光电技术及应用

DOI：10.16818/j.issn1001－5868.2024022703

多层次架构下融合自注意力的三维激光点云语义分割算法

王德智[1]，周芸伊[2]，刘晗庆[2]，姜　海[1]，刘明慧[1]，刘晓宇[1]，冯子怡[2*]

（1. 国网辽宁省电力有限公司 丹东供电公司，辽宁 丹东 118000；2. 沈阳农业大学 信息与电气工程学院，沈阳 110000）

摘　要： 为解决三维激光点云局部特征提取不充分且缺少上下文特征信息融合的问题，提出了一种融合自注意力机制与多层次特征提取架构的 MAKNet 点云特征提取网络。该网络以三维激光点云数据作为输入，通过引入 SAA 模块提取点云特征，增加中心点特征值与其邻域点特征值之间关注权重值，抑制稀疏点特征低识别度问题，然后采用多尺度特征提取方式，进行多层点特征提取和融合，并进行点云特征跳跃链接，增加被提取点信息涵盖量。实验结果表明，在公开数据集 S3DIS 上总体准确率相比于 PointNet＋＋由 80.1％提升至 86.9％，在自建输电线路走廊数据集上总体准确率达到 96.4％，证明 MAKNet 网络在语义分割任务上具有良好的鲁棒性以及较强的泛化能力。

关键词： 三维激光点云；自注意力机制；多层次架构；特征提取；深度学习

中图分类号： TP391　**文章编号：** 1001－5868(2024)04－0647－07

3D Laser Point Cloud with Self-attention under Multi-level Architecture Semantic Segmentation Algorithms

WANG Dezhi[1], ZHOU Yunyi[2], LIU Hanqing[2], JIANG Hai[1], LIU Minghui[1], LIU Xiaoyu[1], FENG Ziyi[2]

(1. State Grid Liaoning Electric Power Company Limited, Dandong Power Supply Company, Dandong 118000, CHN; 2. Shenyang Agricultural University, College of Information and Electrical Engineering, Shenyang 110000, CHN)

Abstract: To address the insufficient local feature extraction and lack of context feature fusion in three-dimensional laser point clouds, we propose MAKNet, a point cloud feature extraction network that integrates a self-attention mechanism with a multi-level feature extraction architecture. Taking three-dimensional laser point cloud data as input, MAKNet employs an SAA module to extract point cloud features. It enhances sparse point recognition by introducing attention weights between the central point features and neighboring point features. Furthermore, MAKNet utilizes a multi-scale feature extraction approach to extract and fuse multi-layer point features, followed by point cloud feature skip connections to increase the coverage of the extracted point information. Experimental results demonstrated that on the S3DIS dataset, the overall accuracy of MAKNet was 86.9％, which was an improvement compared to that of PointNet＋＋ (80.1％). On a self-built dataset of transmission line corridors, MAKNet achieved an overall accuracy of 96.4％, showcasing its robustness and strong generalization capabilities in semantic segmentation tasks.

Key words: 3D laser point cloud; self-attention mechanisms; multi-level architecture; feature extraction; deep learning

收稿日期：2024－02－27.

基金项目：国网辽宁省电力有限公司管理科技项目资助(SGTYHT/23-JS-001).

* **通信作者：**冯子怡

0　引言

目前三维激光点云数据在许多领域被广泛应用，比如汽车自动驾驶、三维建模、机器人导航和电力巡检等。与排列在规则像素网格上的图像数据不同，三维激光点云是在一个三维坐标系统中描述物体三维坐标、深度、颜色等信息的点的集合，这使得三维激光点云具有不规则性和无序性的特点，因此使用深度学习方法高精度地提取三维激光点云数据的特征信息具有实际价值意义。

根据点云语义分割模型处理过程的不同，可以将目前的深度学习方法分为两大类：间接分割和直接分割[1]。间接分割方法是指将三维激光点云进行体素化，再对体素或二维图像数据进行卷积处理，但此方法具有结构分辨率低、数据处理复杂等缺点；直接分割方法是指直接对三维激光点云数据进行卷积等处理，但存在数据处理难度高、效率低的问题。2017 年 Qi 等[2-4]提出了 PointNet 网络，开创性地使用多层感知机直接处理三维点云数据。2019 年 Wang 等提出了 EdgeConv[5]，在保持点云排列不变性的同时生成描述点与其相邻点之间关系的边缘特征，缺乏对点云分布不规则性的处理。2020 年 Hu 等提出了 RandLA-Net[6]，使用局部空间编码(LocSE)单元来保留局部几何结构，利用 Attentive pooling 自动保留有用的局部特征，有效增加了每个点的感受野。2021 年 Zhao 等提出了 Point Transformer[7]，创造性地将 Transformer 引入到三维激光点云领域中，使用自注意力层来构建语义分割地自注意网络。2022 年 Lai 等提出了 Stratified Transformer[8]，以分层的方式对近点进行密集采样，对远点进行稀疏采样，使模型能够以较低的计算成本扩大有效接受场，并捕获远程上下文信息。2023 年曲彦霖等[9]在 PointNet＋＋中引入通道及空间注意力模块，提升不同特征学习能力，提高分割精度。现有的方法通常没有充分考虑到每个点在分割任务中的重要性差异，这可能会降低物体识别的准确性。

基于此，本文提出一种融合自注意力机制与多层次架构的三维激光点云特征提取方法 MAKNet。使用多层次特征提取架构，采集多层点特征并相加结合，抑制点云密度不均匀导致的稀疏点特征无法识别的问题；引入 SA 模块结合自注意力机制，增强点与点之间相关性，在获取尽可能多的全局信息的同时增强点云特征的局部一致性。

1　三维激光点云特征提取网络 MAKNet

本研究的三维激光点云特征提取网络 MAKNet 总体架构如图 1 所示。现实场景中由激光雷达方法产生的点云数据通常十分庞大，且点云分布存在稀疏性和不规则性等问题，导致模型运算极其复杂，所以引入了 SA 特征提取模块，并融合自注意力机制，构建 SAA 模块(Set Abstraction Attention)，精细提取点云语义结构信息；采用多层次特征提取架构对多层点特征进行提取与聚合，扩大每点感受野，充分覆盖不同密度点云特征结构。如图 1 所示，N 表示输入点云个数；F 表示每个点附加特征数；C 表示输入点云数据的三维坐标特征；K 表示分割类别数。编码器部分采用 SAA 模块进行点云特征提取，通过最远点采样(FPS)采集点云全局特征，结合基于自注意力机制的 K 近邻采样进行局部特征提取，然后再使用最大池化函数(Max Pooling)实现区域特征提取与融合，考虑到点云稀疏性的问题，采用多层次 SAA 模块特征提取的方式，进行多层点特征提取和融合，然后再进行特征拼接；解码器部分则是采用基于距离插值的分层特征传播(Feature Propagation)策略进行逐步上采样来传播特征信息，以输出点云语义分割结果。

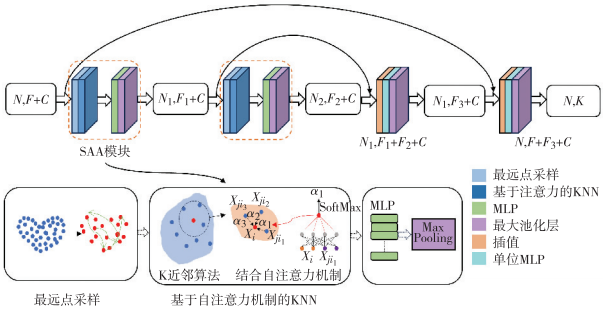


图 1　MAKNet 总体架构

1.1　三维激光点云特征提取 SAA 模块

SAA 模块中为了获得点云数据的全局特征，选择使用最远点采样算法。从所有点云数据 N 中随机选择一个点云作为初始选择采样点，计算其他未选择采样点中的每个点云到初始选择采样点之间的距离，将距离值最大的点云纳入选择采样点集合中，不断更新距离值，一直循环迭代最远点采样算法，直到获得目标数量 N_1 个采样点。最远点采样算法在

具有相同点云数量的情况下，可以更好覆盖整个点集，高质量地保留有用点云信息，以及保证点云数据采集的均匀性。

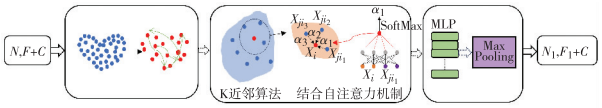
原始 SA 模块的局部特征信息采用一般 K 近邻算法来提取，其提取过程表达式为：

$$X_i = \frac{1}{K}\sum_{m=1}^{K} X_{ji_m} \tag{1}$$

式中，$X_i = \{x_1, x_2, \cdots, x_{N_1}\}$ 为中心点，$X_{ji_m} = X_{ji_1}, \cdots, X_{ji_k}$ 为 K 个邻域点。

以最远点采样算法从所有点云数据 N 中采集到的 N_1 个点作为一般 K 近邻算法的输入，预设 K 近邻邻域的搜索半径 R，以 N_1 个点作为中心点，在半径 R 的球体邻域范围内进行搜索，每个邻域内按距离中心点从近到远的顺序搜索 K 个邻域点，由此可得到 N_1 个子区域，每个子区域具有 K 个点，进而实现局部特征的提取。虽然此方法可以达到提取局部特征、弥补 PointNet 网络泛化能力差的效果，但是如果某个中心点靠近分割结构边缘，与其邻域内的点可能会出现不在同一个分割类别里的情况。面对这种问题，一般 K 近邻算法无法正确识别真实信息，导致分割类别出现误差问题。

考虑到上述问题，在 SA 模块的基础上，引入了自注意力机制[10]，将一般 K 近邻算法与自注意力机制相结合，构建 SAA 模块，改进后的 SAA 模块更加关注点与点之间的强相关性，SAA 模块架构如图 2 所示。



最远点采样 基于自注意力机制的KNN

N：输入点云个数；F：每个点附加特征数；C：点云三维坐标

图 2 SAA 模块架构

SAA 模块选择不直接聚合中心点特征，而是依靠自注意力机制，计算每个中心点特征值与其邻域点特征值之间关注权重值，再通过聚合器计算 K 个邻域点关注权重值的加权平均值，最后将加权平均值与初始中心点特征值相结合构建成一个新的中心点特征进行输出，操作过程可以表示为：

$$X'_i = X_i + \frac{1}{K}\sum_{m=1}^{K} \alpha_m X_{ji_m} \tag{2}$$

式中，α_m 表示每个中心点特征值与其邻域点特征值之间关注权重值。

$$\alpha'_m = f(X_i, X_{ji_m}) \tag{3}$$

$$\alpha_m = \mathrm{softmax}(\alpha'_m) \tag{4}$$

式中，f 表示一个多层感知机（MLP）训练层，α_m 为使用 softmax 函数对中心点与邻域点之间关联度值进行归一化处理的权重值[13]。

针对点云数据的非结构性，即点云的位置顺序不影响对象物体的性质，选择使用对称函数——最大池化函数作用于 N_1 个子区域上，在每个子区域上选取点云特征值的最大值，实现点云特征的提取与融合[14]。

1.2 多层次点云特征提取架构

在点云数据采集中，常常会发生某些区域的数据点非常密集，而其他区域的数据点很稀疏的情况。这种不均匀分布可能是由于不同地方的景物复杂度不同，或者是采集设备的特性所导致的[15]。通常情况下，模型更容易学习和理解密集区域的细节，而对稀疏区域的信息感知能力较弱。因此，如果使用常规的方式来训练模型，可能会错过一些很重要的信息，无法捕捉到整体的局部结构，进而导致模型在理解和处理点云数据时出现问题[16-17]。因此，本研究需要采用一些特殊方法，以帮助模型更好地处理密度不均匀的点云数据。

针对上述问题，考虑到点云特征提取的全面性及精确度，提出了一种多层次点云特征提取架构，如图 3 所示。采用连续两次在不同区域尺度进行 SAA 模块特征提取的方式，进行多层点特征提取和融合，再进行点云特征的拼接组合，以得到更精细的点云特征细节，扩大每个点云感受野，增加被提取点的信息涵盖量，使覆盖特征区域更广泛。

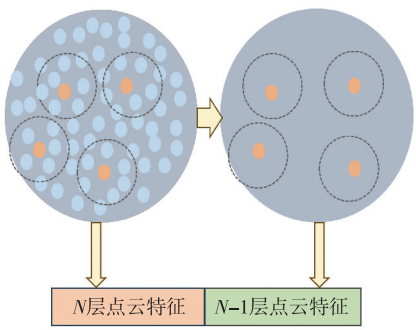


图 3 多层次点云特征提取架构

在多层次点云特征提取架构中，本研究可以根据点云数据的分布情况，以一种自适应的方式来聚合特征信息，下文将直观地说明这个概念。

在图 3 中，本研究使用 SAA 模块来从第 N 层提取特征。该模块生成了两种不同的特征向量，左

侧的向量代表了每个子区域的特征，而右侧是通过 SAA 模块直接处理局部区域中的所有原始点云而获得的特征向量。在某一级区域的特征表示是这两个向量的串联结果。

这意味着本研究从两个不同的角度来考虑特征提取：首先，考虑每个子区域的特征，然后将整个局部区域的特征与之结合。这有助于捕捉点云数据的多层次信息，并在不同分布情况下自适应地聚合特征，从而提高模型性能。当处理稀疏点云数据时，有些局部区域可能包含较少的点，在计算这些向量时容易受到采样不足问题的影响，因此第一个特征向量的可靠性可能较低。在这种情况下，需要为这些向量分配较低的权重，以减小对最终结果的影响。与之相反，当处理密集的点云数据时，第一个特征向量可能提供更多详细的信息，因为其具有在更高分辨率下检测的能力。此时，需要为这些向量分配较高的权重，以确保其对结果的贡献更大。权重的分配可以根据数据的密度情况来自适应调整，以更好地反映点云中不同区域的特征重要性。

2　点云分割模型训练

2.1　数据集的制作与训练

采用的服务器系统是 Ubuntu 22.04，工作站搭配处理器是 AMD Ryzen Threadripper PRO 3975WX 32-Cores 3.50 GHz，配备显卡 NVIDIA RTX A4000，显存 16 GB，使用软件平台为 python3.8.16，搭配 pytorch2.0.1，cuda11.7 构建网络环境。

选择三维点云语义分割数据集 S3DIS[11] 及自建的输电线路走廊数据集上进行训练与测试，验证本网络的性能。S3DIS 数据集共包含 3 座不同的建筑的 6 个区域，217 个室内房间场景，13 种语义元素，分别包括：窗、地板、墙壁、椅子、门、天花板、沙发、梁、板、柱、柜、桌子、混杂元素（其他），共计约有 6.9 亿个带有三维坐标、RGB 颜色信息和语义标签的三维点云数据。

自建输电线路走廊数据集使用大疆经纬 M300 RTK 无人机搭载禅思 L_1 激光雷达扫描镜头，航行高度为 100 m，航行速度为 8 m/s，采样频率为 124 kHz，回波模式为双回波，扫描模式为非重复扫描，真彩上色模式为打开，RTK 选择端口使用 WSG 84，进行数据采集。首先使用统计滤波、布料模拟滤波对数据进行去噪、地面点去除处理。然后使用软件 cloudcompare 进行人工标注非地面点，构建一套输电线路走廊点云数据集，共包含 6 个区域，50 个输电线路走廊场景，5 种语义元素，分别包括：输电线路、植被、杆塔、建筑物以及混杂元素（其他），如图 4 所示。共计约有 5.6 亿个带有三维坐标、RGB 颜色信息和语义标签的三维点云数据。

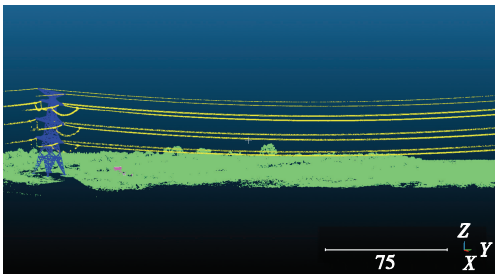


图 4　输电线路走廊数据集

上述数据集均默认使用区域 1-4 和区域 6 作为训练集，区域 5 作为测试集，实验设置 epoch 为 32，初始学习率为 0.001，并根据训练情况自适应调整学习率，step_size 为 10，batch_size 为 8，momentum 设置为 0.01，使用 Adam 优化器。

2.2　算法性能评估

采用总体准确率（OA）、交并比（IoU），平均交并比（mIoU）作为评价指标。总体准确率用以评价分割类别正确的样本数量占所有样本数量的比例，交并比用以评价分割网络对某一类别的预测结果和真实值的交集与并集之比，平均交并比则是表示对每一类别的交并比之和与分割总类别数的比值。具体表达式如下：

$$OA=\frac{TP+TN}{TP+TN+FP+FN} \tag{5}$$

$$IoU=\frac{TP}{FP+TP+FN} \tag{6}$$

$$mIoU=\frac{\sum(\text{each class}IoU)}{K} \tag{7}$$

式中，TP，TN，FP，FN 分别为真正值、真负值、假正值、假负值，K 为分割类别数。

3　模型测试结果与分析

3.1　公开数据集语义分割结果分析

为了直观展现所提网络 MAKNet 在点云语义分割任务上的效果，首先在公开数据集 S3DIS 上进行实验测试。

由图 5 可以看出，在较为复杂的室内环境下，如

办公室、会议室以及卧室等，不同种类物体的分割边界更加明显，这样的场景分割结果从视觉上看更为清晰明了。然而，在类似走廊等狭长的室内环境中，物体分割可能出现明显的错误，对于墙壁及墙壁上的挂件等物体无法达到理想的分割结果，而且物体内部可能会出现一些额外的干扰点。

为了进一步对本文所提网络的实验效果进行定量评价，将其实验结果与现有模型 PointNet[2]，PointNet＋＋[3]，Point Transformer[7]，ASIS[12] 等主流分割网络进行对比，性能比较结果如表 1 所示。

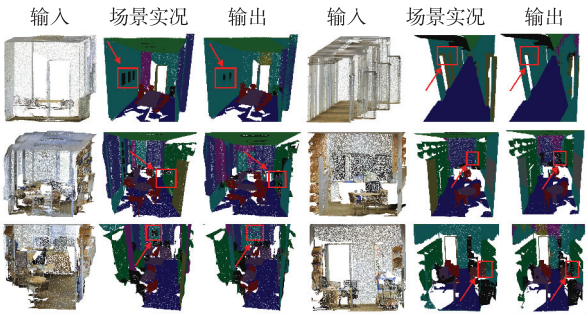


图 5 S3DIS 数据集上语义分割可视化结果

表 1 S3DIS 数据集上的语义分割评价指标结果对比

模型	*OA*/%	*mIoU*/%
PointNet[2]	75.6	41.1
PointNet＋＋[3]	80.1	54.5
PT[7]	86.1	61.2
ASIS[12]	84.3	58.5
MAKNet(本文)	86.9	61.3

由表 1 可以得知，本文所提网络 MAKNet 在语义分割任务中总体准确率比 PointNet＋＋网络提高 6.8%。相较于其他点云语义分割模型，所提网络取得语义分割任务的最优精确度。MAKNet 网络在 S3DIS 数据集上的评价指标有明显提升，结合自注意力机制的 SAA 模块在语义分割任务上可以提高点云特征提取精确度，具有很高的稳定性和抗干扰能力，能有效提升分割精度，可以应对实际场景中复杂分类情况。

3.2 自建数据集语义分割结果分析

将所提 MAKNet 网络在自己建立的输电线路走廊数据集上进行语义分割实验，验证 MAKNet 网络的泛化能力，结果如表 2 所示。由于输电线路走廊点云场景含有大量地面点数据，不同类别点云数据数量差异过大，对于分割精度可能会造成较大影响，所以分别对输电线路走廊数据集中的带有地面点数据和不带有地面点数据进行实验。

由表 2 可知，在输电线路走廊数据集上，带有地面点数据的分割精度远低于不带有地面点数据的，这是由于点云数据数量差异过大会干扰点云特征的正确提取，对网络训练精度产生较大影响。对于不带有地面点数据进行实验，总体准确率可以达到 96.4%，平均交并比为 67.7%，实验可视化结果如图 6 所示，可以得知，所提网络对于植被、输电线路及建筑物分割效果良好。实验结果表明所提网络 MAKNet 在实际应用中可以取得较高的分割精度，具有较好的泛化能力。

表 2 输电线路走廊数据集语义分割结果

模型	*OA*/%	*mIoU*/%
MAKNet-with ground	60.2	34.6
MAKNet-without ground	96.4	67.7

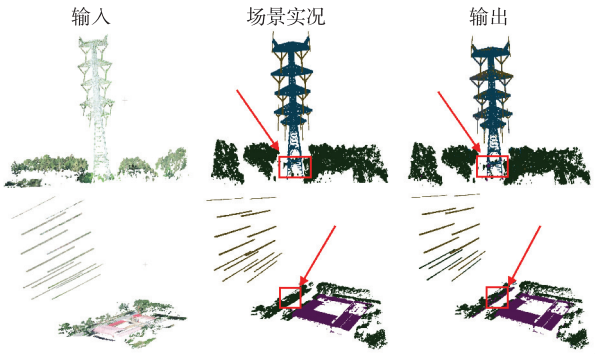


图 6 输电线路走廊数据集语义分割可视化结果

3.3 消融实验

为了验证结合自注意力机制的 SAA 模块以及多层次特征提取架构的有效性，使用 S3DIS 公共数据集对分割模型进行消融实验，结果如表 3 所示。MNet 指既不加入自注意力机制也不引入多层次特征提取架构的基础模型；MANet 指在基础模型的基础上引入自注意力机制；MSNet 指在基础模型的基础上引入空间注意力机制；MKNet 指在基础模型的基础上引入多层次提取架构。

表 3 消融实验语义分割结果

模型	*OA*/%	*mIoU*/%
MNet	78.3	48.6
MANet	85.4	58.7
MSNet	82.7	56.5
MKNet	80.3	55.7
MAKNet(本文)	86.9	61.3

由表 3 可以得出，仅考虑自注意力机制对网络精度的影响，MANet 网络在总体准确率和平均交并比上可以达到 85.4%和 58.7%，高于 MSNet 网络

2%左右，自注意力机制相较于空间注意力机制具有更好的精度表现。仅考虑多层次提取架构对网络精度的影响，MKNet 网络在总体准确率和平均交并比上可以达到 80.3%和 55.7%。

在网络中加入自注意力机制可以提高点云特征提取准确度，对于点云语义分割精度有明显提升，总体准确率可以提升 7.1%，平均交并比提升 10.1%，再引入多层次特征提取架构后两个评价指标约提升了 1.5%～2.6%，证明了结合自注意力机制的 SAA 模块以及多层次特征提取架构的有效性。

4　结束语

为了解决点云数据处理中的一些问题，提出一种名为 MAKNet 的点云特征提取网络。该网络以编码器-解码器结构为基础，旨在处理点云数据中的局部特征提取问题，以及合并局部特征和上下文特征。具体来说，本研究引入了新的点云特征提取模块 SAA，其结合了自注意力机制和 K 近邻采样算法。这意味着本研究可以更好地处理局部特征，通过强调中心点与周围邻域点之间的关系，来提取更有代表性的特征类别信息。此外，采用了多层次特征架构，以扩大网络对上下文特征的感知范围。这有助于抑制稀疏点云数据的特征分散问题，并提高网络的泛化能力。在 S3DIS 数据集和输电线路走廊数据集上进行了语义分割实验，发现 MAKNet 网络能够有效地提取和利用点云数据的局部特征，并在多个尺度上提取点云的语义特征。这提高了点云语义分割的准确性和泛化性。值得注意的是，通过在网络中引入自注意力机制，增加了网络的计算复杂性。

参考文献：

[1] 刘新锐，滕　达，卢思超，等. 基于深度学习的点云语义分割研究综述[J]. 北京石油化工学院学报，2023，31(2)：54-61.
Liu Xinrui，Teng Da，Lu Sichao，et al. A survey of semantic segmentation of point cloud based on deep learning[J]. J. of Beijing Institute of Petrochemical Technol.，2023，31(2)：54-61.

[2] Qi C R，Su H，Mo K，et al. PointNet：Deep learning on point sets for 3D classification and segmentation[C]// Proc. of IEEE Conf. on Computer Vision and Pattern Recognition，2017：652-660.

[3] Qi C R，Li Y，Hao S，et al. PointNet＋＋：Deep hierarchical feature learning on point sets in a metric space[C]// Proc. of Conf. and Workshop on Neural Information Processing Systems(NIPS)，2017：5105-5114.

[4] Jiang M，Wu Y，Zhao T，et al. Pointsift：A siftlike network module for 3d pointcloud semantic segmentation[J]. ArXiv preprint，2018，1807：00652.

[5] Wang Y，Sun Y，Liu Z，et al. Dynamic graph CNN for learning on point clouds[J]. ArXiv preprint，2019，1801：07829.

[6] Hu Q，Yang B，Xie L，et al. RandLA-Net：Efficient semantic segmentation of large-scale point clouds[C]// Proc. of IEEE Conf. on Computer Vision and Pattern Recognition，2020：11108-11117.

[7] Zhao H，Jiang L，Jia J，et al. Point transformer[C]// Computer Vision and Pattern Recognition，2021：389-409.

[8] Lai X，Liu J，Jiang L，et al. Stratified transformer for 3D point cloud segmentation[C]// Proc. of IEEE Conf. on Computer Vision and Pattern Recognition，2022：8490-8499.

[9] 曲彦霖，王　悦，张　倩，等. 一种基于空间特征注意力机制的点云分析方法[J]. 激光与光电子学进展，2023，60(24)：2415003.
Qu Yanlin，Wang Yue，Zhang Qian，et al. Point cloud analysis method based on spatial feature attention mechanism[J]. Laser Optoelectronics Progress，2023，60(24)：2415003.

[10] Liang Z，Yang M，Li H，et al. 3D instance embedding learning with a structure-aware loss function for point cloud segmentation[J]. IEEE Rob. Autom. Lett.，2020，5(3)：4915-4922.

[11] Armeni I，Sener O，Zamir A，et al. 3D semantic parsing of largescale indoor spaces[C]// IEEE Conf. on Computer Vision and Pattern Recognition，2016：1534-1543.

[12] Wang X L，Liu S，Shen X Y，et al. Associatively segmenting instances and semantics in point clouds[C]// IEEE Conf. on Computer Vision and Pattern Recognition，2019：4096-4105.

[13] Liu W Y，Wen Y，Yu Z，et al. Large-margin softmax loss for convolutional neural networks[C]// Inter. Conf. on Machine Learning，2016：7-18.

[14] Xu M，Ding R，Zhao H，et al. Paconv：Position adaptive convolution with dynamic kernel assembling on point clouds[C]// Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition，2021：3173-3182.

[15] 王秋红，徐　杨，蒋诗怡，等. 级联边缘卷积与注意力机制的点云分类分割研究[J]. 计算机工程与应用，2023，60(12)：170-180.
Wang Qiuhong，Xu Yang，Jiang Shiyi，et al. Research on point cloud classification and segmentation of cascaded edge convolution and attention mechanism[J]. Computer Engineering and Applications，2023，60(12)：170-180.

[16] 佟国峰，刘永旭，彭　浩，等. 基于编码特征学习的三维激光点云语义分割网络[J]. 模式识别与人工智能，2023，36(4)：313-326.
Tong Guofeng，Liu Yongxu，Peng Hao，et al. 3D point cloud

semantic segmentation network based on coding feature learning [J]. Pattern Recognition and Artificial Intelligence, 2023, 36 (4): 313-326.

[17] 汪争锐，郭 艿，冯立辉. 基于局部空间信息表征融合和信息深度残差提取的点云分类分割算法[J]. 自动化与仪器仪表，2023，(5)：1-5，9.

Wang Zhengrui, Guo Peng, Feng Lihui. Point cloud classification and segmentation algorithm based on local information representing and fusing and information deep residual extractor[J]. Automation and Instrumentation, 2023, (5): 1-5, 9.

作者简介：

王德智(1987—)，男，工程师，主要研究方向为输配电；

冯子怡(1991—)，女，博士，讲师，研究方向为卫星遥感。