 LGSA-HFFNet 算法的有效性, 为轻量化点云配准工作提供了新的方法。

参考文献

[1] YU W CH, SHU J P, YANG Z H, et al. Deep learning-based pipe segmentation and geometric reconstruction from poorly scanned point clouds using BIM-driven data alignment[J]. Automation in Construction, 2025, 173;

106071.
 [2] ZERMAS D, IZZAT I, PAPANIKOLOPOULOS N. Fast segmentation of 3D point clouds: A paradigm on LiDAR data for autonomous vehicle applications[C]. 2017 IEEE International Conference on Robotics and Automation, 2017: 5067-5073.
 [3] 樊一源, 王珂, 蒋敬尧, 等. 航天桁架结构 AR 装配中的配准技术[J/OL]. 中国测试, 1-12[2015-10-25]. FAN Y Y, WANG K, JIANG J Y, et al. Registration technology in AR-guided assembly of aerospace truss structures [J/OL]. China Measurement & Test, 1-12 [2015-10-25].
 [4] 刘天宝, 郭家慧, 宋伊彬, 等. 基于注意力机制增强的术前-术中非同源点云配准[J]. 中国激光, 2025, 52(3): 61-70.
 LIU T B, GUO J H, SONG Y B, et al. Preoperative and intraoperative cross-source point cloud registration based on attention mechanism enhancement [J]. Chinese Journal of Lasers, 2025, 52(3): 61-70.
 [5] BESL P J, MCKAY N D. A method for registration of 3-D shapes [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 1992, 14(2): 239-256.
 [6] 朱浩, 倪锐峰. 基于点云稀疏语义特征的智能网联汽车协同感知配准算法[J]. 仪器仪表学报, 2023, 44(10): 314-324.
 ZHU H, NI R F. A cooperative perception registration algorithm for intelligent and connected vehicles based on sparse semantic features[J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 314-324.
 [7] 罗其俊, 相承志, 张红颖. 基于骨架点云配准的泊位飞机快速位姿估计算法[J]. 电子测量与仪器学报, 2025, 39(1): 156-164.
 LUO Q J, XIANG CH ZH, ZHANG H Y. Fast pose estimation algorithm for berth aircraft based on skeleton point cloud registration [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(1): 156-164.
 [8] 程天宇, 顾菊平, 华亮, 等. 基于几何代数 SURF 的三维医学图像配准研究[J]. 仪器仪表学报, 2022, 43(9): 227-237.
 CHENG T Y, GU J P, HUA L, et al. Research on 3D medical image registration based on geometric algebra

- SURF [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 227-237.
- [9] RUSU R B, BLOWDOW N, BEETZ M. Fast point feature histograms (FPFH) for 3D registration [C]. 2009 IEEE International Conference on Robotics and Automation, 2009: 3212-3217.
- [10] LE H M, DO T T, HOANG T, et al. SDRSAC: Semidefinite-based randomized approach for robust point cloud registration without correspondences [C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 124-133.
- [11] 薛豪鹏, 田江晓, 李荣华, 等. 结合反射率先验信息的空间非合作目标点云分割配准方法 [J]. 宇航学报, 2025, 46(6): 1169-1178.
- XUE H P, TIAN J X, LI R H, et al. Point cloud segmentation registration method based on prior information of reflectance for space non-cooperative targets [J]. Journal of Astronautics, 2025, 46(6): 1169-1178.
- [12] MA T J, HAN G L, CHU Y ZH, et al. Sparse-to-dense point cloud registration based on rotation-invariant features [J]. Remote Sensing, 2024, 16(13): 2485.
- [13] 赵迪, 赵祖高, 程煜林, 等. 多特征关键点的自适应尺度融合特征点云配准 [J]. 电子测量技术, 2023, 46(10): 68-75.
- ZHAO D, ZHAO Z G, CHENG Y L, et al. Adaptive scale fusion feature point cloud registration for multi-feature key points [J]. Electronic Measurement Technology, 2023, 46(10): 68-75.
- [14] ZHANG ZH Y, SUN J D, DAI Y CH, et al. VRNet: Learning the rectified virtual corresponding points for 3D point cloud registration [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(8): 4997-5010.
- [15] 王艺诗, 徐田来, 张泽旭, 等. 基于点云深度学习的对称结构空间目标相对位姿测量 [J]. 宇航学报, 2023, 44(2): 294-302.
- WANG Y SH, XU T L, ZHANG Z X, et al. Relative pose measurement of space target with symmetrical structure based on point cloud deep learning [J]. Journal of Astronautics, 2023, 44(2): 294-302.
- [16] WANG H Y, 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.
- [17] LU F, CHEN G, LIU Y L, et al. HRegNet: A hierarchical network for efficient and accurate outdoor LiDAR point cloud registration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(10): 11884-11897.
- [18] ZHANG Y, SUN Y, WU L, et al. 3D point cloud semantic segmentation based PAConv and SE_variant [J]. Instrumentation, 2023, 10(4): 27-38.
- [19] GUO M H, CAI J X, LIU ZH N, et al. PCT: Point cloud Transformer [J]. Computational Visual Media, 2021, 7(2): 187-199.
- [20] HUANG SH 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, 2021: 4267-4276.
- [21] 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, 2022: 6677-6686.
- [22] YUAN Y ZH, WU Y, FAN X L, et al. EGST: Enhanced geometric structure Transformer for point cloud registration [J]. IEEE Transactions on Visualization and Computer Graphics, 2023, 30(9): 6222-6234.
- [23] WU T, PAN L, ZHANG J ZH, et al. Balanced chamfer distance as a comprehensive metric for point cloud completion [J]. Advances in Neural Information Processing Systems, 2021, 34: 29088-29100.
- [24] YANG J L, LI H D, CAMPBELL 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.
- [25] 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, 2019: 7163-7172.
- [26] WANG Y, SOLOMON J M. Deep closest point: Learning representations for point cloud registration [C]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 3523-3532.

作者简介



于智龙,2002 年于深圳大学获得学士学位,2007 年于哈尔滨理工大学获得硕士学位,2013 年于东北林业大学获得博士学位,现为哈尔滨理工大学副教授,主要研究方向为输配电系统的状态检测、人工智能、机器学习。

E-mail: zlyu@hrbust.edu.cn

Yu Zhilong received his B. Sc. degree from Shenzhen University in 2002, his M. Sc. degree from Harbin University of Science and Technology in 2007, and his Ph. D. degree from Northeast Forestry University in 2013. He is currently an associate professor at Harbin University of Science and Tech-

nology. His main research interests include condition monitoring of power transmission and distribution systems, artificial intelligence, and machine learning.



高东浦(通信作者),2022 年于江苏科技大学大学获得学士学位,现为哈尔滨理工大学硕士研究生,主要研究方向机器人应用技术。

E-mail: TsugDP1127@hotmail.com

Gao Dongpu (Corresponding author) received his B. Sc. degree from Jiangsu University of Science and Technol in 2022. He is currently a M. Sc. candidate at Harbin University of Science and Technology. His main research interest includes robotics application technology.