

DOI:10.3969/j.issn.1003-5060.2026.02.019

结合深度学习和 K-Means 的行道树提取及单木分割研究

史志飞¹, 高飞¹, 袁斌², 吴言安², 张树峰², 谢荣晖²

(1. 合肥工业大学 土木与水利工程学院, 安徽 合肥 230009; 2. 安徽开源路桥有限责任公司, 安徽 合肥 230093)

摘要:针对目前城市道路场景中行道树提取方法需要设置的参数较多以及树冠点云相互重叠难以精确分割的问题,文章采用一种行道树提取与单株木分割算法。首先通过布料滤波算法从原始点云中移除地面点,并利用半径滤波滤除离群点,去除地面点和噪声点对行道树提取的影响;然后通过增加 PointNet++ 网络的点集抽象模块(set abstraction, SA)提高模型特征提取能力,使模型更适用于行道树点云的提取,并利用改进后的网络从原始点云中提取行道树点云;最后结合密度聚类算法(density-based spatial clustering of applications with noise, DBSCAN)与 K-Means 算法对相互重叠的行道树点云进行分割,得到单株木信息。为验证该方法的有效性,以北京永昌路道路数据集进行训练测试。结果表明:改进后模型的行道树点云平均提取精度和交并比(intersection over union, IoU)分别提高了 9.2% 和 15.1%,达到了 94.5%、0.916;单木分割平均精度达到了 91.3%。

关键词:车载激光点云;行道树提取;单木分割;PointNet++;K-Means

中图分类号:P237;U495

文献标志码:A

文章编号:1003-5060(2026)02-0260-08

Method of street tree extraction and single wood segmentation by deep learning and K-Means

SHI Zhifei¹, GAO Fei¹, YUAN Bin², WU Yan'an², ZHANG Shufeng², XIE Ronghui²

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China; 2. Anhui Kaiyuan Highway and Bridge Co., Ltd., Hefei 230093, China)

Abstract: A street tree extraction and single wood segmentation algorithm is used to address the issues of multiple parameters that need to be set for street tree extraction methods in urban road scenes, as well as the difficulty in accurately segmenting overlapping tree crown point clouds. Firstly, ground points are removed from the original point clouds using cloth simulation filtering algorithm, and outliers are filtered using radius filtering to remove the influence of ground points and noise points on the extraction of street trees. Then, by adding the set abstraction(SA) module of PointNet++ network, the feature extraction ability of the model is improved, making it more suitable for extracting street tree point clouds. The improved network is used to extract street tree point clouds from the original point clouds. Finally, the density-based spatial clustering of applications with noise(DBSCAN) and K-Means algorithms are combined to segment overlapping street tree point clouds and obtain single wood information. To verify the effectiveness of this method, training tests were conducted on the Yongchang Road dataset in Beijing. The experimental results show that the average extraction accuracy and intersection over union(IoU) of the im-

收稿日期:2023-09-08; **修回日期:**2023-10-24

基金项目:国家自然科学基金资助项目(42204052);安徽省自然科学基金资助项目(2008085MD115)

作者简介:史志飞(1999—),男,安徽舒城人,合肥工业大学硕士生;

高飞(1962—),男,安徽天长人,合肥工业大学教授,博士生导师,通信作者, E-mail: gaofei@hfut.edu.cn;

袁斌(1969—),男,安徽望江人,安徽开源路桥有限责任公司正高级工程师。

proved model for street tree point clouds increase by 9.2% and 15.1%, respectively, reaching 94.5% and 0.916; the average accuracy of single wood segmentation reaches 91.3%.

Key words: vehicle-borne laser point cloud; street tree extraction; single wood segmentation; PointNet++; K-Means

0 引 言

行道树是道路绿化的重要组成部分,具有降低路面噪音、净化城市空气、增加城市绿化率、补充氧气、吸收二氧化碳、遮阴避日、缓解司机视觉疲劳等多种功能。行道树的提取在城市绿化和数字化管理方面具有重要意义,但传统人工测量方式效率低。近年来,遥感和摄影测量设备在包括树木在内的目标检测和评估中发挥了关键作用。这是由于各种有价值的工具(如合成孔径雷达、激光雷达等设备)可以有效地安装在各种遥感平台上(如机载、无人机、汽车甚至背包)。随着车载激光扫描技术快速发展,该技术能高效精确地获取道路及其周围地物的三维坐标、回波强度、入射角以及颜色等信息,为获取道路两侧行道树信息提供了新方法。

目前对点云数据中行道树的提取研究主要分为 4 类。① 基于聚类的方法:文献[1]根据高程信息将树木点云切片并利用 DBSCAN(density-based spatial clustering of applications with noise)算法对切片的点云进行聚类,结合地物形态特征识别树干中心点,通过中心点圆形索引获取单株木信息;文献[2]对地面点构建规则数字高程模型(digital elevation model, DEM),并在其基础上滤除低矮地物点(如草坪、绿化带、车辆等),再通过欧几里得聚类算法提取行道树点云。② 基于构建模板的方法:文献[3]根据杆状地物的表达特征构建模型,在模型和语义规则的约束下得到候选杆状点云,并基于最小二乘判别方法对候选杆状点云进行判别分析。③ 基于机器学习的方法:文献[4]首先通过数学形态学滤波滤除地面点,然后使用纵向网格模板初步提取杆状地物,最后根据预先训练好的支持向量机(support vector machine, SVM)模型对提取的杆状地物进行分类识别。④ 基于深度学习的方法:文献[5]提出一种用于城市区域目标提取的 PointNet++ 算法,其中包括 1 棵树,该算法的树检测准确率约为 84.7%;文献[6]基于多方向生成目标点云的二值图像,并展成二值向量描述目标对象的特征,然后构建训练深度信念网络对路侧目标进行

提取实验,行道树的提取精度达到了 97.31%。

由上述研究分析可知,当前基于车载激光点云提取行道树主要存在以下问题:① 问题 A 为提高提取精度,需要设置多个阈值来对数据进行约束,进行多次交互,效率较低;② 问题 B 对行道树的独立性要求较高,相邻的重叠行道树点云难以精确分割分类。

首先,通过布料滤波和半径滤波滤除原始点云中的地面点和噪声点,降低数据量的同时减弱地面点和噪声点对后续行道树点云提取的影响。然后,针对问题 A,本文使用 PointNet++ 从预处理后点云中直接提取行道树点云,不需要设置参数。PointNet++ 作为点云深度学习网络,采用一种层次化特征学习,能够很好地提取点云的全局特征与局部特征,分割分类精度较高。但经典 PointNet++ 适合室内小场景点云分割,对大型道路场景点云提取精度较低。因此对 PointNet++ 进行改进,改进部分主要有:① 通过均衡降采样使样本数据中各种类别更加均衡;② 通过增加 PointNet++ 网络的点集抽象模块(set abstraction, SA)提高模型特征提取能力,使模型更适用于大型道路场景下行道树点云的提取。

利用改进后的 PointNet++ 提取到全部行道树点云后,下一步对行道树进行单木分割。但部分行道树点云的树冠相互重叠,难以通过单一的算法进行树木分割。针对问题 B,本文结合 DBSCAN 与 K-Means 算法实现单木分割,首先根据高程信息获取底部树干层点云,利用 DBSCAN 对树干点云进行聚类,探测到树木的棵数以及树木中心位置;然后将树木的棵树、树木中心位置分别初始化 K-Means 聚类的 K 值参数和初始聚类中心,基于初始化参数的 K-Means 对相互重叠的行道树进行分割,得到独立树木信息;最后,以北京市永昌路的车载激光点云数据进行训练测试,验证了本文方法的有效性、可行性。

1 数据预处理

1.1 地面点滤除

车载 LiDAR 点云中,地面是各类地物联系的纽带,各类地物都与地面相连并成为一个整体。

要准确分离出各类地物,需要先移除地面点云,使各地物成为相互独立的个体,便于各地物进行探测和识别,大幅度减少了数据量^[4],加快运行速度。本文通过布料滤波算法^[7-9]确定地面点,该算法的基本原理为:将原始点云翻转,假设有一块布料受重力作用从上方落下,覆盖翻转后的点云数据,最终落下的布料即可认为是地面。

1.2 离群点剔除

车载激光扫描仪采集数据的过程中不可避免地会含有噪声点或离群点等干扰点云,为有效地去除这些噪声,采用半径滤波来剔除离群点,如图 1 所示。半径滤波是一种基于领域点分析的滤波,设定 2 个参数半径 r 和最少领域点数 m ,对于任意点 P ,若其半径 r 领域内的点数小于 m ,则将 P 判定为离群点进行剔除。半径滤波原理如图 1 所示。若 $m=2$ 则绿点作为离群点剔除;若 $m=3$,则绿点和蓝点作为离群点剔除。




图 1 半径滤波离群点剔除

2 基于改进 PointNet++ 的行道树提取

2.1 PointNet++ 模型

PointNet++^[10]是一种稳健的网络架构,用于处理度量空间中的一组采样点。PointNet++在点集的嵌套划分上递归地起作用,并且在学习距离度量的层次特征方面是有效的。层次结构由 4 个点集抽象模块组成。每个点集抽象模块层由采样层、分组层和 PointNet 层组成。PointNet++网络的基本思想是将点集划分为多个相互重叠的局部区域,对这些局部区域应用 PointNet 网络提取局部特征,然后将这些局部特征分组为更大的单元,再提取更高级别的特征。重复此步骤,直到提取到整个点集的所有特征,局部特征提取如图 2 所示。




图 2 局部特征提取

2.2 均衡化采样

PointNet++语义分割模型是针对室内场景进行设计的,待分割目标尺寸较小,各种类别的占比均衡,分割效果较好。在道路语义分割场景中,部分类别点云占比较小,部分类别点云占比较大造成数据的不平衡。不平衡数据集会使模型偏向占比大的类别,导致小类别提取的精度低。针对此问题,本文利用随机采样滤波对训练数据集进行下采样(测试集不变),使训练样本各类别数据更加均衡,并探究在不同样本比例下模型的测试精度和交并比(intersection over union, IoU)。

本文使用经典 PointNet++语义分割模型,在相同的测试样本数据下,对比分析不同样本比例的训练数据对测试结果的影响,测试精度与 IoU 结果如图 3 所示。图 3 中:横坐标表示训练样本数据中非行道树点云数目与行道树点云数目的比值;纵坐标表示测试数据集的行道树提取的平均精度和 IoU。当目标点云与非目标点云的样本比值接近 1:1 时,此时模型的训练效果最好。




图 3 测试精度和 IoU

2.3 改进的 PointNet++ 模型

PointNet++作为点云深度学习网络,采用一种层次化特征学习,能够很好地提取点云的全局特征和局部特征,分割分类精度较高。经典 PointNet++的官方数据集是室内场景数据集 S3DIS,适合室内小场景点云分割,对大型道路场景点云语义分割精度较低。

经典 PointNet++语义分割模型采用 4 个抽象集合模块以及 4 个特征传递模块(feature propagation, FP),其中 SA 模块采样半径分别为

0.1、0.2、0.4、0.8 m。SA 模块的采样半径最大为 0.8 m,该采样半径可以满足室内小场景点云数据的特征提取,但对于行道树等较大的地物,该采样半径难以提取其全局特征,并且大型道路场景点云数据量要远多于室内场景,因此原 PointNet++ 特征提取模块的采样点数不能满足道路这种大场景点云数据的语义分割任务。

针对以上问题,本文在 PointNet++ 网络的基础上增加了 2 层 SA 模块和 FP 模块,增加了网络的深度,使网络特征提取能力更强,也便于平滑地增大采样半径、采样点数^[11-12]。同时,调整了每层 SA 模块的采样点数与采样半径,使网络更加适合道路场景点云数据,模型结构参数对比见表 1 所列。

表 1 模型参数对比

层名	经典 PointNet++ 模型			改进 PointNet++ 模型		
	采样点数	采样半径	特征数	采样点数	采样半径	特征数
SA1	1 024	0.1	64	2 048	0.2	64
SA2	256	0.2	128	1 024	0.4	128
SA3	64	0.4	256	512	0.8	256
SA4	16	0.8	512	256	1.6	512
SA5				128	3.2	1 024
SA6				64	6.4	2 048

由表 1 可知,本文对 PointNet++ 模型的改进主要包括:采样半径变为 0.2、0.4、0.8、1.6、3.2、6.4 m,改进后的采样半径从最小到最大,实现了网络的多尺度特征学习能力;增大每层模型采样点数,使模型能够获取更丰富的特征;将提取的特征数量从 512 增长到 2 048,提高模型的学习效果。

3 单木分割

在车载激光点云中,由于行道树与行道树之间距离过近,树冠点云相互重叠、遮掩,导致难以通过单一的聚类算法进行分割。针对此问题,本文使用了一种结合 DBSCAN 和 K-Means 算法的行道树精细分割算法。


首先根据高程信息获取底部树干层点云,利用 DBSCAN 对树干层进行聚类,根据聚类的数量与每个聚类的中心点位置,探测到树木的棵数与中心位置,对 K-Means 聚类的 K 值和初始聚类中心进行初始化;然后基于初始化参数的 K-

Means 聚类对相互重叠的行道树进行分割,得到独立行道树地物信息。


3.1 基于 DBSCAN 的树干提取

DBSCAN 是经典的基于点云密度聚类的算法,可以发现任意形状类簇,同时也能识别出噪声点^[13-14]。考虑到相邻的行道树之间的树冠相互重叠,而树干相对独立,可以通过提取树干来确定树木的棵数以及每棵树的中心位置。对于大多数行道树,树冠通常位于地面 2 m 以上,为了排除树冠层点云对树干提取的影响,截取行道树高于所在区域地面 1.5 m 以内的树干处点云,并对其进行 DBSCAN 聚类,探测树木的棵数、每棵树的树干点云及其中心位置^[15-16]。交错重叠点云分割如图 4 所示。


图 4b 中:粉色点云为通过高程截取的高于所在区域地面 1.5 m 以内的树干点云,利用 DBSCAN 仅对树干点云进行聚类,可以得到 3 个聚类,即探测到重叠树木的棵数为 3,再计算每个聚类的中心点坐标。



(a) 原始行道树点云



(b) 基于DBSCAN的树干提取



(c) 基于K-Means的分割结果正视图

(d) 基于K-Means的分割结果俯视图

图 4 交错重叠点云分割

3.2 基于初始化参数的 K-Means 单木分割

K-Means 是一种经典的无监督聚类算法,其算法原理是:设置聚类的个数 K ,找出 K 个最优初始聚类中心,将每个点划分到距离最近的聚类中心所代表的类别中,并更新了新的类簇中心,直到所有点都分配到相应的聚类中。 K -Means 算法具有步骤简单易于实现且应用场景广泛等优点,但该算法也存在一定的局限性,如需要预先设置 K 值、对初始类簇中心选择敏感可能造成局部最优等。

针对以上问题,本文根据 3.1 节中的方法,利用 DBSCAN 算法对底部树干点云进行聚类,根据 DBSCAN 聚类的类簇数量、类簇中心来初始化 K -Means 算法的 K 值与初始类簇中心。最后,本文利用初始化参数的 K -Means 算法对相邻行道树进行单木分割,分割结果如

图 4c、图 4d 所示。

4 实验与分析

4.1 实验数据

本文实验环境如下:CPU 为 i5-10200, GPU 为 GTX1650,内存为 16GiB,深度学习框架为 Pytorch。

实验选取北京永昌路某段道路场景数据进行训练测试,点云数据由移动车载激光扫描仪获取,原始道路场景如图 5 所示。

为验证模型的有效性,本文选取了其中 3 段道路数据进行验证分析,每段道路全长为 200~300 m,每段道路包含的点云数据量为 1.5×10^7 左右。选取的道路点云数据中包含了多种不同类型的地物,主要有行道树、车辆、建筑、路灯、公交站等。

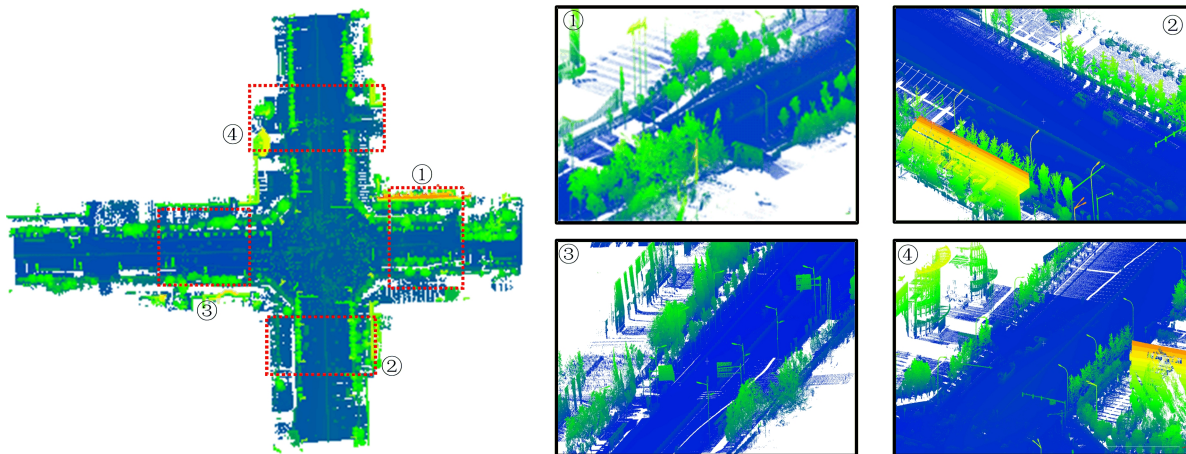


图 5 原始道路场景

4.2 数据预处理

首先采用布料模拟滤波移除地面点云,结合车载道路数据特性,将布料滤波算法的参数设置为:布料分辨率 0.5,最大迭代次数 500,距离阈值 0.2 m。对于点云去噪部分,领域点个数设置为

10,领域半径为 0.1 m。

实验数据 1~3 的原始点云数据和数据预处理结果分别如图 6~图 8 所示。由图 6~图 8 可知,滤波后的点云数据量减少了约 80%,基本能够达到离群点去除效果。




图 6 实验数据 1 和数据预处理结果




图 7 实验数据 2 和数据预处理结果




图 8 实验数据 3 和数据预处理结果

4.3 行道树点云提取

4.3.1 超参数设置


结合道路点云数据的特征及硬件设备条件,经多次实验,超参数设置为:初始学习率 0.001,优化器 Adam,训练轮数 100,批尺寸 16。

4.3.2 模型对比

实验对比了本文改进的 PointNet++ 分割模型与经典 PointNet++ 分割模型对行道树点云的提取效果。训练数据采用均衡化采样处理后的道路场景数据,测试数据不变。行道树点云提

取结果如图 9 所示,其中绿色点云表示提取到的行道树点云。

从图 9 可以看出,PointNet++ 模型将与行道树相邻的建筑、路灯、公交站等地物错误分类为行道树点云,而改进后的模型整体精度更高,错误分割的点云更少,可以满足行道树点云的提取需求,精度和 IoU 结果见表 2 所列。从表 2 可以看出,本文行道树提取模型相比于 PointNet++ 模型的提取精度和 IoU 有了显著地提升,其中 IoU 值平均提升 15.1%、精度平均提升 9.2%。



(a) 道路 1 的 PointNet++ 模型

(b) 道路 1 的本文模型

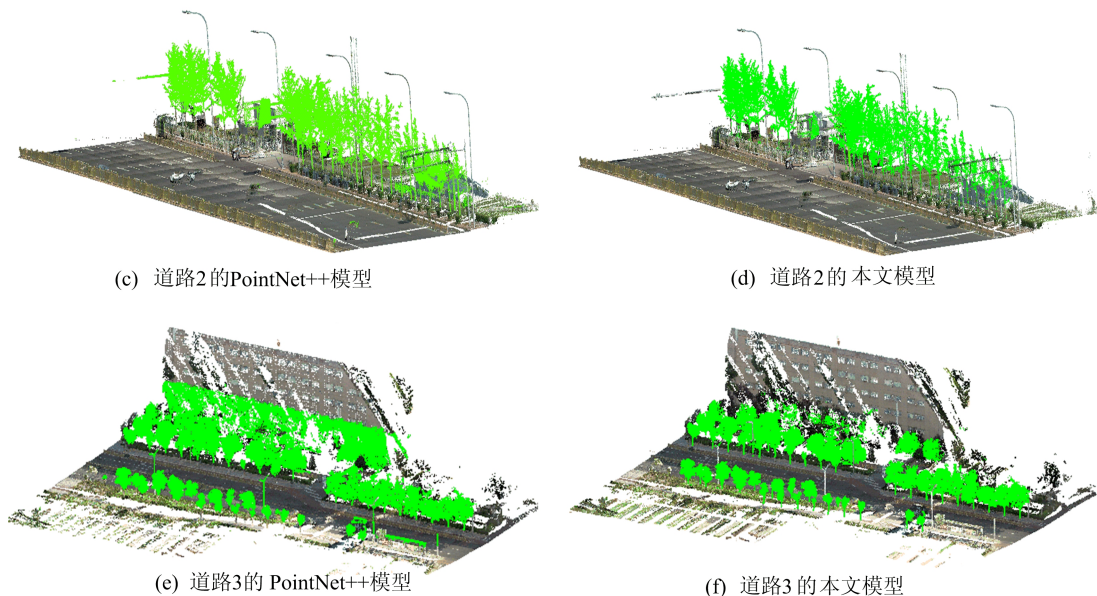


图 9 本文模型与 PointNet++ 分割模型对行道树点云的提取效果对比

表 2 本文模型与 PointNet++ 模型分割精度和 IoU

数据	PointNet++ 模型		本文模型	
	IoU	精度/%	IoU	精度/%
道路 1	0.766	86.2	0.934	97.1
道路 2	0.742	84.4	0.902	92.4
道路 3	0.787	85.5	0.912	94.1

4.4 单木分割

在提取到的行道树点云中,不可避免地存在非行道树点云,首先利用人工去除这些点云,将干扰降到最低。

然后,基于高程信息获取底部树干层点云,截取行道树高于所在区域地面 1.5 m 以内的树干处点云,并对其进行 DBSCAN 聚类。DBSCAN 的聚类半径与最小领域点数分别设置为 0.5 m 和 6。

最后,根据 DBSCAN 的聚类个数与每个聚类的中心点坐标,初始化 K-Means 算法的 K 值与初始聚类中心,单木分割结果如图 10 所示。





图 10 单木分割示意图

对本文方法分割行道树单木效果进行评估,在没有真实的行道树数据前提下,利用人工方式获取每个道路场景下行道树的棵数作为参考,并与本文单木分割算法所分割的树木棵数进行比较,结果见表 3 所列。从表 3 可以看出,本文单木分割算法平均精度达到了 91.3%。

表 3 单木分割精度

道路场景	分割数目	实际数目	精度/%
道路 1	40	43	93.0
道路 2	22	24	91.7
道路 3	49	55	89.1



5 结 论

本文采用一种基于改进 PointNet++ 的行道树语义分割模型和行道树分割算法,实现了对道路两侧行道树的点云提取与分割。首先对道路数据进行数据预处理,基于布料滤波和半径滤波分别滤除地面点和离群噪声点;然后对 PointNet++ 进行改进,通过均衡化采样对训练数据进行预处理,解决样本数据不平衡的问题,对 PointNet++ 模型参数进行调整,提高模型特征提取能力,使模型更适用于道路场景下行道树的提取;其次结合 DBSCAN 和 K-Means 算法实现行道树点云单木的分割;最后通过在自建数据集上进行实验。结果表明,本文模型的测试精度和 IoU 较 PointNet++ 模型分别平均提高 9.2%、15.1%,达到 94.5%、0.916;单木分割平均精度达到了 91.3%,说明本文行道树提取与分割方法具有一定的可行性、有效性。

[参 考 文 献]

- [1] 穆田宝,吴琳娜,张海涛,等. 基于车载 LiDAR 数据的行道树信息提取及安全风险评估[J]. 林业资源管理, 2022, 51(5):91-98.
- [2] 张西童. 车载 LiDAR 点云中路灯与行道树信息提取研究[D]. 焦作:河南理工大学, 2017.
- [3] 李永强,董亚涵,张西童,等. 车载 LiDAR 点云路灯提取方法[J]. 测绘学报, 2018, 47(2):247-259.
- [4] 李永强,李鹏鹏,董亚涵,等. 车载 LiDAR 点云数据中杆状地物自动提取与分类[J]. 测绘学报, 2020, 49(6):724-735.
- [5] HAICHI M, HONGCHAO M, LIANG Z, et al. Extracting urban road footprints from airborne LiDAR point clouds with PointNet++ and two-step post-processing[J]. Remote Sensing, 2022, 14(3):789-812.
- [6] 罗海峰,方莉娜,陈崇成,等. 基于 DBN 的车载激光点云路侧多目标提取[J]. 测绘学报, 2018, 47(2):234-246.
- [7] SHOKRI D, ZABOLI M, DOLATI F, et al. POINTNET++ transfer learning for tree extraction from mobile LiDAR point clouds[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2023, 10: 721-727.
- [8] ZHANG W, QI J, WAN P, et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation[J]. Remote Sensing, 2016, 8(6):501-522.
- [9] 李海亭,肖建华,李艳红,等. 机器学习在车载激光点云分类中的应用研究[J]. 华中师范大学学报(自然科学版), 2015, 49(3):460-464.
- [10] QI C R, YI L, SU H, et al. Pointnet++: Deep hierarchical feature learning on point sets in a metric space[C]//31st Conference on Neural Information Processing Systems. [S. l.: s. n.], 2017:1-5.
- [11] DICKSON M C, BOSMAN A S, MALAN K M. Hybridised loss functions for improved neural network generalisation[C]//Pan-African Artificial Intelligence and Smart Systems Conference. Cham; Springer International Publishing, 2021:169-181.
- [12] OKSUZ K, CAM B C, AKBAS E, et al. Rank & sort loss for object detection and instance segmentation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. [S. l.: s. n.], 2021:3009-3018.
- [13] 牛国臣,王月阳,田一博. 改进密度聚类的激光雷达障碍物检测方法[J]. 北京航空航天大学学报, 2023, 49(10): 2608-2616.
- [14] 孙国强. 车载行道树点云单体化及几何属性提取研究[J]. 测绘通报, 2022(增刊2):189-194.
- [15] 张良. 基于深度学习的行道树识别方法研究[D]. 南京:东南大学, 2019.
- [16] ZHEN Y H, ZHOU X L, SHUANG G J, et al. Street tree extraction and segmentation from mobile LiDAR point clouds based on spatial geometric features of object primitives[J]. Forests, 2022, 13(8):1245-1263.

(责任编辑 吴 亮)