

# POWERLINE-ALS:一种用于输电线路场景深度学习语义分割的机载 LiDAR 点云数据集

王郑阳<sup>1</sup>, 俞昊<sup>2</sup>, 孟昊<sup>1</sup>, 马宇轩<sup>1</sup>, 冉春晴<sup>1</sup>, 黄岩<sup>3</sup>, 周兴华<sup>1</sup>, 王胜利<sup>1</sup>, 张晓波<sup>1</sup>

(1. 山东科技大学海洋科学与工程学院, 山东青岛 266590;

2. 山东科技大学测绘与空间信息学院, 山东青岛 266590;

3. 江苏省地质勘查技术院, 江苏南京 211102)

**摘要:**为实现基于深度学习的输电线路点云精确语义分割, 必须建立能够准确反映目标类别特征的点云数据集。但现有数据集无法满足输电线路场景点云语义分割的需要。因此, 基于机载 LiDAR 获取的某地区 500 kV 超高压输电线路巡检点云数据构建了一套深度学习数据集——POWERLINE-ALS。该数据集包含地线、导线、杆塔、植被、建筑、低矮电力线等 6 个类别, 输电线路长 21 km。同时, 利用 PointNet++、PointCNN、KPConv、SPG、RandLA-Net 等 5 种常用深度学习模型对数据集进行了训练和测试。模型实验结果表明, POWERLINE-ALS 能够在目前主流的深度学习模型上应用, 具有普适性, 其最高测试精度和平均交并比分别达 95.31% 和 82.25%, 可以满足实际点云数据语义分割工作的精度要求。

**关键词:**输电线路; 语义分割; 深度学习; 机载 LiDAR; 点云数据集

中图分类号: P237

文献标志码: A

## POWERLINE-ALS: An airborne LiDAR point cloud dataset for transmission line scene semantic segmentation with deep learning methods

WANG Zhengyang<sup>1</sup>, YU Hao<sup>2</sup>, MENG Hao<sup>1</sup>, MA Yuxuan<sup>1</sup>, RAN Chunqing<sup>1</sup>,  
HUANG Yan<sup>3</sup>, ZHOU Xinghua<sup>1</sup>, WANG Shengli<sup>1</sup>, ZHANG Xiaobo<sup>1</sup>

(1. College of Ocean Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China;

2. College of Geodesy and Geomatics, Shandong University of Science and Technology, Qingdao 266590, China;

3. Geological Exploration Technology Institute of Jiangsu Province, Nanjing 211102, China)

**Abstract:** To achieve the accurate semantic segmentation of transmission line point clouds based on deep learning, it is necessary to establish a point cloud dataset that can accurately reflect the characteristics of the target category. However, the existing datasets cannot meet the needs of semantic segmentation of transmission line scene point clouds. Therefore, a deep learning dataset, POWERLINE-ALS, was constructed in this paper based on the point cloud data obtained by utilizing airborne LiDAR to inspect the 500 kV ultra-high voltage transmission lines in a certain region. The dataset includes six categories of ground objects: ground wires, wires, towers, vegetation, buildings, and low power lines. The length of transmission line is 21 km. The dataset was trained and tested by using five common deep learning models, PointNet++, PointCNN, KPConv, SPG, and RandLA-Net. The

收稿日期: 2022-09-28

基金项目: 国家自然科学基金项目(42106072); 山东省自然科学基金项目(ZR2020QD071); 山东省重点研发计划项目(2019JZZY010809)

作者简介: 王郑阳(1998—), 男, 山东聊城人, 硕士研究生, 主要从事激光点云三维重建的研究。

张晓波(1990—), 男, 山东安丘人, 讲师, 博士, 主要从事地球物理探测技术的研究, 本文通信作者。

E-mail: zxb@sdust.edu.cn

experimental results indicate that POWERLINE-ALS can be applied to the current mainstream deep learning models and has universality. With the highest test accuracy and the mIoU of 95.31% and 82.25% respectively, it can meet the accuracy requirements for actual point cloud data semantic segmentation.

**Key words:** transmission line; semantic segmentation; deep learning; airborne LiDAR; point cloud dataset

输电线路是保障国家工业生产和居民日常工作生活的重要电力设施。随着人们对电力系统稳定性要求的不断提高,输电线路巡检已成为保障电力供应的一项重要工作<sup>[1]</sup>。目前,基于机载激光雷达(light detection and ranging, LiDAR)技术所获取的点云数据是输电线路巡检的主要数据形式,而对输电线路点云数据进行处理和分析是输电线路巡检工作的重要内容。

在输电线路巡检数据处理中,精确的点云语义分割作为风险点检测、输电线路三维重建及可视化、导线覆冰分析等应用的基础,已成为当前研究的热点。但输电线路点云数据具有大场景、大数据量、明显的无序性和稀疏性等特点,常规基于人工或点云库的数据处理方法效率和精度低下,无法满足实际生产的需要。机器学习方法对电力线提取有较好的效果,但该方法对于整个场景中不同类别的点云难以准确分割。而深度学习技术因具有处理效率高、能够识别复杂特征等优势,在点云数据语义分割领域展现出巨大潜力<sup>[2]</sup>。近年来,已有学者围绕基于深度学习的点云语义分割方法开展了相关研究,根据使用数据类型的不同分为三类:基于体素化的方法、基于网格的方法以及基于原始点云的方法。其中,基于体素化和基于网格的方法均需进行数据预处理;而基于原始点云方法可直接利用原始三维点云信息提取目标的几何信息、刻画结构,从而实现精确、高效的点云语义分割。目前基于原始点云的方法又细分为:①基于 point-wise 的方法,如 PointNet<sup>[3]</sup>、PointNet++<sup>[4]</sup>模型逐点使用共享多层感知机(multilayer perceptron, MLP)的方法提取点云的全局特征,RandLA-Net<sup>[5]</sup>模型使用随机降采样和局部特征聚合的方法逐点提取点云的全局特征和局部特征信息;②基于点卷积的方法,如 PointCNN<sup>[6]</sup>模型采用“ $\chi$ -Conv”点卷积模块实现了点云数据的规则化,KPConv<sup>[7]</sup>模型采用可变点卷积核模块提高了点云数据特征提取的效果;③基于图的方法,如陈景尚等<sup>[8]</sup>验证了超点图(superpoint graphs, SPG)方法在复杂室外场景中电力设施点云分割的精度。

由于深度学习是一种基于数据驱动的技术,为得到高精度输电线路点云语义分割的结果,必须建立相应的能够准确反映目标类别特征点云数据集。随着深度学习技术研究的不断深入,多种场景的高质量点云数据集不断涌现,常用的室内小型数据集如 ShapeNetCore<sup>[9]</sup>、ScanNet<sup>[10]</sup>、S3DIS<sup>[11]</sup>等,大场景典型数据集如 SemanticKITTI<sup>[12]</sup>、Semantic3D<sup>[13]</sup>、DALES<sup>[14]</sup>、WHU-MLS<sup>[15]</sup>等。其中,SemanticKITTI 和 Semantic3D 数据集分别包含 28 和 8 个语义类,虽然均为城市户外场景,但都不包括输电线路场景;DALES 数据集包含地面、植被、电线、电线杆、建筑物、栅栏、卡车、轿车等 8 个语义类,WHU-MLS 数据集包含电线杆、电力线等 30 个语义类,虽然采集了输电线路场景,但场景中电力线语义类别单一,未对其类别进行细分。

由上述典型点云数据集特点可知:①目前小场景数据集居多,虽然不乏高质量大场景户外数据集,但其中很少或不包含输电线路相关点云数据,难以帮助算法训练出电力线场景分类模型;②虽有少量数据集包含输电线路场景,但其数据场景只包含一类电力线,对电力线的语义类别也没有细分。此外,由于输电线路场景与常规室外场景相比存在显著差异,特别是实际电力线点云空间分布狭长,地面建筑与低矮植被等类别混叠在一起,导致点云数据集中各类别训练样本分布不均衡;③目前缺少专门为输电线路巡检构建的、能准确反应输电线路场景特征且包含各种复杂地形或环境的高质量输电线路点云数据集。

针对当前输电线路巡检点云数据集构建中存在的问题,本研究基于机载 LiDAR 获取的某地区 500 kV 超高压输电线路点云数据,制作了一套专门用于输电线路巡检的大场景三维点云数据集 POWERLINE-ALS。同时为验证所建数据集的普适性和有效性,分别基于 PointNet++、PointCNN、KPConv、SPG、RandLA-Net 等 5 种具有代表性的深度学习模型进行训练与测试。该数据集可为基于深度学习的输电线路点云语义分割等应用提供数据支撑,对提高输电线路巡检工作效率具有重要意义。

## 1 原始点云数据获取

为建立输电线路三维点云数据集,首先需要通过输电线路巡检获取实际点云数据。目前,在实际输电线

路巡检作业中,机载 LiDAR 比车载 LiDAR 具有更好的复杂地形适应能力,比地面静态扫描仪具有更出色的全方位扫描能力。机载 LiDAR 具有点云密度高、不受恶劣天气影响、适合室外场景作业等特点,成为最常用的数据采集方式。机载 LiDAR 不能单独作业,必须依赖高精度的定位方式和可靠的飞行平台,同时,考虑到实际作业中人力成本的控制以及点云数据精度的要求,需要对定位方式和飞行平台进行合理选择。

下面以某输电线路巡检作业为例,对不同定位方式及飞行平台进行详细对比分析。本次输电线路巡检中,机载 LiDAR 测量系统所用激光扫描仪型号为 RIEGL VUX-1HA,组合导航系统型号为北斗星通 SPAN-ISA-100C,工业相机型号为凌云 LBAS-GE120-09C。该数据采集工作采用的飞行平台共 5 种,包括载人直升机、载人自旋翼、无人直升机、无人固定翼和无人多旋翼。

在定位方式的选择上,本次巡检采用不同飞行平台分别搭载 4 种定位方式进行实验,得到的定位精度如图 1 所示。4 种定位方式包括省 CORS (province CORS)、千寻 CORS(QianXun CORS)<sup>[16]</sup>、动态后处理(post-processing kinematic, PPK)基站差分定位、多源数据融合精密单点定位<sup>[17]</sup>(precise single point positioning, PPP)。通过在飞行路线区域布设检核点(如道路拐点、房角、杆塔顶部点等),制作点之记,再依据点云影像,结合激光回波等测量结果,计算外业点云数据与检核点的误差,从而获得不同定位方式的定位精度。通过对比分析可以看出,省 CORS 和千寻 CORS 的精度较低,而 PPK 基站差分定位和多源数据融合 PPP 的精度要明显优于前两种定位方式。在除载人自旋翼以外的 4 种飞行平台测试中,PPK 基站差分定位方式的精度均优于多源数据融合 PPP。因此,载人自旋翼搭配多源数据融合 PPP 或其他平台搭配的 PPK 基站差分定位为最优搭配。

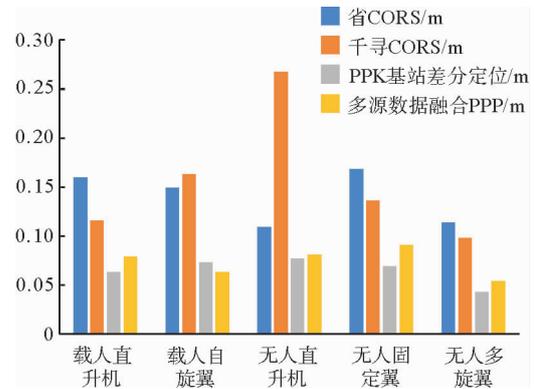


图 1 飞行平台定位精度

Fig. 1 Positioning accuracy of flight platforms

在除载人自旋翼以外的 4 种飞行平台测试中,PPK 基站差分定位方式的精度均优于多源数据融合 PPP。因此,载人自旋翼搭配多源数据融合 PPP 或其他平台搭配的 PPK 基站差分定位为最优搭配。

在飞行平台的选择方面,本次巡检对 5 种飞行平台的续航时间、采集飞行速度、飞行高度等信息进行实验并汇总,如表 1 所示。从表中可以看出,载人直升机与载人自旋翼的续航能力强,但是载人直升机需要额外的人员配置,而载人自旋翼需要专门的跑道,这两种方法成本高且得到的点密度低,所获取数据质量不高;无人固定翼的续航时间短,采集的点云密度仅为 33 点/m<sup>2</sup>,难以满足输电线路巡检的基本要求(点云密度 80~200 点/m<sup>2</sup>);无人多旋翼虽然采集点云密度达 223 点/m<sup>2</sup>,但是续航时间短,实际获取的总数据量较少,

表 1 飞行平台对比

Table 1 Comparison of flight platforms

主要参数名称	载人直升机	载人自旋翼	无人直升机	无人固定翼	无人多旋翼
最高升限/m	7 010	300	2 000	4 500	2 500
续航时间/h	4.5	4~8	2	1	0.5
最大速度/(km/h)	258	195	112	120	30
采集飞行速度/(km/h)	60	70	60	78	25
起降方式	垂直起降	50 m 跑道	垂直起降	垂直起降	垂直起降
点密度/(点/m <sup>2</sup> )	85	80	131	33	223
试用规模/km	>150	>100	<50	>100	均适用
点频/(10 <sup>-4</sup> s)	75	75	50	25	75
飞行高度/m	130	130	120	220	120

难以满足数据应用的需要;无人直升机采集点云密度达 131 点/ $\text{m}^2$ ,续航时间适中,可以满足输电线路巡检的基本要求且经济适用性高,因此选择无人直升机为飞行平台。

综上所述,在利用机载 LiDAR 实现输电线路点云数据采集时,选择 PPK 基站差分作为定位方式、无人直升机作为飞行平台的应用效果最优,因此本研究由无人直升机采用 PPK 基站差分定位技术进行点云数据的采集。

## 2 点云数据集构建

基于无人直升机获取的原始输电线路点云数据,共计 65 个杆塔档间(简称为场景),输电线路点云数据集的构建主要包括分离地面点与数据集标注两部分。

### 2.1 分离地面点

由于超高压输电线路一般架设在空旷的野外环境,点云数据中地面点的数量在整个场景中占比较高(达 80%以上)。而在基于深度学习模型进行输电线路特征学习过程中,不同类别点云数量的差异会对网络训练精度产生较大影响。为提高非地面点云的语义分割效果,在数据集建立过程中首先对地面点云进行分离。采用复杂度和精度两个指标对地面点云分离算法进行评价。

在复杂度方面,由于超高压输电线路场景地形条件复杂,地面滤波难度较大。三角网滤波的效果易受地形特征的影响,且滤波器中各种参数的设置较为繁琐。布料模拟滤波算法<sup>[18]</sup>通过模拟柔软的布料覆盖于地面的过程提取地面点,参数设定较为简单,通常只需要设置分类阈值(用于区分是否为地面点、最大迭代次数和布料格网大小),即在少量先验阈值的约束下对地面点进行分离。

在精度方面,本研究采用美国摄影与遥感协会提出的交叉表评价体系对三角网滤波与布料模拟滤波两种方法进行对比,算法误差如表 2 所示。其中 I 类误差表示被误判为非地面点的地面点占地面点总数的比例;II 类表示被误判为地面点的非地面点占非地面点总数的比例;总误差为误判点占总点云数量的比例。

由表 2 结果对比可知:布料模拟滤波的 I 类误差比三角网滤波低 3.47%,说明布料模拟滤波算法将地面点误判为非地面点的概率小于三角网滤波算法;II 类误差二者相差不大且布料模拟滤波的总误差比三角网滤波低 4.92%,布料模拟滤波的误判点总数远小于三角网滤波误判点总数,整体判别要优于三角网滤波。

由于布料模拟滤波不需要过多先验阈值,且参数设置较为简单,同时算法误差小于三角网滤波。因此,本研究首选布料模拟滤波算法来实现地面点云的初步分离。但如表 2 所示,利用该算法对地面点云滤波后仍存在 7.14%的总误差。为实现完整地面点云的分离,采用手动标注的方式对地面点云做进一步修正。

### 2.2 数据集标注

将地面点云分离后,进一步对非地面点云采用 CloudCompare 软件进行手动标注。首先对不同类别点云数据进行框选,按类别依次分割为不同区域并保存,然后对每类分别添加标签值,将点云分为杆塔、导线、地线、低矮电力线、建筑、植被等 6 类,如图 2 所示。其中,杆塔是整个电力线路的关键设施,能够架空导线和地线,起到保护支撑作用;导线是固定在杆塔上输送电流用的金属线,用于传输电流,减少电能损耗;输电线路跨越地域广,且完全暴露在空中,在雷雨季节易受雷击,是输电线路发生事故的主要原因,地线可保护架空输电线路免遭雷电袭击;低矮电力线是经过村庄或城镇的低压输电线,多为 220 V 的生活用电;建筑主要由一些靠近输电线路的农房、板房等组成;植被主要由输电线路经过的耕地、森林、城市道路绿化植物等组成。根据以上点云类别,共手动标注 3 246 万个点,实现输电线路点云数据集——POWERLINE-ALS 的构建。表 3 和表 4 分别列出 POWERLINE-ALS 语义分割数据集中训练集和测试集的不同类别点数和场景数。

表 2 地面滤波算法误差对比

滤波算法	I 类误差	II 类误差	总误差
布料模拟滤波	12.83	3.28	7.14
三角网滤波	16.30	2.34	12.06

由表 3 可知,训练集共包含 54 个场景,涵盖植被、杆塔、地线、导线、低矮电力线、建筑等类别。如表 4 所示,测试集共包含 11 个场景且每个场景均未在训练集中出现。测试集包含的类别数与训练集相同,以便有效测试深度学习模型的训练效果。如表 5 所示,将制作好的 POWERLINE-ALS 数据集与一些常规标准点云数据集进行对比,可以看出该数据集不仅包含输电线路场景,并且对不同电力线的种类也进行了划分,为输电线路的精确语义分割提供数据支撑。

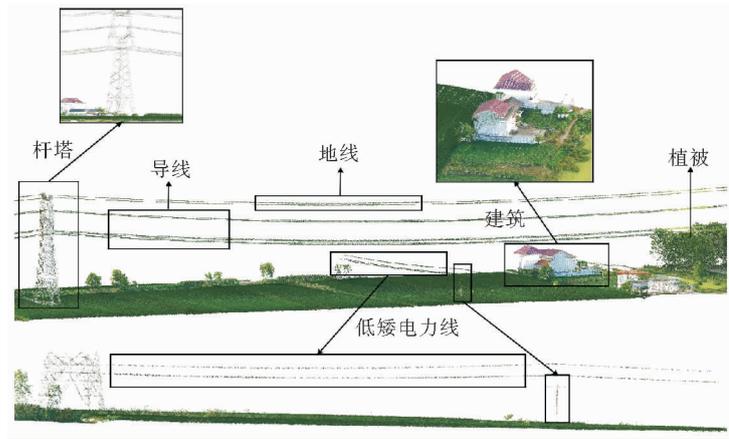


图 2 原始点云数据集

Fig. 2 Original point cloud dataset

表 3 训练集类别信息

Table 3 Training set category information

训练集	植被	杆塔	地线	导线	建筑	低矮电力线	总计
点数/个	18 767 273	2 433 216	543 686	1 248 088	3 054 952	125 085	26 172 300
占比/%	71.6	9.3	2.1	4.8	11.7	0.5	100
包含该类别的场景数/个	54	54	54	54	40	48	—

表 4 测试集类别信息

Table 4 Test set category information

测试集	植被	杆塔	地线	导线	建筑	低矮电力线	总计
点数/个	3 432 350	311 887	84 976	325 952	2 119 972	9 185	6 284 322
占比/%	54.6	4.9	1.4	5.2	33.7	0.2	100
包含该类别的场景数/个	11	11	11	11	10	6	—

表 5 数据集信息对比

Table 5 Comparison of dataset information

数据集名称	数据集采集所用传感器平台	数据集所含类别数量	是否为大场景数据集	是否包含有关于输电线路场景	是否对不同电力线进行分类
ShapeNetCore	—	55	×	×	—
ScanNet	RGB-D 传感器	21	×	×	—
S3DIS	—	12	×	×	—
SemanticKITTI	车载 LiDAR	28	✓	×	—
Semantic3D	地面静态 LiDAR	8	✓	×	—
DALES	机载 LiDAR	8	✓	✓	×
WHU-MLS	地面静态 LiDAR	30	✓	✓	×
POWERLINE-ALS	机载 LiDAR	6	✓	✓	✓

综上,本研究所构建的 POWER-LINE-ALS 数据集共包含 65 个场景的输电线路点云数据,其中训练集包含 54 个场景,测试集包含 11 个场景,点云类别包括植被、杆塔、地线、导线、建筑和低矮电力线等。图 3 为训练集中第 14 个场景的点云数据示意图,为了便于理解各类别点云的空间分布关系,这里将剔除的地面点与训练集数据进行合并展示。图 4 为数据集中不同类别点云的细节特征。

### 3 基于深度学习的数据集测试

为检验所建立的输电线路点云数据集 POWERLINE-ALS 的适用性,选用目前常用的深度学习模型:SPG、PointCNN、PointNet ++、KPCConv、RandLA-Net 等进行测试。

#### 3.1 数据集评价指标

针对不同的深度学习模型,选用总体精度(overall accuracy,OA)和交并比

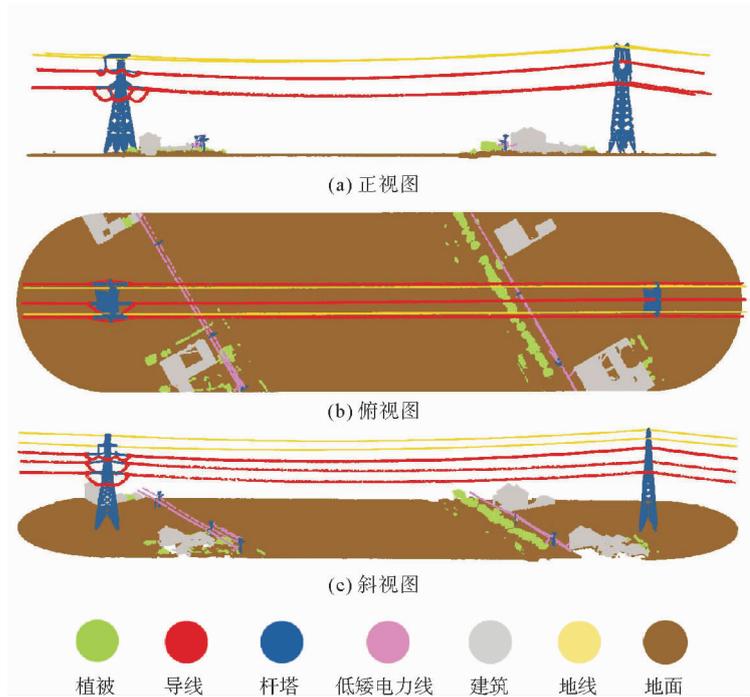


图 3 训练集的第 14 个场景点云数据示意图

Fig. 3 Schematic diagram of the 14th scene of training dataset

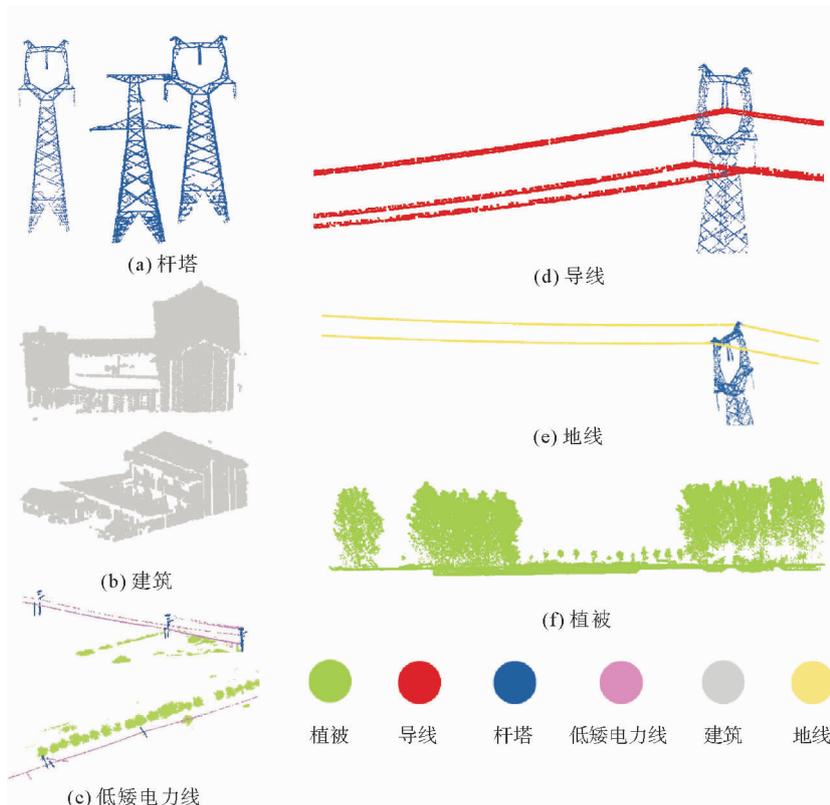


图 4 不同类别点云细节特征示意图

Fig. 4 Schematic diagram of detail features of different categories of point clouds

(intersection over union, IoU) 两种语义分割评价指标衡量分类的性能。其中,  $V_{OA}$  表示分类的总体精度, 是统计每一个样本点的预测结果与真实结果一致性的最简单的精度评价指标;  $V_{IoU}$  是真实值(ground truth)和预测值(predicted segmentation)的交集和并集之比。  $V_{mIoU}$  是所有类别的平均  $V_{IoU}$  值,  $V_{mIoU}$  评价指标具有代表性强、全局评价客观的优势, 被广泛应用于评价语义分割网络的优劣性。  $V_{OA}$  值和  $V_{IoU}$  值计算公式为:

$$V_{OA} = \frac{\sum V_{TP}}{N}, \quad (1)$$

$$V_{IoU} = \frac{P \cap G}{P \cup G} = \frac{V_{TP}}{V_{TP} + V_{FN} + V_{FP}}。 \quad (2)$$

其中:  $G$  表示真实值;  $P$  表示预测值;  $N$  表示样本总数;  $V_{TP}$  表示真正, 即正确预测的值的样本数;  $V_{FN}$  表示假负, 即将该类别判别为其他类别的样本数;  $V_{FP}$  表示假正, 即将其他类别判别为该类别的样本数。  $V_{TP}$ 、 $V_{FP}$ 、 $V_{FN}$  通过混淆矩阵计算所得, 见表 6。

### 3.2 常用深度学习模型介绍

由于 SPG、PointCNN、PointNet++、KPConv、RandLA-Net 等 5 种深度学习模型在 Semantic3D、SemanticKITTI 等大场景典型数据集上表现出优异的测试精度与效率, 网络中各超参数的设定均经过大量测试验证, 算法较为稳定。因此基于以上深度学习模型对 POWERLINE-ALS 数据集进行测试, 以验证该数据集的可用性。表 7 为 5 种深度学习模型的对比。

表 6 混淆矩阵

Table 6 Confusion matrix

	$V_{TP}$	$V_{FP}$	$V_{FN}$
真实值	1	0	1
预测值	1	1	0

表 7 深度学习模型

Table 7 Deep learning models

深度学习模型	原理	优点	缺点
SPG <sup>[8]</sup>	基于图卷积	利用边缘特征提升大规模点云场景的分割精度	将目标进行划分的步骤较难实现, 容易造成分类错误
PointCNN <sup>[6]</sup>	基于点卷积	使用 $\chi$ 变换对特征矩阵进行重新加权和排列, 改善无序性的影响	邻域特征获取不充分, 且时间和空间复杂度较大
PointNet++ <sup>[4]</sup>	基于 MLP 逐点处理	通过层级下采样捕捉局部信息, 多尺度分组与多分辨率分组	采样点方向过于集中, 难以适应复杂场景
KPConv <sup>[7]</sup>	基于点卷积	可任意设置核点数, 比固定卷积核方法更灵活	忽略目标之间的边界信息
RandLA-Net <sup>[5]</sup>	基于 MLP 逐点处理	随机采样及局部特征聚合模块有效解决了采样信息丢失的问题	易受数据采集噪声的影响

### 3.3 数据集测试

对 3.2 介绍的 5 种深度学习模型进行 POWERLINE-ALS 数据集测试。实验的软硬件配置如表 8 所示。深度学习框架为 TensorFlow 和 Pytorch。

训练过程中网络模型的超参数包括: Epoch 数值为 1 000, Batch\_Size 数值为 2, 优化器为 Adam, 动量和初始学习率分别为 0.9 和 0.001, 衰减率为 0.000 1。

基于 SPG、PointCNN、PointNet++、KPConv、RandLA-Net 等 5 种深度学习模型对

表 8 软硬件配置

Table 8 Software and hardware configuration

名称	配置
操作系统	Ubuntu18.04
处理器	Intel® Xeon(R) W-2235 CPU@3.80GHzx12
显卡	NVIDIA Quadro RTX 4000
显存	8 GB
CUDA 版本	10.1
cuDNN 版本	7.5.1
Python 版本	3.7.3
TensorFlow 版本	1.13.1
Pytorch 版本	1.4.0
开发环境	Anaconda3
编译环境	PyCharm

POWERLINE-ALS 数据集进行语义分割处理。不同深度学习模型的语义分割结果如表 9 所示。总体而言,各深度学习模型均取得了较好的语义分割效果: $V_{OA}$ 值均在 85%以上,其中 SPG 为 86.82%,PointCNN 为 85.42%,PointNet++ 为 92.26%,KPConv 为 94.95%,RandLA-Net 为 95.31%; $V_{mIoU}$ 值均在 62%以上,其中 SPG 为 62.16%,PointCNN 为 72.80%,PointNet++ 为 73.82%,KPConv 为 80.09%,RandLA-Net 为 82.25%。对不同类别的点云而言,植被、导线、地线、杆塔类别在大部分网络模型中效果均较好,其原因是:①导线、地线、杆塔特征明显,特征学习容易判别;②植被点云数量多,其特征学习更充分,可预测程度高。低矮电力线整体分类效果较差,原因是该类别数据集点云数量较少,且点云密度不均衡,因而在学习特征时可利用的上下文信息较少,特征聚合能力差。

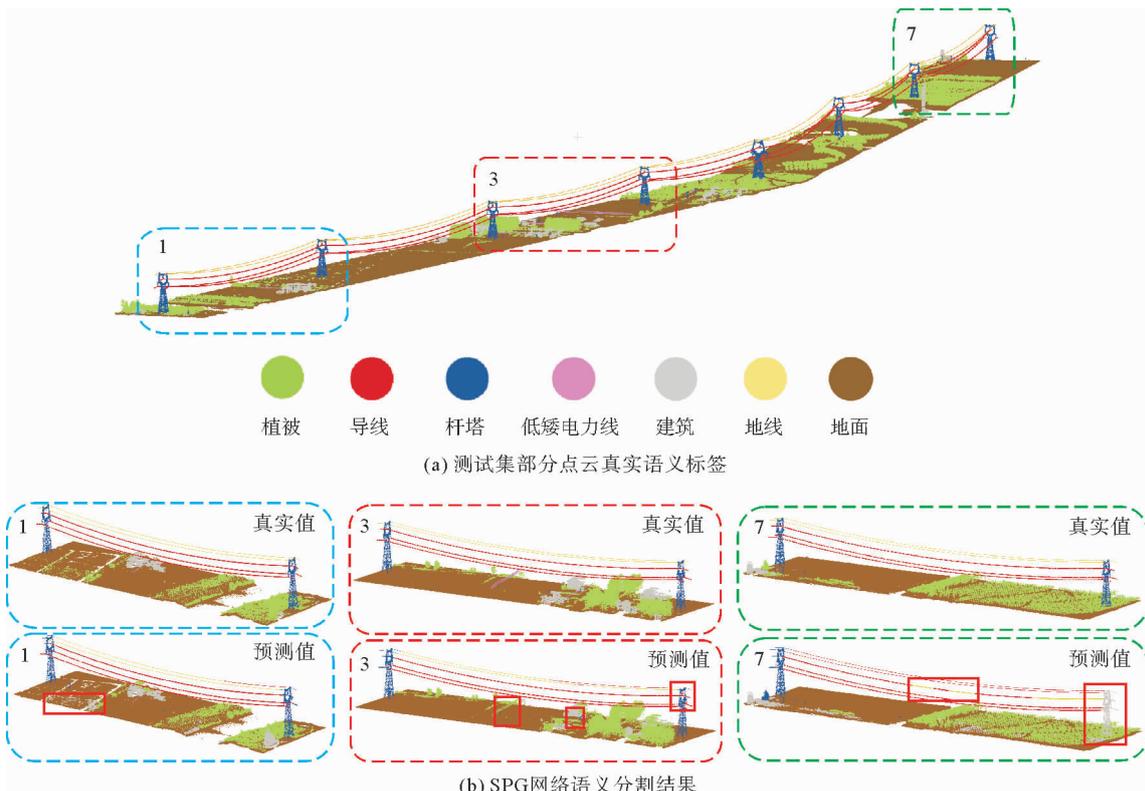
表 9 基于 POWERLINE-ALS 数据集的语义分割结果

Table 9 Semantic segmentation results based on POWERLINE-ALS dataset

%

网络模型	$V_{IoU}$						$V_{mIoU}$	$V_{OA}$
	植被	建筑	低矮电力线	导线	杆塔	地线		
SPG	82.64	62.90	4.06	89.26	83.56	50.55	62.16	86.82
PointCNN	98.00	72.80	27.10	80.90	88.40	69.50	72.80	85.42
PointNet++	85.64	62.27	5.45	92.60	81.91	92.64	73.82	92.26
KPConv	96.69	94.10	17.56	93.01	80.84	98.32	80.09	94.95
RandLA-Net	94.65	91.51	36.91	98.82	80.16	91.45	82.25	95.31

这里以测试集中部分场景的点云数据为例,对不同网络的语义分割结果进行了展示(图 5)。图 5(a)为测试集第 1~7 场景的点云真实语义标签,图 5(b)~5(f)分别为采用 SPG、PointCNN、PointNet++、KPConv、RandLA-Net 等 5 种模型的语义分割结果(第 1、3、7 场景)。其中,地面类别点云未参与语义分割,但为了保证数据集的完整性,图 5 将剔除的地面点加入语义分割预测结果中一并展示。从局部分割误差结果可以看出(图 5 红色矩形区域),各网络模型的点云语义分割效果与其评价指标一致,均获得了良好的分割效果。



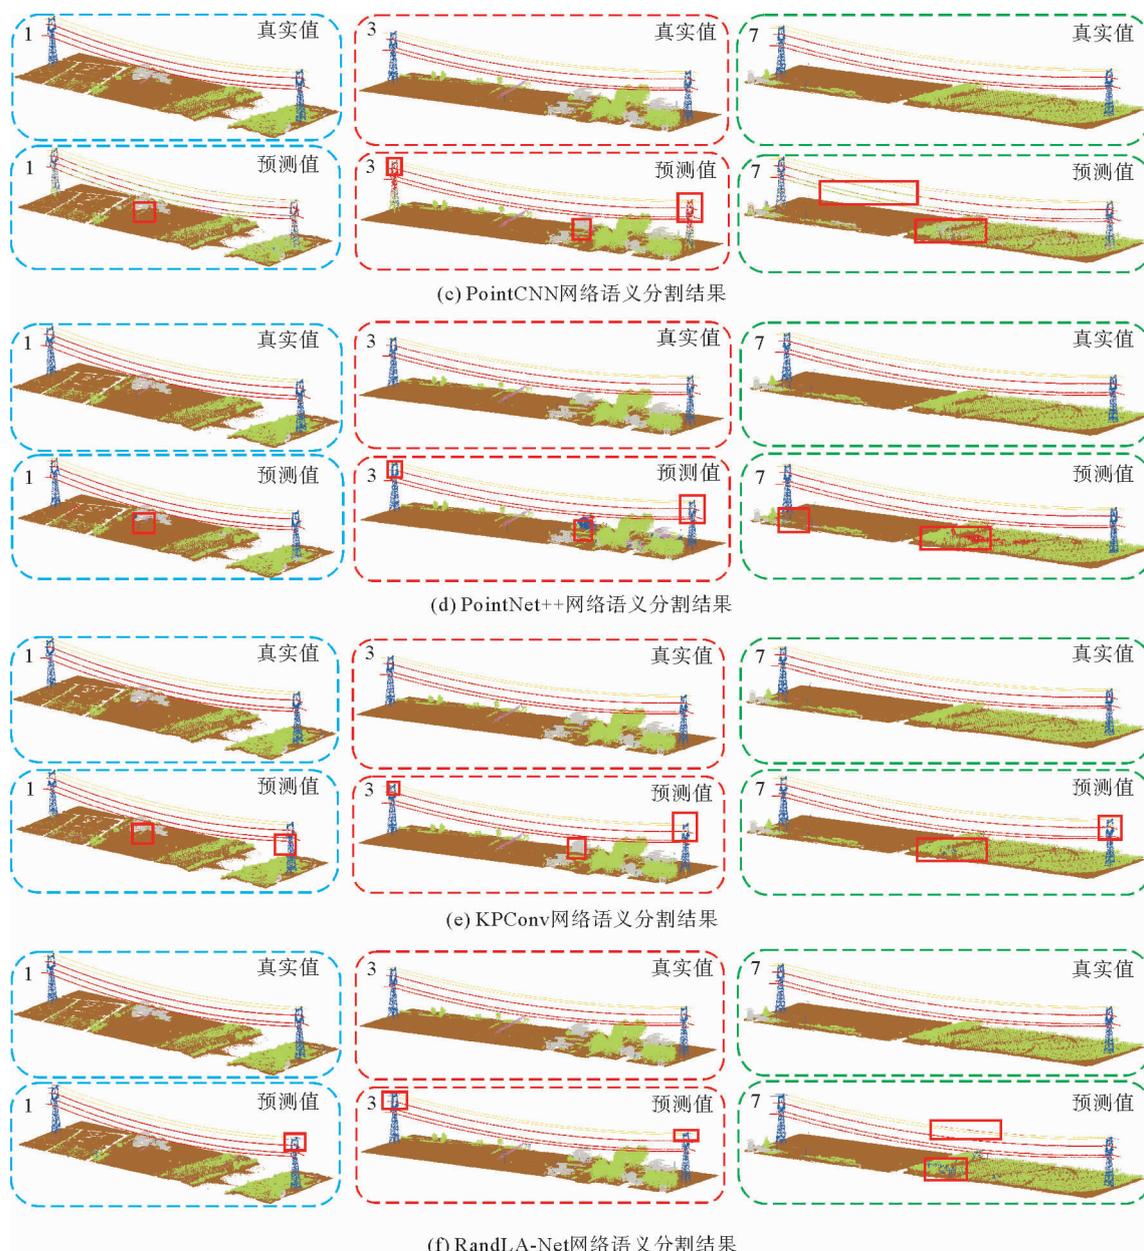


图5 局部点云语义分割结果(测试集的第1、3、7个场景)

Fig. 5 Partial point cloud semantic segmentation results (the 1st, 3rd, 7th scenes of test dataset)

## 4 结论

本研究构建了一套应用于深度学习语义分割的 500 kV 超高压输电线路点云数据集 POWERLINE-ALS。分别采用 5 种主流的深度学习点云语义分割算法对该数据集进行测试。实验结果表明:

1) 在原始点云数据采集方面,通过对不同定位方式及飞行平台进行详细对比分析可得,以 PPK 基站差分作为定位方式、无人直升机作为飞行平台的采集方式具有最优的应用效果。

2) 在数据集建立方面,与三角网滤波相比,布料模拟滤波参数设置简单且算法误差小;同时,采用先布料模拟滤波、后手动标注的方式可实现完整地面点云的分离。基于非地面点云构建的 POWERLINE-ALS 数据集包含 6 个点云类别以及 65 个场景的输电线路点云数据,其中训练集包含 54 个场景,测试集包含 11 个场景。该数据集与多种常用深度学习点云数据集对比,具有包含输电线路场景丰富、可实现不同电力线类

别划分的等特点。

3) 在深度学习模型测试方面,所使用的深度学习算法均可对 POWERLINE-ALS 数据集中不同类别的点云实现有效的语义分割;各种算法测试结果的  $V_{OA}$  值均在 85% 以上,最高可达 95.31%,  $V_{mIoU}$  值均在 62% 以上,最高可达 82.25%。

从 5 个深度学习模型测试的结果可以看出,POWERLINE-ALS 数据集对不同深度学习模型具有普适性,且对输电线路类别区分准确,能够为基于深度学习的输电线路点云语义分割提供可靠的数据支撑。下一步,将利用已构建的输电线路场景数据集,针对目前低矮电力线类别分割精度较低的问题,对深度学习模型进行改进,以期对各类别点云均获得高精度的语义分割效果。

#### 参考文献:

- [1] 陈传法,王梦樱,杨帅,等.适用于林区机载 LiDAR 点云的多分辨率层次插值滤波方法[J].山东科技大学学报(自然科学版),2021,40(2):12-20.  
CHEN Chuanfa,WANG Mengying,YANG Shuai,et al.A multi-resolution hierarchical interpolation-based filtering method for airborne LiDAR point clouds in forest areas[J].Journal of Shandong University of Science and Technology(Natural Science),2021,40(2):12-20.
- [2] 李海伦,江浩,孙鹏伟.基于李代数表征的三维物体空间姿态检测[J].山东科技大学学报(自然科学版),2019,38(6):91-97.  
LI Hailun,JIANG Hao,SUN Pengwei.Three-dimensional object space pose detection based on Lie algebras representation [J].Journal of Shandong University of Science and Technology(Natural Science),2019,38(6):91-97.
- [3] 赵中阳,程英蕾,释小松,等.基于多尺度特征和 PointNet 的 LiDAR 点云地物分类方法[J/OL].激光与光电子学进展,2019,56(5).DOI:10.3788/LOP56.052804.  
ZHAO Zhongyang,CHENG Yinglei,SHI Xiaosong,et al.Terrain classification of LiDAR point cloud based on muti-scale features and PointNet[J/OL].Laser & Optoelectronics Progress,2019,56(5).DOI:10.3788/LOP56.052804.
- [4] 陈正宇,彭淑雯,朱号东,等.基于样本加权 PointNet++ 的输电通道点云分类研究[J].遥感技术与应用,2021,36(6):1299-1305.  
CHEN Zhengyu,PENG Shuwen,ZHU Haodong,et al.LiDAR point cloud classification of transmission corridor based on sample Weighted-PointNet++[J].Remote Sensing Technology and Application,2021,36(6):1299-1305.
- [5] HAN G J,ZHU Y T,LIAO L C,et al.Hybrid attention-based 3D object detection with differential point clouds[J/OL].Electronics,2022,11.DOI:10.3390/electronics11234010.
- [6] 胡传文,卢世杰,杨文敬,等.基于 LiDAR 点云的建筑物分割深度学习模型研究[J].测绘通报,2021(12):88-93.  
HU Chuanwen,LU Shijie,YANG Wenjing,et al.Deep learning architecture for building extraction using LiDAR point clouds[J].Bulletin of Surveying and Mapping,2021(12):88-93.
- [7] GHARINEIAT Z,KURDI F T,CAMPBELL G.Review of automatic processing of topography and surface feature identification LiDAR data using machine learning techniques[J/OL].Remote Sensing,2022,14.DOI:10.3390/rs14194685.
- [8] 陈景尚,魏攀.基于 Superpoint Graphs 模型的输电线路点云自动分割方法[J].测绘地理信息,2022,47(增1):183-187.  
CHEN Jingshang,WEI Pan.An automatic segmentation method of transmission line point cloud based on Superpoint Graphs model[J].Journal of Geomatics,2022,47(S1):183-187.
- [9] ZHANG D W,HAN J W,CHENG G,et al.Weakly supervised object localization and detection: A survey[J/OL].IEEE Transactions on Pattern Analysis and Machine Intelligence,2021,44(9):5866-5885.DOI:10.1109/TPAMI.2021.3074313.
- [10] MINAEE S,BOVKOV Y,PORIKLI F,et al.Image segmentation using deep learning: A survey [J/OL].IEEE Transactions on Pattern Analysis and Machine Intelligence,2021.DOI:10.1109/TPAMI.2021.3059968.
- [11] XIE Y X,TIAN J J,ZHU X X.Linkng points with labels in 3D: A review of point cloud semantic segmentation [J/OL].IEEE Geoscience and Remote Sensing Magazine,2020,8(4):38-59.DOI:10.1109/MGRS.2019.2937630.
- [12] GUO Y L,WANG H Y,HU Q Y,et al.Deep learning for 3D point clouds: A survey[J/OL].IEEE Transactions on Pattern Analysis and Machine Intelligence,2020.DOI:10.1109/TPAMI.2020.3005434.
- [13] BELLO S A,YU S S,WANG C,et al.Review: Deep learning on 3D point clouds[J/OL].Remote Sensing,2020,12.DOI:10.3390/rs12111729.

- [14] HU Q Y, YANG B, XIE L H, et al. Learning semantic segmentation of large-scale point clouds with random sampling[J/OL]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021. DOI: 10.1109/TPAMI.2021.3083288.
- [15] 杨必胜, 韩旭, 董震. 点云深度学习基准数据集[J]. 遥感学报, 2021, 25(1): 231-240.  
YANG Bisheng, HAN Xu, DONG Zhen. Point cloud benchmark dataset WHU-TLS and WHU-MLS for deep learning[J]. National Remote Sensing Bulletin, 2021, 25(1): 231-240.
- [16] 步东亮. 省级 CORS 与千寻位置 CORS BDS 网络 RTK 精度对比分析[J]. 矿山测量, 2021, 49(1): 61-64.  
BU Dongliang. Comparative analysis of RTK accuracy between provincial CORS and Chihiro location CORS BDS[J]. Mine Surveying, 2021, 49(1): 61-64.
- [17] 孟昊, 韩保民, 王胜利, 等. 多系统融合精密单点定位在机载雷达输电线路巡检中的应用[J]. 全球定位系统, 2021, 46(5): 104-110.  
MENG Hao, HAN Baomin, WANG Shengli, et al. Airborne radar power line inspection based on multi-GNSS fusion precise single point positioning [J]. GNSS World of China, 2021, 46(5): 104-110.
- [18] ZHANG W M, QI J B, WAN P, et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation[J/OL]. Remote Sensing, 2016, 8. DOI: 10.3390/rs8060501.

(责任编辑: 高丽华)

---

### (上接第 32 页)

- [12] 朱正任, 冯成凯, 徐琪尧, 等. 基于小波分析的多波束声呐图像角度响应修正方法[J]. 山东科技大学学报(自然科学版), 2021, 40(2): 31-40.  
ZHU Zhengren, FENG Chengkai, XU Qiyao, et al. Angular response correction method of multibeam sonar images based on wavelet analysis[J]. Journal of Shandong University of Science and Technology(Natural Science), 2021, 40(2): 31-40.
- [13] CLARKE J E H, DANFORTH B W, VALENTINE P. Areal seabed classification using backscatter angular response at 95 kHz[C]// Proceedings of SAACLANT Conference on High Frequency Acoustics in Shallow Water, Lerici: NatoSaclant Undersea Research Centre, 1997: 243-250.
- [14] 郑淑丹, 郑江华, 石明辉, 等. 基于分形和灰度共生矩阵纹理特征的种植型药用植物遥感分类[J]. 遥感学报, 2014, 18(4): 868-886.  
ZHENG Shudan, ZHENG Jianghua, SHI Minghui, et al. Classification of cultivated Chinese medicinal plants based on fractal theory and gray level co-occurrence matrix textures[J]. Journal of Remote Sensing, 2014, 18(4): 868-886.
- [15] 刘学军, 龚健雅, 周启鸣, 等. 基于 DEM 坡度坡向算法精度的分析研究[J]. 测绘学报, 2004, 33(3): 258-263.  
LIU Xuejun, GONG Jianya, ZHOU Qiming, et al. A study of accuracy and algorithms for calculating slope and aspect based on grid digital elevation model(DEM)[J]. Acta Geodaetica et Cartographica Sinica, 2004, 33(3): 258-263.
- [16] DIESING M, GREEN S L, STEPHENS D, et al. Mapping seabed sediments: Comparison of manual, geostatistical, object-based image analysis and machine learning approaches[J]. Continental Shelf Research, 2014, 84: 107-119.
- [17] LEWIS K B. A reversal of throw and change of trend on the Wellington fault in Wellington Harbour[J]. New Zealand Journal of Geology and Geophysics, 1989, 32(2): 293-298.

(责任编辑: 高丽华)