基于PointNet++算法的道路设施双形态点云分类研究

刘 政[1],张中月[2],吴长悦[1],王 鹤[1]

(1.华北理工大学 矿业工程学院,河北 唐山 063210;
2.河北科技工程职业技术大学 建筑工程系,河北 邢台 054000)

摘要:针对复杂道路场景中由点云相互遮挡、设施结构残缺以及残缺点云样本稀缺性所导致的分类难题,文章提出了基于PointNet++算法的道路附属设施点云分类方法。通过构建涵盖行道树、路灯、垃圾桶等典型设施的道路场景点云数据集,利用PointNet++算法的多尺度特征提取能力,采用完整点云数据训练模型探究其对完整及残缺点云的分类鲁棒性。结果表明:该模型对完整点云的分类准确率达到93.6%,对残缺点云的分类准确率平均达到90%以上,显著优于传统手工分类方法。该研究验证了PointNet++算法模型对点云缺损的强容错能力,可为智慧道路巡检系统的设施自动化识别与城市三维点云缺损修复提供技术支持。

关键词:PointNet++;道路附属设施;点云分类

中图分类号:P237 **文献标志码**:A **文章编号**:1672-349X(2025)06-0023-06

DOI:10.16160/j.cnki.tsxyxb.2025.06.005

Research on Dual-Morphological Point Cloud Classification of Road Facility Based on PointNet++

LIU Zheng[1], ZHANG Zhongyue[2], WU Changyue[1], WANG He[1]

(1. College of Mining Engineering, North China University of Science and Technology, Tangshan 063210, China;
2. Department of Architectural Engineering, Hebei Vocational University of Technology and Engineering, Xingtai 054000, China)

Abstract: To overcome classification challenges in complex road scenes caused by mutual occlusion of point clouds, facility structural defects, and scarcity of incomplete point cloud samples, this paper proposes a point cloud classification method for road ancillary facility based on PointNet++. By constructing a point cloud dataset of road scenes encompassing typical facilities such as roadside trees, road lamps and trash bins, and leveraging the multi-scale feature extraction capabilities of PointNet++, the model is trained solely on complete point cloud data to investigate its robustness in classifying both complete and incomplete point clouds. The results show that the classification accuracy of complete point clouds reaches 93.6%, while that of incomplete point clouds exceeds 90%, significantly outperforming traditional manual feature methods. This demonstrates PointNet++'s strong fault tolerance for point cloud defects, providing technical support for automated facility recognition in

收稿日期:2025-02-27

作者简介:刘政(2000—),男,河北衡水人,硕士研究生,研究方向为摄影测量与遥感。

通讯作者:吴长悦(1971—),男,河北唐山人,副教授,硕士,研究方向为摄影测量与遥感。

smart road inspection systems and the repair of urban 3D point cloud defects.
Key Words：PointNet＋＋；road ancillary facilities；point cloud classification

0 引言

近年来，随着车载激光雷达与无人机技术的快速发展，道路点云的获取变得更加便捷高效，进而推动了道路管理向数字化、智慧化转型。然而，在复杂道路场景中，行道树、路灯等设施常因相互遮挡而导致点云数据残缺，且缺损区域形态不规则，使得传统分类方法难以准确识别目标类型[1]。此外，实际巡检中获取的点云往往残缺不全，从而导致分类的难度上升。因此，如何对复杂道路设施的点云进行分类已经成为提升道路设施自动化管理效率的关键难题。目前，道路设施点云分类研究主要围绕传统特征识别与深度学习方法展开。胡舒[2]基于车载 LiDAR 点云对城市道路两侧典型地物进行分类，但未验证模型对缺损数据的适应性；李佳佳[3]提出了一种基于深度学习的杆状地物分类方法，但场景单一，未覆盖垃圾桶、行道树等多类别目标；普东东[4]通过随机采样增强了数据多样性，但未解决真实遮挡逻辑下的分类难题；龙安洋[5]基于几何特征和区域生长算法实现了道路目标分类，但该算法对遮挡场景适用性较差。总体而言，现有方法多采用公用数据集进行分析，设施分布情况较为理想化，且所用方法难以适配现实道路的复杂情况，对于存在遮挡和局部缺损形态的点云的分类能力仍显不足。鉴于此，本文提出了一种基于 PointNet＋＋算法的道路设施双形态点云分类方法。通过无人机与手持三维扫描仪两种方式获取原始点云数据，构建了涵盖行道树、路灯、垃圾桶及标识牌等典型设施的点云数据集，将其中 90％的完整点云当作训练集、将剩余 10％的完整点云与残缺点云作为测试集进行训练和测试，以探究该方法训练的模型对双形态点云的分类能力。

1 PointNet＋＋算法的架构与功能

1.1 网络整体架构

PointNet＋＋算法是一种层级化点云处理框架，其分类与分割网络基于共享的编码器结构，网络架构如图 1 所示。

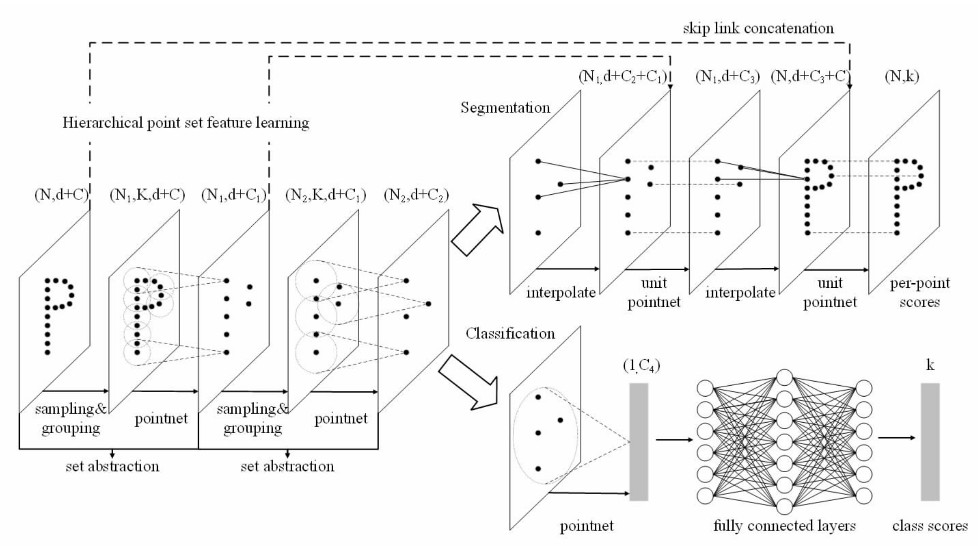

图 1 PointNet＋＋算法网络架构

编码器由多个 Set Abstraction 层构成，依次执行最远点采样、球形邻域构建和局部特征聚合（PointNet＋＋算法最大池化），每级输出关键点数量递减（如 1024→512→128→1），特

征维度递增(如 128→256→512→1024),通过全局最大池化生成设施的整体描述向量[6]。

分类网络由全连接层与 Dropout 组成,直接将全局特征映射至类别概率;分割网络在编码器后接层级化特征传播解码器,通过上采样逐步恢复点云密度与细节,最终针对每个点拼接其多层级特征(高层语义+底层几何),并通过共享 MLP 输出逐点分类结果。

1.2　Set Abstraction 层

Set Abstraction(集合抽象层)是 PointNet++算法的核心模块,用于逐层提取点云的多尺度局部特征,并通过层级聚合构建全局语义。表 1 为该模块的核心步骤与作用。

表 1　Set Abstraction 核心步骤与作用

核心步骤	技术细节	作用
采样(Sampling)	使用最远点采样,从输入点云中选取 N 个中心点	最大程度保留基本特征的情况下降低点云密度
分组(Grouping)	针对每个中心点搜索领域点组成组	构建局部点集
特征提取(Feature Extraction)	针对每个组使用 MLP+最大池化,生成局部特征向量	获取局部几何信息

注:不同的 Set Abstraction 层负责处理不同的任务。

1.3　最远点采样

为了减少特征损失,每个局部区域中心点的采样采用了最远点采样方式,即假设有一个点的集合$\{A_1, A_2, A_3, \cdots, A_n\}$,则选取彼此距离最远的 k 个点。如图 2 所示,假设有 7 个点 P_0-P_6。首先,初始化第一个点为 P_0,则距离 P_0 的最远点为 P_6,并得到最远点的点集为$\{P_0, P_6\}$。其次,选取第三个点:先取图 2 中剩余点到 P_0 和 P_6 的最小值,再取这些最小值里面的最大值,然后确定第三个点。最后,重复第二个步骤,直到完成 k 个点选取。这样的采样方式叫做最远点采样,可以很大程度上保留特征,并尽可能保证采样的局部区域重合度最小[7]。

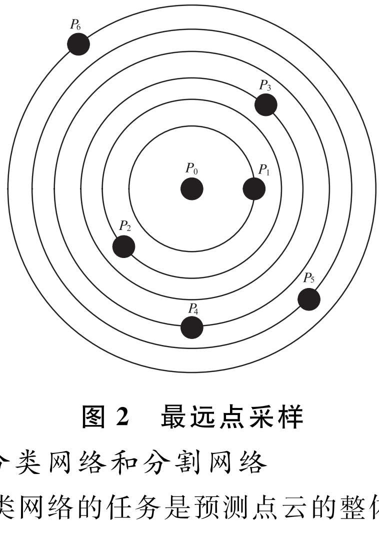

图 2　最远点采样

1.4　分类网络和分割网络

分类网络的任务是预测点云的整体类别标签,其流程是,先通过多层 Set Abstraction 模块对输入点云进行特征提取,直至最后一层 Set Abstraction 输出的全局特征(如 1×1 024 维向量)通过全连接层映射到类别空间(如输出 40 维向量对应 ModelNet40 的 40 类),再经过 Softmax 函数转换为类别概率,输出结果为单个标签的概率分布[8]。

分割网络的目标是对点云中每个点赋予语义标签。其前半部分与分类网络共享编码器流程,后半部分通过特征传播(FP)层进行上采样,并融合编码器中的跳跃连接特征以恢复细节[9]。最终,解码器输出的特征经过逐点 MLP(将每个点的特征映射到类别维度)生成逐点概率矩阵,输出结果为每个点的类别标签。

这两种网络的主要差异在于:分类网络聚焦全局特征聚合,输出单一标签;分割网络依赖局部特征融合,输出密集的逐点预测。实际应用中,分类网络用于物体识别,分割网络则用于精细结构分析。

2　数据集构建

区别于现有该研究方向的大多数成果,本文采用自建数据集,旨在验证 PointNet++算法在自建数据集中的识别精度。从数据采集到数据集构建的整个流程如图 3 所示。

本文数据由无人机倾斜摄影与手持三维扫

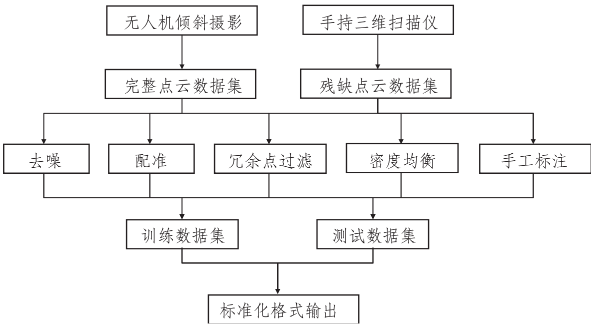

图 3 数据集构建

描仪采集，对获取的原始数据进行如图 3 所示的预处理。经点云标注等步骤后，为验证本文的研究思路，将处理好的完整点云数据集按照 9∶1 分为训练集和测试集，将残缺点云数据集全部作为测试集，最后参考 S3DIS 数据集的格式进行格式输出。部分完整点云数据和残缺点云数据如图 4 和图 5 所示。

图 4 完整点云数据

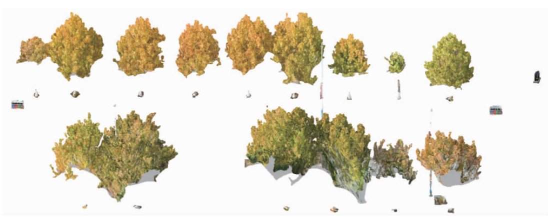

图 5 残缺点云数据

3 实验与分析

3.1 实验环境

实验硬件平台采用 Intel Core i7-12700H CPU，NVIDIA RTX 3060 GPU(6 GB 显存)及 16 GB DDR4 内存。软件环境搭载 Windows 11 系统，基于 PyTorch 2.4.1 深度学习框架与 CUDA 12.4 并行计算架构，配合 Python 3.12 开发环境进行本次实验。通过预实验验证后，将训练板块的超参数设置为：初始化学习率为 0.001 5，批处理尺寸为 16(受限于显存容量)，学习率衰减为 0.7，最大训练轮次设定为 100。

3.2 精度评价

精度评价指标是衡量模型性能的重要工具，常用于评估其在特定任务上的有效性。在分类任务中，精度(Precision)、召回率(Recall)和 F_1 值(F_1-score)是常用的指标[10]。

根据上述指标分别对完整点云和残缺点云分类精度进行评估。具体数据如表 2 和表 3 所示。

对表 2 中各项指标进行分析可知，本文对完整点云数据集进行分类的三项指标均较高，只有方形路牌和圆形路牌的分类精度较低于其他类别的点云分类精度，但仍能满足后续的智慧道路应用。

对表 3 中各项指标进行分析可知，自建数据集数据获取的局限性使得残缺点云集中缺失方形路牌、圆形路牌这两类设施点云，仅对剩余的 5 类设施点云进行了分类，通过数据可以看出，整体分类精度虽较完整点云集的分类精度低，但仍保持在 90% 以上的精度水平，足以明确区分各类设施点云。

表 2 完整点云集识别精度 %

指标	路灯	标识牌	方形路牌	圆形路牌	旧垃圾桶	新垃圾桶	树木
精度	99.58	99.29	73.31	83.56	99.95	99.98	99.99
召回率	97.11	99.56	98.31	99.19	99.99	99.80	100.00
F_1 值	98.33	99.42	83.99	90.71	99.97	99.89	99.99

表 3 残缺点云集识别精度 %

指标	路灯	标识牌	旧垃圾桶	新垃圾桶	树木
精度	92.32	93.35	95.65	92.58	94.52
召回率	98.15	90.77	93.38	89.54	92.17
F_1 值	95.15	92.04	94.50	91.03	93.33

3.3 可视化分析

图 6 和图 7 分别从整体和局部对完整点云的分类情况进行了可视化，整体而言分类精度较高，包括对新旧两种形态的垃圾桶和两种不同形状的路牌以及标识牌均能正确区分，且无

明显错分、漏分现象，而且对绝大多数互相遮挡的树木和路灯点云均能进行正确分类。细节上，从图 7 可以看出部分路灯灯头的少许点云被错分成了树木类，这可能与特征学习不充分抑或两者存在相似特征有关，后续还需完善细节，提高路灯灯头的分类精度。

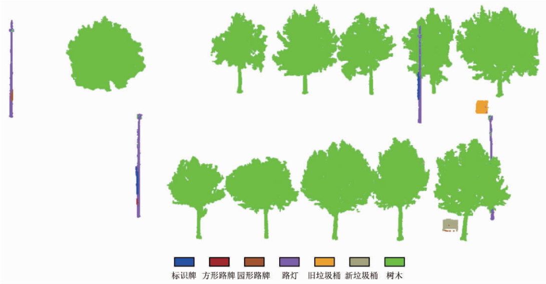

图 6　完整点云整体分类图

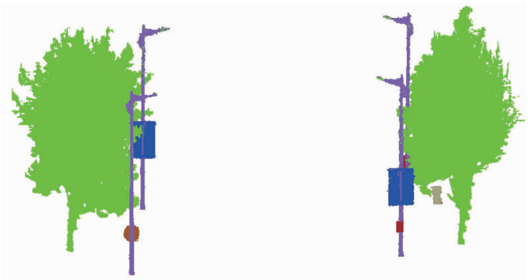

图 7　完整点云细节分类图

图 8 和图 9 是模型对残缺点云进行分类后的可视化结果，从中可以看出多数设施点云存在缺损。尽管如此，该模型仍能在较大程度上将点云所属的类别进行正确分类，并没有因为点云的残缺而出现大量的错分现象，但总体分类精度低于完整点云，如树木出现了错分现象，树冠部分出现了零散点云被错分成路灯的情况，这应该也是与特征学习不完善有关，后续还需改进算法。此外，由于树木点云体量较大，因此这种极少量的错分现象不会影响树木点云的整体分类。

4　结论

基于无人机倾斜摄影与手持三维扫描技术，构建了道路附属设施的多源点云数据集，并采用 PointNet++深度学习算法开展了点云分类的实证研究。实验结果表明，基于完整点云训练的模型在完整测试集上取得了显著效果：

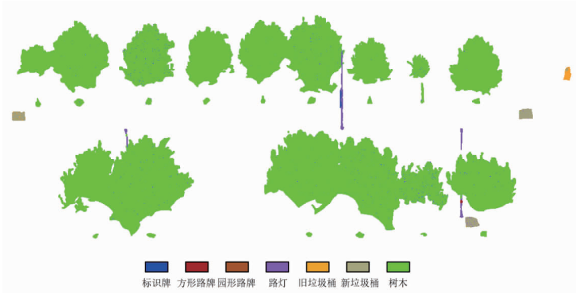

图 8　残缺点云整体分类图

图 9　残缺点云细节分类图

分类准确率平均达到 93.6%，树木、标识牌、路灯及新旧垃圾桶等典型设施的 F_1 值均超过 95%，印证了该算法对复杂空间特征的提取能力；而方形和圆形路牌 80%左右的分类精度则揭示了刚性几何体在点云表征中的固有问题，这可能与视角单一导致特征泛化性不足有关。值得注意的是，模型对无人机获取的残缺点云仍达到了 90%以上的分类精度，特别是对存在局部缺失的路灯、树木等设施表现出强鲁棒性，这为实际巡检中普遍存在的数据不完整问题提供了有效的解决方案。

本研究的创新性体现在两个方面：其一，通过构建包含完整点云和残缺点云双形态的道路设施点云数据集，验证了 PointNet++算法模型在非理想数据条件下的迁移能力；其二，通过验证基于完整点云训练的模型对残缺点云的直接适用性，突破了实际场景中由设施遮挡、数据残缺导致的分类瓶颈，显著降低了高成本、全要素数据采集的需求。然而，受限于自建数据集的规模，现有模型对栅栏、交通信号灯等长尾设施的识别能力尚未得到验证，且方形和圆形路牌的分类精度仍有提升空间。

未来本研究将沿着三个方向展开：一是通过融合多传感器数据（如热成像、高光谱）构建

多维特征空间，以增强相似设施的区分度；二是开发基于注意力机制的特征补偿模块，针对性提升局部残缺区域的表征能力；三是探索对比学习等自监督方法，突破有限标注样本对模型泛化性能的制约。

参考文献：

[1] 潘翔. 基于深度学习的道路场景典型地物分类研究[D]. 焦作：河南理工大学，2023.

[2] 胡舒. 基于车载 LiDAR 点云的城市道路两侧典型地物分类[D]. 武汉：武汉大学，2021.

[3] 李佳佳. 基于深度学习的车载 LiDAR 杆状地物点云分类研究[D]. 焦作：河南理工大学，2022.

[4] 普东东. 基于 LiDAR 点云数据的道路场景分类研究[D]. 南京：南京信息工程大学，2022.

[5] 龙安洋. 基于车载激光点云的道路目标分类方法研究[D]. 广州：华南理工大学，2023.

[6] WANG Y，BAI G，LIU H，et al. A PointNet＋＋model with transformer network for pedicle segmentation[C]//东北大学，中国自动化学会信息物理系统控制与决策专业委员会. 第 34 届中国控制与决策会议论文集(4)，2022：6.

[7] 李松，张安思，伍婕，等. 基于 PointNet＋＋的邻域特征增强点云语义分割方法[J]. 激光杂志，2024，45(7)：174－179.

[8] YOUNGH A S，KYUNGWAHN S，DONGCHEON L. Semantic segmentation and building extraction from airborne LiDAR data with multiple return using PointNet＋＋[J]. Applied sciences，2022，12(4)：1975.

[9] JIA I W，GAO H Y，ZHANG P R，et al. Multispectral LiDAR point cloud classification using SE-PointNet＋＋[J]. Remote sensing，2021，13(13)：2516.

[10] 龚国栋，李耀斌，花向红，等. 一种探讨点云深度学习决策的 PointNet＋＋解析网络[J]. 测绘地理信息，2022，47(6)：50－54.

（责任编校：白丽娟）

（上接第 18 页）

[2] 张智琳，王家富，李国兴. 基于 V 型开发模式的 FSAE 赛车传动系统开发[J]. 汽车实用技术，2024，49(1)：75－80.

[3] 王迅佳. 构建针对车载汽车电子控制装置的硬件在环仿真测试平台[D]. 上海：上海交通大学，2012.

[4] CURIEL-RAMIREZ A L，RAMIREZ-MENDOZA A R，IZQUIERDO-REYES J，et al. Hardware in the loop framework proposal for a semi-autonomous car architecture in a closed route environment[J]. International journal on interactive design and manufacturing (IJIDeM)，2019，13(4)：1647－1658.

[5] TRAPH NER P，OLMA S，KOHLSTEDT A，et al. Hardware-in-the-Loop simulation for a multiaxial suspension test rig with a nonlinear spatial vehicle dynamics model[J]. IFAC papers on-line，2019，52(15)：109－114.

[6] 易高. 基于驾驶模拟器汽车电子稳定程序的硬件在环仿真系统[D]. 长沙：湖南大学，2007.

[7] 黄胜龙. 汽车发动机 ECU 的自动化 HIL 仿真测试平台的研究与实现[D]. 长春：吉林大学，2013.

[8] 刘灵. 硬件在环(HIL)技术在动力集成开发中的应用研究[J]. 汽车零部件，2018(8)：84－87.

[9] 陈元平. 浅谈电动挖掘机数字化施工技术原理与应用[J]. 工程机械与维修，2023(4)：47－49.

[10] 刘宏波. 基于 CANoe 的车身网络通信设计[J]. 机电工程技术，2012，41(2)：1－4.

（责任编校：白丽娟）