

基于 B-PointNet++ 的地下电缆工井点云语义分割模型^{*}

王丽欢 任雨 刘建 李军阔 宫世杰

(国网河北省电力有限公司经济技术研究院 石家庄 050000)

摘要:地下电缆工井具有规模大、范围广、空间分布复杂等特点,为提高地下电缆工井筛查效率,保障地下电缆安全可靠运行,提出了一种基于宽度学习系统(broad learning system, BLS)和编解码器(encoder-decoder)的 PointNet++ 模型,简称 B-PointNet++,并将其应用于地下电缆工井点云语义分割。首先,为提高 PointNet++ 对于大规模点云数据的特征学习能力以及学习效率,提出了基于 Encoder-Decoder 的 PointNet++ 学习框架,并在 PointNet 核心网络中引入 BLS 算法替代原有多层感知器(multilayer perceptron, MLP),充分发挥 BLS 随机化学习效率;其次,采集了雄安新区地下电缆工井点云数据并加入真实语义标签制作模型训练需要的数据集;最后,与 PointNet 和 PointNet++ 等现有方法相比,B-PointNet++ 具有更高的精确度、召回率、交并比和 F1 分数,有利于地下电缆工井场景的多目标分割,有较大的应用潜力。

关键词:电缆工井;点云语义分割;PointNet++;宽度学习系统;编解码器

中图分类号: TN249 **文献标识码:** A **国家标准学科分类代码:** 520.6

B-PointNet++ model for semantic segmentation of underground cable shaft point cloud

Wang Lihuan Ren Yu Liu Jian Li Junkuo Gong Shijie

(Economic Research Institute, State Grid Hebei, Shijiazhuang 050000, China)

Abstract: Underground cable shaft has the characteristics of large scale, wide range and complex spatial distribution. In order to improve the efficiency of underground cable shaft screening and ensure the safe and reliable operation of underground cable, this paper proposes a novel PointNet++ model based on broad learning system (BLS) and encoder-decoder for cable shaft point cloud semantic segmentation, termed as B-PointNet++. Firstly, in order to improve the feature learning ability and efficiency of PointNet++ for solving large-scale point cloud data, a PointNet++ Encoder-Decoder model is proposed. Meanwhile, BLS algorithm is introduced into the PointNet to replace the multilayer perceptron (MLP) and give full play to the efficiency of BLS randomization learning. Secondly, the point cloud data of underground cable shaft in Xiong'an were collected and the data set required by real semantic label was added to the model training. Finally, compared with the existing methods, the results show that B-pointnet++ has higher precision, recall, intersection over union and F1 values compared with PointNet and Pointnet++, it is beneficial to multi-objective segmentation of underground cable shaft scenes, and has great application potential.

Keywords: cable shaft; point cloud semantic segmentation; PointNet++; broad learning system; encoder-decoder

0 引言

激光采集设备的普及,为三维激光点云数据获取以及大规模三维场景识别分析提供了便利^[1-2]。语义分割作为

三维场景分析中的核心步骤,已成为导航定位、计算机视觉、智能机器人、测绘地理信息等多领域的重要研究重点^[3]。

传统的三维场景点云分割方法主要包括基于边界的

收稿日期:2022-11-03

^{*} 基金项目:国网河北省电力有限公司科技项目(5204JY20000)资助

分割方法,基于区域增长的分割方法,基于模型拟合的分割方法和基于聚类的分割方法^[4]。但是,传统的点云分割算法在处理地下电缆海量数据时,存在特征提取繁杂、效率低下、泛化能力低等问题,无法满足大规模地下电缆工井场景分割需求^[5-6]。

深度学习技术的普及与成功,为突破三维点云场景分割瓶颈带来了新的机遇和挑战^[7-8]。基于深度学习的点云语义分割方法又可以根据处理原始三维场景点云的方式分为间接语义分割和直接语义分割^[9]。间接语义分割方法不能将原始点云数据直接输入算法中进行模型训练及特征提取,常见的处理方法为将原始点云进行栅格体素化或多视角二维图像化,存在网络模型计算量大,对计算机性能要求高、网络泛化能力较差^[10-11]。

直接语义分割方法能够实现直接输入点云数据进行三维场景的语义分割,无需进行其他的转换操作,提高了点云数据的利用效率,且保留了点云数据的空间三维信息,该类型方法以 PointNet 为代表,但是 PointNet 不能充分利用空间信息,无法获得局部信息^[12]。PointNet++ 作为 PointNet 的深层版本,具有多层次结构,提高了局部特征的提取能力^[13]。

但是,当面对数量众多且大小不一的复杂物体时,可能需要对数据进行预处理,其中的挑战是充分提取点特征和局部特征,提高模型性能,管理大规模的点云数据,并有效地提取数据信息成为人们关注的重点。此外,PointNet 采用的全连接神经网络存在训练效率低,计算复杂度高等问题,严重影响点云分割效率。

因此,为实现地下电缆工井点云场景的语义分割,本文提出了一种 B-PointNet++ 深度学习模型,利用编码器-解码器(encoder-decoder)框架^[14],提高大规模点云数据特征学习能力,同时,利用宽度学习系统(broad learning system, BLS)修正 PointNet 网络^[15-16],以确保模型获得可接受度高的分割结果的同时,提高模型分割效率,从而提高地下电缆工井筛查效率,保障地下电缆安全运行。

1 B-PointNet++ 编解码网络

1.1 相关工作

1) PointNet

PointNet 由 Qi 等^[13]提出,是第一个能够直接处理点云数据的深度学习模型,其能够通过多层感知器(multi-layer perceptron, MLP)学习每个点的特征表示并实现所有点特征的聚合。其网络结构如图 1 所示,给定网络输入和输出,其训练过程可以分为 3 个主要阶段。

(1)对各点的空间坐标进行输入变换,输入变换模块采用 T-Net 网络预测点的仿射变换矩阵,并与输入矩阵相乘,获取输入点的正则空间。

(2)利用 MLP 对阶段(1)中对齐的点进行特征学习,并使用特征变换模块对学习到的点特征进行对齐,得到对齐的特征矩阵。

(3)将阶段(2)中得到的特征矩阵进行高维映射,并使用最大池化层得到全局特征。将全局特征和对齐的特征输入至 MLP,获得最后输出。

2) PointNet++

为了有效提取点云数据局部特征,PointNet++ 网络^[17]在 PointNet^[18]的基础上引入了层次特征学习框架,是 PointNet 的深度学习版本,其网络结构如图 2 所示。

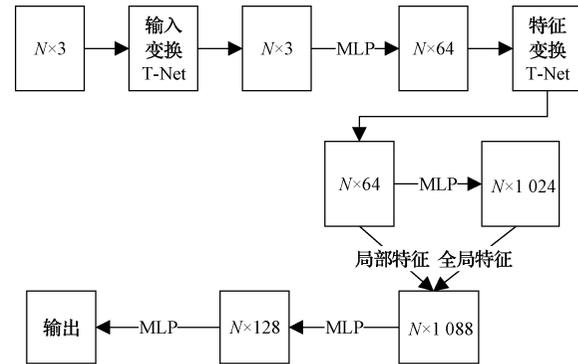


图 1 PointNet 网络模型

PointNet++ 的基本思想是划分数据集,提取局部特征,然后连续抽象,提取高维特征^[19]。PointNet++ 本质上是 PointNet 的分层版本。每一层有 3 个子阶段,分别为采样(sampling)、分组(grouping)和 PointNet。在采样阶段,选择质心,在分组阶段,质心周围给定半径内的相邻点被创建成多个子点云。然后将子点云赋给一个点网络,得到这些子点云的高维表示。除此之外,PointNet++ 采用 U-Net 架构,采用跳跃连接。PointNet 组件包含一组卷积、规范化和修正线性单元(ReLU)、最大池化层。

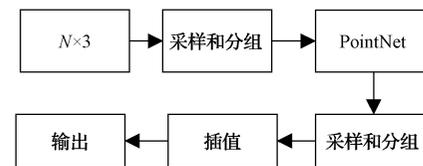


图 2 PointNet++ 网络模型

1.2 本文提出模型

1) B-PointNet

B-PointNet 网络模型如图 3 所示。由图 3 可得,PointNet 是 PointNet++ 的核心组件,原始的 PointNet 通过 MLP 学习每个点的特征表示并实现所有点特征的聚合^[13]。BLS 是一种新型随机化神经网络模型^[14-15],能够利用随机化算法分配网络参数并生成宽度模型,与基于反向传播的 MLP 网络相比,能够提高网络收敛速率,因此,为提高 PointNet 学习效率,本文首先提出一种 B-PointNet 模型,使用 BLS 替代原有的 MLP 网络,其中 BLS 算法流程主要包括如下 3 个步骤^[14-15]。

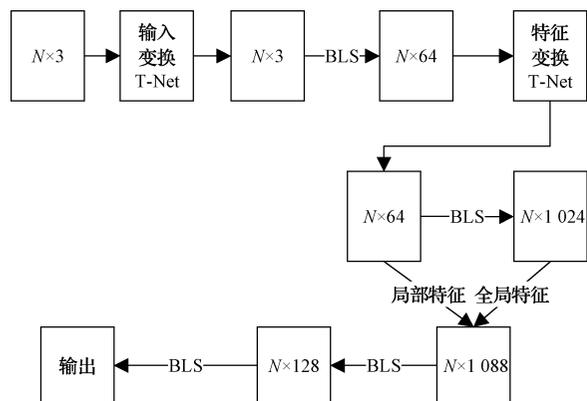


图3 B-PointNet 网络模型

(1) 特征映射

由于 BLS 无需将神经网络扩展为深度模型,在 B-PointNet 中,其首先利用式(1)将输入数据 X 进行 m 次特征映射,每次映射为 p 维特征,并根据式(2)对所有映射节点进行特征组合。

$$F_j = \phi(XW_{e_j} + b_{e_j}) \quad j = 1, 2, \dots, m \quad (1)$$

$$F^m = [F_1, F_2, \dots, F_m] \quad (2)$$

式中: ϕ 为特征映射过程所采取的激活函数; W_{e_j} 和 b_{e_j} 分别代表映射节点的随机权重和偏置。

(2) 特征增强

当映射过程结束后, BLS 将通过式(3)将 F^m 进行 n

次特征增强,每次特征增强生成 q 个网络节点,并根据式(4)对所有增强节点进行特征组合。

$$H_k = \phi(F^m W_{hk} + b_{hk}) \quad k = 2, 3, \dots, n \quad (3)$$

$$H^n = [H_1, H_2, \dots, H_n] \quad (4)$$

式中: ϕ 代表特征增强节段的激活函数,可与映射阶段相同; W_{hk} 和 b_{hk} 分别代表增强节点的随机权重和偏置。

(3) 计算 BLS 输出

在计算输出前,首先利用式(5)对式(2)映射特征、式(4)增强特征进行组合,根据式(6)岭回归计算方法计算 BLS 输出权重 β 。

$$A = [F^m \mid H^n] \quad (5)$$

$$\beta = (A^T A + CI)^{-1} A^T Y \quad (6)$$

式中: C 为正则化参数,一般选择趋近于 0 的数值; Y 代表点云标签。

通过式(7)计算 BLS 输出结果 \hat{Y} 。

$$\hat{Y} = A\beta \quad (7)$$

2) B-PointNet++ 编解码网络结构

为了有效提取大规模点云数据特征,分割地下电缆工井点云,提出了一种 B-PointNet++ 编解码模型,将 PointNet++ 扩展为编解码网络模型,并使用 B-PointNet 替代 PointNet,如图 4 所示(上半部),编解码器网络包含 3 个卷积层,每个卷积层后面都有一个整流线性单元(ReLU)激活函数、批量归一化和最大池化层^[14]。

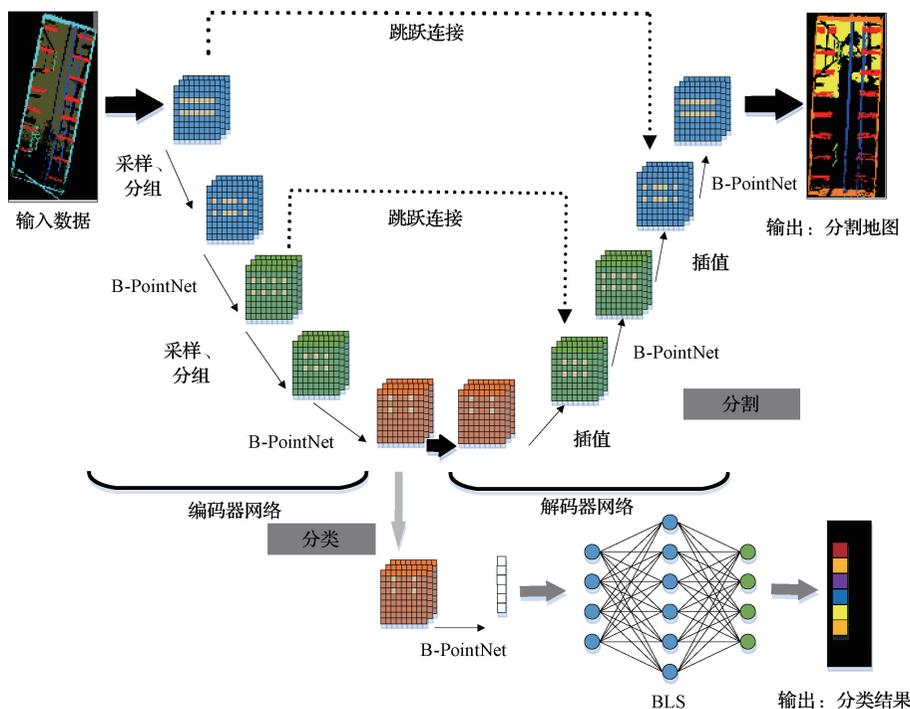


图4 B-PointNet++ 编解码器模型

在卷积层,使用一组权值可学习的核(过滤器)进行卷积运算,将输入数据转换为特征图。具体来说,在输入和

核之间进行卷积运算,其中每个核在输入上跨一步滑动,产生卷积层的空间输出。卷积层的输出大小取决于输入

大小、填充、内核大小和步幅。本研究填充采用相同的方法,即通过使用零填充遍历所有输入来保持内核卷积窗口的大小。在卷积层之后,利用 ReLU 的良好性能激活特征图的各个元素,然后进行批处理归一化,以简化计算,加快训练过程,同时提高模型的鲁棒性。随后,以 Max-pooling 为下采样核心,减小特征图的大小。Max-pooling 的操作是根据输入大小、填充大小、内核大小和步幅,在池化窗口中提取最大值,并在输入上滑动输出。最大池化的优点是可以减轻计算负载,防止过拟合。

解码器网络通过反卷积层进行上采样操作,放大输入,提取高分辨率特征。反卷积层被认为是一个转置的反卷积层,根据输入大小、填充和步幅将粗输入转换为密集输出,但网络的“暗箱”放大往往忽略细节,导致输出不理想。为了获得良好的输出,级联层将卷积层和反卷积层的输出特征融合在一起,通过跳跃式连接将编码器的特征映射复制到解码器中,从而展开特征映射。该模型基于反卷积和拼接,根据增强和重用的特征进行训练,将下采样过程产生的特征映射缩放到原始数据的大小。

在训练过程中,利用分类交叉熵(cross-entropy, CE)损失函数^[20]来评估地面真实值与预测结果之间的差异。这种损失可以更新模型的参数,跟踪三维隧道点云多类目标分割的性能。损失函数定义如下:

$$CE(y, \bar{y}) = - \sum_{i=1}^n \bar{y}_i \cdot \log y_i \quad (8)$$

式中: n 是类的数量; \bar{y}_i 表示预测; y_i 表示标签。

2 实验数据来源

2.1 点云数据采集

为进行地下电缆工井点云语义分割,分割实验以雄安新区 5、6、7、8、9 号地下电缆工井为对象,采集设备为架站式三维激光扫描仪,共采集 29 587 038 个点。由于采集地下电缆工井点云数据时光线暗淡,无法获取真实三维场景颜色信息,因此对采集的地下电缆工井三维场景点云数据进行属性剥离,剥离每个点的颜色信息及强度信息,保留坐标信息,减少数据量。其中,部分数据截图如图 5 所示。

2.2 数据集制作

为了三维点云场景分割工作的精准及高效,本文根据 ModelNet40 大型数据集的制作要求,完成了雄安新区地下电缆工井点云数据集制作。数据集制作主要包括如下 4 部分。

1) 点云数据预处理

对采集的雄安新区地下电缆工井点云数据进行去噪及抽稀操作,去除场景中分割物体不相关的点云数据。

2) 点云类别属性标注

电缆工井点云场景中主要包括地面、顶、爬梯、墙、电缆线、支架等组成,本次实验采用 CloudCompare 点云处理软件(版本 v2.11.3)对电缆工井点云进行类别属性标记,具体的属性标记如表 1 所示,标记后部分效果如图 6

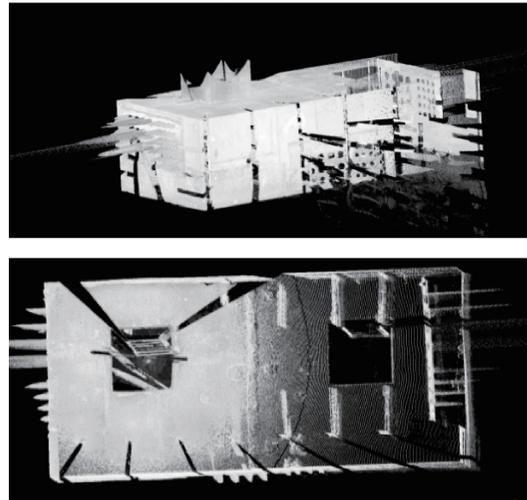


图 5 雄安新区部分地下电缆工井点云数据

表 1 雄安新区 5 号电缆工井标签分类

类别	点云数量	标签
地面	3 196 085	0
顶	2 719 484	1
爬梯	301 794	2
墙	2 985 875	3
电缆线	755 900	4
支架	650 680	5
其他	23 668	6

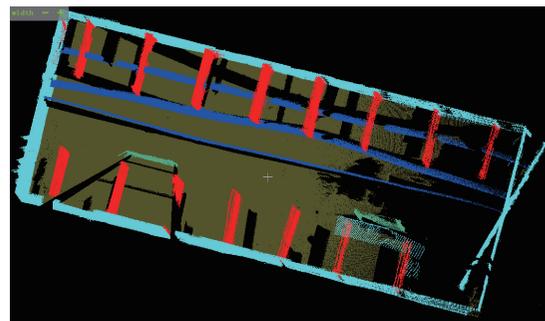


图 6 雄安新区 5 号电缆工井部分标记效果

所示。

3) 坐标归一化处理

由于地下电缆工井点云数据采用不同的站点采集,直接输入原始电缆工井点云坐标到 PointNet++ 进行训练,会导致模型泛化能力差,且由于原始坐标过大导致网络训练过程缓慢甚至崩溃,因此需要对地下电缆工井点云数据进行统一归一化处理。

将 X 、 Y 、 Z 的值限制在 $-1 \sim 1$ 。具体步骤如下:分别寻找点云数据中 X_{\max} 、 Y_{\max} 、 Z_{\max} 和 X_{\min} 、 Y_{\min} 、 Z_{\min} ;利用式(9)分别对点坐标进行变化;其中 $(X_{\text{原}}, Y_{\text{原}}, Z_{\text{原}})$ 代表原始坐标, $(X_{\text{后}}, Y_{\text{后}}, Z_{\text{后}})$ 代表归一化后坐标。

$$\begin{cases} X_{后} = \frac{2(X_{原} - X_{min})}{(X_{max} - X_{min})} - 1 \\ Y_{后} = \frac{2(Y_{原} - Y_{min})}{(Y_{max} - Y_{min})} - 1 \\ Z_{后} = \frac{2(Z_{原} - Z_{min})}{(Z_{max} - Z_{min})} - 1 \end{cases} \quad (9)$$

4) 文件格式转换

雄安新区地下电缆工井点云数据的格式为 .las, 不能直接用于 B-PointNet++ 网络训练。因此, 需要将每个电缆工井点云数据转换为 .pts 格式进行后续的网络训练操作, 转换工具为采用 Cloud Compare 点云处理软件。

3 实验结果与分析

3.1 实验设置

为了检验本文提出模型在地下电缆工井点云中多类目标分割的性能, 本文选择 B-PointNet++ 和 PointNet^[12]、PointNet++ 网络^[13] 进行了实验对比, 除引入 BLS 和 Encoder-Decoder 编解码器模块外, 3 种模型采用默认参数。实验平台环境如表 2 所示。

表 2 实验平台环境

硬件与深度学习框架	型号
CPU	Intel(R)i9-11900K
GPU	RTX 3070 Ti
RAM	32 GB
PyTorch	1.10.1
Python	3.8.0
CUDA	11.3
CUDNN	11.4
系统	Win10 专业版

为对算法进行性能分析, 本文对每个类分别采用 4 个评价指标: 精确度 (precision)、召回率 (Recall)、交并比 (intersection over union, IOU) 和 F1 值作为评价指标, 定义如下^[21-22]:

$$Precision_i = \frac{TP_i}{TP_i + FP_i} \quad (10)$$

$$Recall_i = \frac{TP_i}{TP_i + FN_i} \quad (11)$$

$$IOU_i = \frac{TP_i}{TP_i + FP_i + FN_i} \quad (12)$$

$$F1_i = 2 \times \frac{Recall_i \times Precision_i}{Recall_i + Precision_i} \quad (13)$$

式中: i 代表不同的类, $i = 1, 2, \dots, n$; TP 表示真阳性; FP 表示假阳性; TN 表示真阴性; FN 表示假阴性。

3.2 实验结果

采用雄安 7 号地下电缆工井点云数据, 利用已拟合的分割模型进行场景语义分割, 效果如图 7 所示, 其中图 7(a)为真实点云数据, 图 7(b)为真实语义标签, 图 7(c)

为模型分割效果。真实语义点云数量与模型分割点云数量比较如表 3 所示。

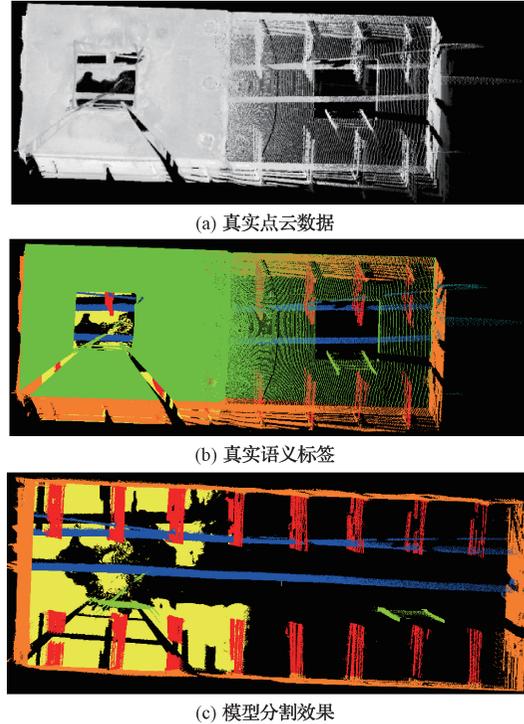


图 7 7 号地下电缆工井点云三维场景分割效果

表 3 真实语义点云数量与模型分割点云数量

类别	真实语义点云数量	模型分割点云数量
地面	1 420 864	1 421 414
顶	2 881 793	2 955 782
爬梯	567 320	494 381
墙	3 581 946	3 604 637
电缆线	475 308	464 371
支架	519 227	506 056
其他	1 528	1 345

从图 7 和表 3 可以看出, 地面、顶、墙模型分割点云数量要多于真实语义点云数量, 爬梯、电缆线、支架模型分割点云数量要小于真实语义点云数量, 在分割支架时, 会因为支架与墙连接及点云质量问题, 导致部分分割错误, 分割成地面及墙, 在分割排管等线性物体时, 算法取得了较好的效果; 分割爬梯时, 会出现部分错误, 将爬梯上表面分割成墙面; 由于部分爬梯距离支架较近, 因此被分割成支架。地面及支架处由于噪点的问题, 将部分地面及支架分割成管线, 但总体达到地下电缆点云三维场景分割的效果, 该模型能对地下电缆工井环境的主要目标进行识别, 一定程度上能够作为通用地下电缆工井分割模型使用。

为了验证上述观点, 使用 IOU 和平均交并比 (mIOU) 2 个评价指标验证本文所提方法的有效性与两种基线方

法的比较。如表4所示,本文所提的模型明显优于两种基线方法。与 PointNet++相比,本文方法极大地提高了平均交并比结果(提高 34.82%)。所提出的方法在不同语

义类别(爬梯除外)的分割方面表现出了出色的性能,表明在三维工业场景中更鲁棒、有代表性的点云特征具有良好的模型适用性。

表4 基线方法和本方法在 IOU、mIOU 评价指标下分割性能的比较 (%)

模型	mIOU	IOU					
		地面	顶	爬梯	墙	电缆线	支架
PointNet	22.91	12.10	19.36	1.23	23.35	50.88	30.52
PointNet++	50.80	48.62	56.36	8.84	63.24	70.86	56.85
B-PointNet++	85.62	86.45	96.88	50.63	87.66	98.86	93.26

注:mIOU 为 IOU 多类分割目标的平均值

此外,表5所示为准确率、召回率和 F1 值等分类指标的结果。可以看出,本文方法在精确度、召回率和 F1 值等方面的表现都有了显著的提升,达到了较高的准确

率。B-PointNet++模型在地面、顶、墙和电缆线等类别的 F1 值均超过 90%,表明本文方法在细分工业类别方面的实力。

表5 本文方法与 PointNet++在 3 个评价指标上的比较 (%)

模型	评价指标	地面	顶	爬梯	墙	支架	电缆线
PointNet++	精确度	86.84	63.31	26.37	80.83	86.30	89.63
	召回率	52.29	53.20	12.52	83.66	46.34	86.56
	F1	65.38	71.56	17.85	83.22	60.61	84.85
B-PointNet++	精确度	96.12	88.86	67.35	96.53	89.00	98.64
	召回率	95.88	93.52	60.32	94.50	86.35	95.52
	F1	95.68	91.88	70.54	93.22	83.48	97.48

为进一步验证本文提出模型的有效性,将本文方法与 PointNet、PointNet++ 2 种模型进行对比,以 7 号地下电缆工井点云整体数据集作为测试集,采用精确度、召回率、交并比和 F1 值作为评价指标,实验结果如表6所示。

表6 不同方法在 7 号地下电缆工井点云数据集上的结果 (%)

模型	精确度	召回率	交并比	F1
PointNet ^[12]	53.46	55.67	66.50	65.23
PointNet++ ^[13]	82.32	82.46	78.65	77.21
B-PointNet++	90.56	90.48	86.67	87.33

由表6可知,本文提出模型与现有模型相比,在各项评价指标结果上具有更好的性能。综合所有结果可以得出结论,本文提出的方法对于地下电缆工井点云语义分割具有较强的鲁棒性和有效性。

4 结论

地下电缆工井点云语义分割是当前热门问题,能够快速精准的识别地下电缆工井点云场景物体并进行分割对后续建模及运维工作都起到至关重要的作用。本文提出的 B-PointNet++模型,利用编解码器和宽度学习框架,克服了传统 PointNet++网络特征学习能力不足和学习效率低的缺点,提高了地下电缆工井点云语义分割的精

度。未来工作将从以下两个方面进行:地下电缆工井特殊性而缺少可供参考的公开数据集,并且地下空间数据采集的难度大,点云被遮挡问题严重,导致最终的数据集质量并不是很好;如何根据不同目标样本数据集的数量,均衡的进行模型训练也是有待解决的问题。

参考文献

- [1] 孙炜,苑河南,刘乃铭,等.融合轮廓特征的线激光点云的快速配准算法[J].电子测量与仪器学报,2021,35(7):156-162.
- [2] 俞斌,董晨,刘延华,等.基于深度学习的点云分割方法综述[J].计算机工程与应用,2020,56(1):38-45.
- [3] 李海生,武玉娟,郑艳萍,等.基于深度学习的三维数据分析理解方法研究综述[J].计算机学报,2020,43(1):41-63.
- [4] 肖衡.基于 IRNet 单阶段弱监督学习的语义分割方法[J].国外电子测量技术,2021,40(12):30-36.
- [5] 景庄伟,管海燕,臧玉府,等.基于深度学习的点云语义分割研究综述[J].计算机科学与探索,2021,15(1):1-26.
- [6] 吴连耀,万旺根.基于超像素分割的实时单目三维重建[J].电子测量技术,2020,43(11):96-101.
- [7] 王溪波,曹士彭,赵怀慈,等.双边特征聚合与注意

- 力机制点云语义分割[J]. 仪器仪表学报, 2021, 42(12): 175-183.
- [8] 石鑫, 朱永利. 深度学习神经网络在电力变压器故障诊断中的应用[J]. 电力建设, 2015, 36(12): 116-122.
- [9] 林伟. 城市地下管廊点云语义分割与三维重建方法研究[D]. 昆明: 昆明理工大学, 2021.
- [10] MATURANA D, SCHERER S. Voxnet: A 3D convolutional neural network for real-time object recognition [C]. 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2015: 922-928.
- [11] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [12] 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, 2017: 652-660.
- [13] QI C R, YI L, SU H, et al. Pointnet++: Deep hierarchical feature learning on point sets in ametric space[C]. Advances in Neural Information Processing Systems, 2017: 5099-5108.
- [14] 周广宇, 张鹏程, 刘生富, 等. 基于编解码器生成对抗网络的 CT 去噪[J]. 计算机工程与设计, 2022, 43(4): 1059-1065.
- [15] CHEN C L P, LIU Z L. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.
- [16] CHEN C L P, LIU Z, FENG S. Universal approximation capability of broad learning system and its structural variations [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(4): 1191-1204.
- [17] CHEN Y, LIU G, XU Y, et al. PointNet++ network architecture with individual point level and global features on centroid for ALS point cloud classification [J]. Remote Sensing, 2021, 13(3): 472.
- [18] SARASUA I, POLSTERL S, WACHIGER C. Recalibration of neural networks for point cloud analysis [C]. 2020 International Conference on 3D Vision (3DV). IEEE, 2017: 77-85.
- [19] 吴军, 崔玥, 赵雪梅, 等. SSA-PointNet++: 空间自注意力机制下的 3D 点云语义分割网络[J]. 计算机辅助设计与图形学学报, 2022, 34(3): 437-448.
- [20] ZHANG Z, CHEN G, WANG X, et al. Sparse and low-overlapping point cloud registration network for indoor building environments [J]. Journal of Computing in Civil Engineering, 2021, 35(2): 04020069.
- [21] YIN C, WANG B, GAN V J L, et al. Automated semantic segmentation of industrial point clouds using ResPointNet++ [J]. Automation in Construction, 2021, 130: 103874.
- [22] JI A, CHEW A W Z, XUE X, et al. An encoder-decoder deep learning method for multi-class object segmentation from 3D tunnel point clouds [J]. Automation in Construction, 2022, 137: 104187.

作者简介

王丽欢, 硕士, 高级工程师, 主要研究方向为输变电工程设计技术, 三维建模技术。

E-mail: wanglihuan_1986@163.com

任雨(通信作者), 硕士, 高级工程师, 主要研究方向为输变电工程三维设计技术、电网地理信息技术。

E-mail: 597563899@qq.com