

doi: 10.6046/zrzyyg.2021402

引用格式: 孟琮棠,赵银娣,韩文泉,等. 基于 RandLA - Net 的机载激光雷达点云城市建筑物变化检测[J]. 自然资源遥感, 2022,34(4):113 - 121. (Meng C T,Zhao Y D,Han W Q,et al. RandLA - Net - based detection of urban building change using air-borne LiDAR point clouds[J]. Remote Sensing for Natural Resources,2022,34(4):113 - 121.)

基于 RandLA - Net 的机载激光雷达点云城市建筑物变化检测

孟琮棠¹, 赵银娣¹, 韩文泉², 何晨阳¹, 陈锡秋²

(1. 中国矿业大学环境与测绘学院,徐州 221116; 2. 南京市测绘勘察研究院股份有限公司,南京 210019)

摘要: 利用遥感手段对城市建筑物进行变化检测可以快速准确地获取建筑物覆盖的变化信息,但是单纯基于影像数据难以快速、准确地进行三维变化检测,且传统基于点云的方法自动化程度低、精度差。针对这些问题,文章使用机载激光雷达点云数据,引入 RandLA - Net 的点云语义分割方法,提高变化检测的精度与自动化程度,同时通过点云投影的方式,克服了点云无序性导致的 2 期数据间无法差分的问题。标准 RandLA - Net 算法使用点的位置与颜色信息作为特征,并主要用于街景级点云的语义分割。该研究则使用城市大尺度机载点云数据,结合固有的反射强度与影像赋予点云的光谱信息,探究不同特征信息对结果精度的影响。同时,实验中发现除点云强度和光谱等特征外,点本身的坐标信息同样重要,转化为相对坐标使结果精度提升明显。实验结果表明,使用 RandLA - Net 网络对建筑物提取与变化检测获得的结果明显优于传统方法,且验证了使用深度学习方法处理激光雷达数据进行建筑物提取与变化检测的可行性,可以实现可靠的建筑物三维变化检测。

关键词: 机载激光雷达; 点云; 变化检测; 三维语义分割

中图法分类号: TP 79 **文献标志码:** A **文章编号:** 2097 - 034X(2022)04 - 0113 - 09

0 引言

建筑物是城市中的重要主体,在一定程度上反映了城市的发展规模。准确获取建筑物变化信息对于城市发展规划、非法建筑物识别、灾害评估和地理数据库更新等实际领域中具有重要的作用与意义。利用遥感手段对城市建筑物进行变化检测可以快速准确地获取建筑物的变化信息,借助机载激光雷达(light detection and ranging, LiDAR)点云数据可以实现建筑物的三维变化检测,本文三维变化检测意在获取建筑物在三维空间中面积与高程的变化,包括水平面上的新增、拆除以及高度方向上的增高、降低的变化位置与面积。

多年来,研究者们持续挖掘点云在变化检测中的潜力,并发展出了多种检测建筑物三维变化的方法,如基于 2 期数字表面模型(digital surface model, DSM)差分结果进行人工解译^[1]、直方图统计^[2]、连

通性分析^[3]等确定发生变化的建筑物;或分别对 2 期点云的 DSM 通过边界拟合^[4]、高度与平整度分析后聚类^[5]等方法提取建筑物后,再差分进行变化检测;通过先提取点云中的非地面点,再利用影像与分类树提取建筑物后,与现有地理数据库对比的方法^[6];通过影像数字制图产品与激光雷达(light detection and ranging, LiDAR)点云经过支持向量机(support vector machine, SVM)提取建筑物后对比的方法^[7];使用航空影像密集图像匹配点云与 LiDAR 点云建立差分 DSM 提取变化信息后,再使用点云法线方向方差的方法确定变化的建筑物^[8]。可见在这些方法中,获取变化建筑物主要有 2 种手段:提取建筑物后再检测变化;先确定变化候选区域,再确定属于建筑物的变化。而上述方法存在的问题在于:将点云转换为其他规则格式数据易造成信息丢失,局部点甚至更大尺度点云间的关系被忽略;没有充分利用点的强度和光谱信息特征;自动化程度低,需要较多的后处理分析来改善精度。

收稿日期: 2021 - 11 - 22; 修订日期: 2022 - 04 - 08

基金项目: 南京市测绘勘察研究院股份有限公司科研项目“基于点云与影像的城市典型地物变化检测关键技术研究”(编号: H7P210062)和自然资源部退化及未利用土地整治工程重点实验室开放基金课题(编号: SXDJ2019 - 4)共同资助。

第一作者: 孟琮棠(1997 -),男,硕士研究生,研究方向为遥感数据处理。Email: 07152845@cumt.edu.cn。

通信作者: 赵银娣(1980 -),女,副教授,博士,研究方向为遥感数据处理、模式识别。Email: zhaoyd@cumt.edu.cn。

随着近年来深度学习技术的迅速发展,图像处理算法层出不穷^[9-15],且在遥感影像分类与目标检测等任务中的表现优于多种传统方法^[16-20]。点云语义分割方法同样发展迅速^[21],既有以 PointNet^[22-24]为代表的适用于室内场景点云的语义分割算法,也有适用于大规模点云的 RandLA-Net^[25],但利用深度学习方法进行点云的变化检测却少有研究。

本文采用深度学习与分类后检测的方法研究基于机载 LiDAR 点云的建筑物三维变化检测,与当前主流点云变化检测研究不同的是:①引入基于深度学习的点云语义分割网络 RandLA-Net,快速准确地提取建筑物;②结合本文的建筑物提取方法,设计了针对本文异源点云数据的处理方法,以减少点云间的差异,保证变化检测的精度;③充分考虑局部点间的结构与距离特征,加入 LiDAR 点云的反射强度特征与影像赋予的光谱信息作为语义特征,以提高建筑物提取的准确率。




图 1 LiDAR 点云数据示例
Fig. 1 Examples of LiDAR point cloud data

1.2 数据集制作

2 期点云数据由不同的 LiDAR 传感器获取,其点云的不同主要在于点云密度与反射强度的值域。由于 RandLA-Net 在获取局部点信息时,使用了 K 最邻近(K-nearest neighbor, KNN)算法,并固定了最邻近点的数量,导致在点云密度不同的情况下获取的局部信息存在差异,进而在较小样本上进行训练时,网络损失与精度曲线难以收敛。因此使用稀疏的 2017 年点云进行训练,并对 2019 年点云下采样(图2),使得 2 期点云密度相同,以保证异源数据




图 2 采样后点云结构
Fig. 2 Point cloud structure after sampling

1 研究区数据采集与标注


1.1 研究区概况与数据源

研究使用的机载 LiDAR 点云,与车载 LiDAR 不同之处在于:飞机在一定高度飞行,点云密度较为一致,而车载 LiDAR 主要为获得较近处的点云,点云密度相较于机载雷达高,但远近点云的密度不同,且点云规模较机载点云规模小。选择南京市部分区域为研究区,地理坐标在 N32°2'26"~32°4'8", E118°34'17"~118°36'21"之间。通过航空机载 LiDAR 分别采集研究区 2017 年 3 月 2 日及 2019 年 4 月 6 日的点云数据,获得包含地物位置信息以及反射强度的点云,2017 年与 2019 年点云密度分别为 1 点/m²与 16 点/m²,点数量分别为 10 428 812 与 181 208 261 个点。点云数据示例见图 1。

的语义分割精度,但是,本文使用网格采样的方法,采样后的点云结构同样存在差异,2017 年获取的点云是完全无序的,而 2019 年点云在采样后则存在着一定的有序性,其表现为点云呈网格状排列。其次,2 期点云的反射强度值域不同,2017 年点云值为 1~6 的整数,2019 年点云为 1~65 535 的整数,本文将 2019 年点云强度值线性映射至 2017 年的反射强度值域。

点云数据集基于 MicroStation 的 Terrascan 软件,结合航拍影像判读,对研究区内建筑物点云进行目视解译并人工标注。由于实验用的点云重复区域较多,因此仅将 2017 年点云数据进行数据划分,其中 2 期点云 5% 的区域用于测试,并将 2017 年点云其他部分按 4:1 的比例划分为训练集与验证集,2019 年点云数据不参与训练,仅用于测试。

数据集的格式参考点云语义分割数据集 Semantic3D 格式标准^[26],以方便研究与使用时数据集格式的统一。点云数据集包含有标签、坐标、反射强度和光谱信息,标注后的点云数据集如图 3 所示。



(a) 示例 1 (b) 示例 2 (c) 示例 3 (d) 示例 4 (e) 示例 5

图3 点云数据集示例

Fig. 3 Examples of point cloud dataset

2 研究方法

传统的使用点云数据进行变化检测,往往基于 DSM 差分的方法,依赖于高程与手动调整阈值提取建筑物与其变化信息,忽略了较多的局部信息与点云特征,且自动化程度低,结果易与树木混淆,导致低矮建筑物检测结果不佳。针对这些问题,本文引入基于深度学习方法的 RandLA-Net 点云语义分割网络提取建筑物,利用点云坐标、局部点的位置关系、强度、光谱信息,快速、高精度、自动化地提取建筑物。结合分类后检测的变化检测方案,比较前后时期点云语义分割结果,定性与定量地获得目标区域地物范围与高程的变化。同时,本文还通过实验研究了不同特征的组合对最终结果的影响,提出了不同情况下的应用建议。

点云具有无序性的特点,以及前后时期点云数据密度大多不同,无法实现 2 期点云的分割结果的直接差分进行变化检测。因此本文结合影像差分的思路,将 RandLA-Net 网络提取出的点云建筑物通过正射投影的方式,按照相同的空间分辨率投影为包含建筑物高度信息的灰度影像。投影时根据点云的尺寸以及设定的空间分辨率自动计算点云每点坐标与影像像素坐标的转换公式,获得每点对应的像素坐标,像素值为该像素内所有建筑物点的最大 Z

值,非建筑物目标像素值为0;然后通过2期结果差分前后的状态与差分后的值定性定量地判断建筑物目标在三维空间上的变化。其中,假设前一时期的投影结果对应像素值为 A ,后一时期为 B ,则差分时的评判规则为:若 $B > A$,且 $A = 0$,则该位置为新增建筑物;若 $B > A$,且 $A \neq 0$,则为增高;若 $B < A$,且 $B = 0$,则为拆除;若 $B < A$,且 $B \neq 0$,则为降低;其他情况为无变化。

2.1 RandLA-Net 算法结构

RandLA - Net 结构遵循具有跳跃连接的编码解码思想。其结构如图 4 所示,点云不同于影像在于无法通过卷积核的遍历影像提取特征,因此在点云的语义分割算法中,其基本单元为多层感知机(multilayer perceptron, MLP)。在编码端,点云通过每一层的局部特征聚合(local feature aggregation, LFA)算法丰富与学习点的特征,并使用随机采样(random sampling, RS)减小点云的规模,每次保留 25% 的点云数量,每一层的特征维数为(8, 32, 128, 256, 512)。解码端使用每个点与 KNN 获得最邻近点的线性插值方法进行上采样(up - sampling, US),通过跳跃连接与编码端的特征图叠加,然后输入共享的 MLP 进行特征降维。最后,3 个全连接层(fully connected layers, FC)与 Dropout 层用于预测每个点的类别。




图4 RandLA-Net 整体结构图

Fig. 4 RandLA – Net overall structure

2.2 LFA 算法

LFA 算法是 RandLA-Net 结构的核心,主要由 3 个模块组成,包括局部空间编码(local spatial enco-

ding, LocSE)、注意力池化(attentive pooling) 与扩张残差块(dilated residual block), LFA 的模块结构如图 5 所示。




图 5 LFA 模块结构
Fig.5 LFA module structure

2.2.1 LocSE

LocSE 对输入点云的每一个点与最近邻 K 个点的位置信息使用 MLP 进行编码。利用的信息包括点的位置 p_i , 邻近点的位置 p_i^k , 点与邻近点的相对位置关系 $p_i - p_i^k$ 和它们的欧氏距离 $\|p_i - p_i^k\|$ 。相对点位置编码方式为:

$$r_i^k = MLP[p_i \oplus p_i^k \oplus (p_i - p_i^k) \oplus \|p_i - p_i^k\|] , \quad (1)$$

式中 $\oplus$ 表示两者串联拼接。经过 MLP 编码后的特征数为 d , 并与原始输入的特征叠加。最终的输出是该点 K 个 $2d$ 长度的特征信息。

2.2.2 注意力池化

注意力池化模块用于聚合点的局部特征。LocSE 获得的局部点特征, 经过可学习的 FC 与 Softmax 激活函数获得每个邻近点特征的得分作为输入邻近点特征的权重, 对所有邻近点特征加权求和后获得该点 $2d$ 长度的特征, 在经过 MLP 后, 获得该点最终池化后的特征。

2.2.3 扩张残差块

为了处理大规模的点云, RandLA - Net 采用了随机采样的方法对编码端的点云进行下采样, 因为其具有时间与空间复杂度低的特点, 高效且占用内存小。但是随机采样有几率造成关键点信息的丢失, 因此使用扩张残差块模块对 LocSE、注意力池化与 MLP 进行堆叠, 增加每个点的感受野, 降低随机采样丢失关键点信息的影响。

在扩张残差块中, 将 LocSE 与注意力池化模块进行多次堆叠, 并在每次进行 LocSE 前将点的位置信息加入。同时在输入前与输出后馈入 MLP, 以获得必要的特征数, 并将堆叠后的输出特征与输入点

云经过 MLP 处理后的特征相加, 获得最终的聚合特征。

3 实验与结果分析

3.1 实验环境与各项参数

本文的实验环境为 I5 - 8400 处理器, 内存大小 16 G, NVIDIA GeForce GTX 1080Ti 11 G 显卡, 使用 CUDA 11.0 加速 GPU 计算, 深度学习框架为基于 Python 3.5.6 的 TensorFlow - GPU 1.11.0。实验准备数据采样为 1 点/ m^2 的点云, 模型使用的最邻近点 K 值为 16, 单次输入点数为 40 960, 初始学习率为 0.01, 动量为 0.95, 模型迭代次数为 100。点云的预处理与数据集的制作主要基于 MicroStation 上的 TerraScan 软件, 点云投影影像空间分辨率为 1 m。

3.2 LiDAR 点云建筑物提取

从 LiDAR 点云中准确提取建筑物有着诸多干扰, 首先是低矮建筑物高度往往低于周边的高大树木, 因此在提取过程中, 单纯考虑建筑物的高度常会混淆树木与建筑物的提取结果, 同理, 在地形地势起伏较大的区域, 也存在着这种问题, 因此建筑物中点与点之间的关系信息不能忽略。同时, 在考虑点与点之间关系时, 往往受困于建筑物不同的几何结构, 而人工寻找并定义这些结构费时费力。另一方面, 可以借助 LiDAR 点云的反射强度信息作为辅助信息, 在同一栋建筑物上的反射强度常常具有一致性, 但是不同建筑物仍然会表现不同的强度信息, 甚至与周围地物强度一致, 所以无法单独作为判断的依据。再者, 点云也可以结合影像的光谱信息作为辅助特征, 本文则基于以上信息, 分析了不同方法以及不同特征对建筑物提取以及变化检测结果的影响。

使用 RandLA - Net 结合不同的点云特征提取 2 时期异源点云中的建筑物,并同时使用传统基于 DSM 高程阈值的方法与基于软件 ENVI LiDAR 和 TerraScan 的建筑物提取方法进行了对比。在基于 DSM 的方法中,为了尽可能获得最好的结果,对每一块区域单独设置基于人工判断的高度阈值,包括最低、最高与分段的高度阈值。测试区域选取了 2017—2019 年变化较大的区域,并存在着不同形态的建筑物,如矮于树木的低矮临时建筑物、形状不规

则的楼宇以及常见的小区住宅楼等。为了直观表达建筑物提取结果以及便于精度评价,将点云垂直投影为二维图像,并通过分级色彩表达建筑物的高程信息,如表 1—2 所示。其中,RandLA - Net 代表本文使用的方法;I 代表训练与测试时,除坐标外使用了反射强度信息作为特征;RGB 表示结合了后期赋予点的光谱信息作为特征;IRGB 则表示同时加入了强度信息与光谱信息;C 代表该数据中每一点云块的坐标转换为最小坐标为 0 的相对坐标。

表 1 2017 年点云建筑物提取结果
Tab.1 Point cloud building extraction results in 2017


































区域	点云	真实标签	RandLA - Net IRGB C	RandLA - Net RGB C	RandLA - Net I C	RandLA - Net I	TerraScan	ENVI LiDAR	DSM 高程阈值法	图例
a										高程/m  73 0
b										
c										
d										

表 2 2019 年点云建筑物提取结果
Tab.2 Point cloud building extraction results in 2019

区域	点云	真实标签	RandLA - Net IRGB C	RandLA - Net RGB C	RandLA - Net I C	RandLA - Net I	TerraScan	ENVI LiDAR	DSM 高程阈值法	图例
a										高程/m  73 0
b										
c										
d										

由建筑物提取结果可以看出,使用 RandLA - Net 算法提取建筑物在 2017 年与 2019 年 2 期点云数据上的结果完整度高,漏检与错检的情况少,并且可以很好地区分低矮建筑物与树木,如图 6 所示,其

中深绿色表示建筑物,红色表示树木,对应表 1 第一行结果。尤其坐标转换后的点云建筑物提取精度提升明显。




图 6 低矮建筑物与树木区分
Fig.6 Low buildings and trees

一方面,使用传统方法时,本文未对原始点云进行下采样,由 TerraScan 提取的建筑物在稀疏与密集的点云上表现较为一致,但是目标的边界准确度低,存在着较多的错检情况;而 ENVI LiDAR 的结果受点云密度影响较大,难以有效提取 2017 年点云的建筑物;使用人工 DSM 设置高程阈值的方法简单,且不受点云质量差异的影响,但是高耸的树木与地形的起伏使得在处理时要面对树木与低矮建筑物的取舍,同时,为了避免较多的误差,分区域地设置阈值人工成本高,自动化程度低。

另一方面,在使用 RandLA - Net 算法时,对比

了 4 种情况,考虑到 LiDAR 点云数据普遍带有反射强度信息,且在早期测试中的结果也反映出带有特征的点云比单纯使用坐标信息的结果要好,因此本文并没有单独使用坐标信息。在设置的组合中,最值得注意的是,在同样只使用强度信息作为特征时,将坐标转换为相对坐标带来的提升效果明显,尤其在对低矮建筑物的提取上,使用相对坐标则有着更完整的建筑物个体与更为准确的建筑物边界。基于 RandLA - Net 的结果明显好于其他方法,其误差主要在于建筑物本身上,很少存在将树木或其他地物错分为建筑物的情况。精度对比如表 3 所示。

表 3 建筑物提取方法精度对比
Tab.3 Accuracy comparison of the building extraction method

年份	方法	准确率/%	精准率/%	召回率/%	F1 分数	Kappa 系数
2017 年	RandLA - Net IRGB C	98.52	88.21	97.45	92.60	0.917 8
	RandLA - Net RGB C	98.49	88.83	96.45	92.48	0.916 4
	RandLA - Net I C	98.32	88.15	95.45	91.65	0.907 2
	RandLA - Net I	97.27	92.59	83.23	87.66	0.861 3
	ENVI LiDAR	91.91	24.24	94.24	38.39	0.358 1
	TerraScan	95.76	73.58	83.96	78.43	0.760 9
	DSM 高程阈值法	93.55	88.61	63.85	74.22	0.706 4
2019 年	RandLA - Net IRGB C	98.54	86.10	97.69	91.53	0.907 3
	RandLA - Net RGB C	98.94	90.30	97.93	93.96	0.933 7
	RandLA - Net I C	98.59	86.67	97.72	91.86	0.910 9
	RandLA - Net I	94.26	38.24	97.94	55.00	0.525 7
	ENVI LiDAR	97.93	86.17	90.76	88.41	0.872 7
	TerraScan	94.83	72.68	71.46	72.06	0.692 2
	DSM 高程阈值法	97.29	77.23	91.93	83.94	0.824 7

由表 3 计算出的各项指标可以看出,基于 RandLA - Net 算法获得建筑物区域的各项指标均优于 ENVI LiDAR,TerraScan 以及 DSM 高程阈值的方法。对比不同特征的影响,在 2017 年点云上进行的训练,并同时 2017 年与 2019 年点云进行测试,结

果是: 2017 年点云同时使用反射强度与光谱信息的结果最好,2019 年点云仅使用光谱信息结果最好,2 期点云差异如图 2 所示。因此建议: ①在提取建筑物时,使用格网采样后的 2019 年点云,仅需加入光谱信息。考虑到 LiDAR 传感器大多无法同时获取

光谱信息,或者相机参数未知及相机参数误差较大,无法利用光谱信息的时候,仅使用强度信息同样可以获得很好的结果,不建议同时加入强度和光谱信息;②在处理质量较差的 2017 年点云时,其点云整体无序,则需要更多的特征,此时越丰富的特征带来的效果越好,正如结合了反射强度与光谱信息的 2017 年点云结果最好。

此外,点云差异如第 1.2 节所述,使用点的位置、邻近点的位置、2 点的相对位置关系以及其欧式距离来表达坐标位置的特征。如图 2(b),越是规则的点云其相对位置关系的特征越是一致,这点在 RandLA - Net 原文中也有阐述。这也解释了在 2017 年点云上训练的网络在不同特征组合下,2019

年的结果会比 2017 年结果更好的现象。

3.3 LiDAR 点云建筑物变化检测

点云存在无序性的特点,以及 2 期点云获取的传感器不同导致的密度不同,无法直接使用点云间差分的方法进行变化检测,因此本文的思路是将提取建筑物后的点云投影为二维的灰度影像,使用灰度值表示建筑物目标的高度,投影后的二维影像进行差分获得建筑物的变化情况。变化检测结果如表 4 所示,其中不同颜色表示建筑物变化类型,面积与高度变化检测精度分别为 1 m² 和 1 m,此精度决定于点云的密度。使用混淆矩阵评定建筑物变化检测的精度,如表 5 所示。

表 4 变化检测结果
Tab.4 Change detection results




























区域	真实标签	RandLA - Net IRGB C	RandLA - Net RGB C	RandLA - Net I C	RandLA - Net I	TerraScan	ENVI LiDAR	DSM 高程 阈值法	图例
a									未变化 增高 降低 新建 拆除
b									
c									
d									

表 5 建筑物变化检测结果精度对比
Tab.5 Accuracy comparison of building
change detection results

方法	变化 类型	准确 率/%	精准 率/%	召回 率/%	F1 分数	Kappa 系数
RandLA - Net IRBG C	增高	97.22	70.40	97.65	81.57	0.856 6
	降低		87.23	99.71	93.05	
	新建		87.42	92.07	89.68	
	拆除		77.74	79.05	78.39	
RandLA - Net RBG C	增高	97.61	82.23	97.71	89.30	0.876 9
	降低		88.22	98.52	93.09	
	新建		87.73	93.24	90.40	
	拆除		78.91	84.54	81.63	
RandLA - Net I C	增高	97.10	85.62	98.94	91.80	0.849 2
	降低		91.63	99.54	95.42	
	新建		77.33	90.63	83.45	
	拆除		78.20	82.85	80.46	
RandLA - Net I	增高	91.77	31.10	96.60	47.05	0.606 0
	降低		36.72	100.00	53.72	
	新建		38.85	94.24	55.02	
	拆除		86.21	42.94	57.33	

(续表)						
方法	变化 类型	准确 率/%	精准 率/%	召回 率/%	F1 分数	Kappa 系数
ENVI LiDAR	增高	90.46	11.05	64.22	18.86	0.502 4
	降低		9.61	69.44	16.88	
	新建		79.55	35.58	49.17	
	拆除		30.27	88.06	45.05	
TerraScan	增高	91.67	33.31	80.18	47.07	0.628 9
	降低		21.82	73.95	33.70	
	新建		67.19	36.26	47.10	
	拆除		85.90	65.65	74.42	
DSM 高程阈 值法	增高	91.65	84.08	88.39	86.18	0.642 4
	降低		71.99	100.00	83.71	
	新建		63.90	81.50	71.63	
	拆除		83.83	41.62	55.62	

由变化检测结果与指标的计算结果可知,使用 RandLA - Net 方法获得的结果明显优于传统方法,其中使用光谱信息与相对坐标的点云获得最优的变化检测结果,而不是加入所有的特征。同时,使用相对坐标比使用绝对坐标的变化检测结果精度提升明

显,而且在仅使用强度信息与相对坐标时的结果与最好的结果差异较小,这些与上一阶段提取建筑物结果的结论基本一致。

但是明显的问题是存在 2 期建筑物边界不完全重合的情况,即使在原始数据上也存在着边界的粗差,虽然对指标的计算影响较小,但是在实际应用时仍然有着一定问题。其主要原因在于:原始点云的差异,如图 2 所示的点云结构,使得 2 期点云表达的建筑物存在偏差。面对此种问题的处理可使用形态学的后处理方法,但本文为了表现实验过程中的真实性,并未进行过多的后处理。

4 结论与展望

为了同时实现建筑物的面积与高程定性定量的变化检测,使用机载 LiDAR 点云数据制作建筑物点云语义分割数据集,并基于深度学习方法 RandLA-Net 的点云语义分割网络提取建筑物,利用点云的语义分割结果投影为二维影像并进行分类后检测。本研究得出以下结论:

1)使用的 RandLA-Net 算法在建筑物提取与变化检测上的总体精度优于常用的软件与 DSM 分析的方法。

2)在对点云的数据预处理上,使用相对坐标要比使用绝对坐标结果好。

3)在对点云特征的取舍上,过多的特征会造成冗余,仅使用光谱或强度信息时获得的变化检测结果有时要好于两者结合的结果,结合成本分析,仅使用 LiDAR 点云特有的强度信息是最佳方案。

虽然使用的 RandLA-Net 算法获得了很好的建筑物提取与变化检测效果,但是仍然存在由点云差异而影响建筑物边界精度的问题。本文仅使用了较少的建筑物样本进行训练,且只使用了 2017 年的点云进行训练与验证,在之后的研究中会增加点云中目标的样本,通过上下采样增加点云结构化程度;同时优化算法与数据组成,提高模型在异源点云数据上的泛化能力,改善异源点云数据的变化检测精度;未来会加入点云法向量作为特征,进一步提高点云语义分割的性能。

参考文献 (References):

[1] Murakami H, Nakagawa K, Hasegawa H, et al. Change detection of buildings using an airborne laser scanner [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 1999, 54(2): 148-152.

[2] Vu T, Matsuoka M, Yamazaki F. LiDAR-based change detection of buildings in dense urban areas [C]// *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2004: 3413-

3416.

[3] Pang S, Hu X, Wang Z, et al. Object-based analysis of airborne LiDAR data for building change detection [J]. *Remote Sensing*, 2014, 6(11): 10733-10749.

[4] Pirasteh S, Rashidi P, Rastveis H, et al. Developing an algorithm for buildings extraction and determining changes from airborne LiDAR, and comparing with R-CNN method from drone images [J]. *Remote Sensing*, 2019, 11(11): 1272.

[5] 曾静静, 张晓刚, 王刚. 基于 LiDAR 点云的城区地表变化检测 [J]. *城市勘测*, 2021(2): 92-95.

Zeng J J, Zhang X G, Wang G. Urban land surface change detection based on LiDAR point cloud [J]. *Urban Geotechnical Investigation and Surveying*, 2021(2): 92-95.

[6] Matikainen L, Hyypä J, Ahokas E, et al. Automatic detection of buildings and changes in buildings for updating of maps [J]. *Remote Sensing*, 2010, 2(5): 1217-1248.

[7] Malpica J A, Alonso M C. Urban changes with satellite imagery and LiDAR data [J]. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science*, 2010, 38(8): 853-858.

[8] Du S, Zhang Y, Qin R, et al. Building change detection using old aerial images and new LiDAR data [J]. *Remote Sensing*, 2016, 8(12): 1030.

[9] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.

[10] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J/OL]. *arXiv*, 2014(2015-04-10) [2022-10/15]. <https://arxiv.org/abs/1409.1556>.

[11] Badrinarayanan V, Kendall A, Cipolla R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.

[12] 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.

[13] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation [C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2015: 234-241.

[14] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 39(6): 1137-1149.

[15] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 2117-2125.

[16] 谢奇芳, 姚国清, 张猛. 基于 Faster R-CNN 的高分辨率图像目标检测技术 [J]. *国土资源遥感*, 2019, 31(2): 38-43. doi: 10.6046/gtzyyg.2019.02.06.

Xie Q F, Yao G Q, Zhang M. Research on high resolution image object detection technology based on Faster R-CNN [J]. *Remote Sensing for Land and Resources*, 2019, 31(2): 38-43. doi: 10.6046/gtzyyg.2019.02.06.

[17] 武宇, 张俊, 李屹旭, 等. 基于改进 U-Net 的建筑物集群识别研究 [J]. *国土资源遥感*, 2021, 33(2): 48-54. doi: 10.6046/gtzyyg.2020278.

Wu Y,Zhang J,Li Y X,et al. Research on building cluster identification based on improved U - Net[J]. Remote Sensing for Land and Resources, 2021, 33 (2): 48 - 54. doi: 10. 6046/gtzyyg. 2020278.

[18] 卢 麒,秦 军,姚雪东,等. 基于多层次感知网络的 GF - 2 遥感影像建筑物提取[J]. 国土资源遥感,2021,33 (2): 75 - 84. doi:10. 6046/gtzyyg. 2020289.

Lu Q,Qin J,Yao X D,et al. Buildings extraction of GF - 2 remote sensing image based on multi - layer perception network[J]. Remote Sensing for Land and Resources,2021,33 (2): 75 - 84. doi: 10. 6046/gtzyyg. 2020289.

[19] 刘文雅,岳安志,季 钰,等. 基于 DeepLabv3+ 语义分割模型的 GF - 2 影像城市绿地提取[J]. 国土资源遥感,2020,32 (2): 120 - 129. doi:10. 6046/gtzyyg. 2020. 02. 16.

Liu W Y,Yue A Z, Ji Y,et al. Urban green space extraction from GF - 2 remote sensing image based on DeepLabv3+ semantic segmentation model [J]. Remote Sensing for Land and Resources, 2020,32 (2): 120 - 129. doi:10. 6046/gtzyyg. 2020. 02. 16.

[20] 安健健,孟庆岩,胡 蝶,等. 基于 Faster R - CNN 的火电厂冷却塔检测及工作状态判定[J]. 国土资源遥感,2021,33 (2): 93 - 99. doi:10. 6046/gtzyyg. 2020184.

An J J,Meng Q Y,Hu D,et al. The detection and determination of the working state of cooling tower in the thermal power plant based on Faster R - CNN[J]. Remote Sensing for Land and Resources, 2021,33 (2): 93 - 99. doi:10. 6046/gtzyyg. 2020184.

[21] Guo Y,Wang H,Hu Q,et al. Deep learning for 3D point clouds: A survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2020,43 (12): 4338 - 4364.

[22] 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.

[23] Wu B,Wan A,Yue X,et al. Squeezeseg: Convolutional neural nets with recurrent CRF for real - time road - object segmentation from 3D LiDAR point cloud[C]// 2018 IEEE International Conference on Robotics and Automation (ICRA), 2018: 1887 - 1893.

[24] Thomas H,Qi C R,Deschaud J E,et al. Kpconv: Flexible and deformable convolution for point clouds [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6411 - 6420.

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

[26] Hackel T,Savinov N,Ladicky L,et al. Semantic3d. net: A new large - scale point cloud classification benchmark[J/OL]. arXiv, 2017 (2017 - 04 - 12) [2022 - 10 / 15]. <https://arxiv.org/abs/1704.03847>.

RandLA - Net - based detection of urban building change using airborne LiDAR point clouds

MENG Congtang¹, ZHAO Yindi¹, HAN Wenquan², HE Chenyang¹, CHEN Xiqiu²

(1. School of Environment Science and Spatial Informatics, China University of Mining and Technology, Xuzhou 221116, China;
2. Nanjing Insititute of Surveying, Mapping and Geotechnical Investigation Co. Ltd., Nanjing 210019, China)

Abstract: Using remote sensing to detect changes in urban buildings can obtain the change information of building coverage quickly and accurately. However, it is difficult to detect 3D changes quickly and accurately based on image data alone. Moreover, conventional point cloud - based methods have low automation and poor precision. To address these problems, this study used the airborne LiDAR point clouds and employed the RandLA - Net's point cloud semantic segmentation method to improve the accuracy and automation of change detection. Meanwhile, the failure in differentiating two - period data due to point cloud disorder was overcome through point cloud projection. The standard RandLA - Net method, with the location and color information of points as features, is mainly used for semantic segmentation of street - level point clouds. In this study, urban large - scale airborne point clouds combined with the inherent reflection intensity and the spectral information of point clouds given by images were used to explore the influence of different feature information on the precision of the results. Furthermore, it was found that in addition to the point cloud intensity and spectral features, the coordinate information of points is equally important and can be converted into relative coordinates to significantly improve the result precision. The experimental findings show that the results obtained using RandLA - Net are significantly better than those using conventional methods for building extraction and change detection. This study also verified the feasibility of using deep learning methods to process LiDAR data for building extraction and change detection, which can realize reliable 3D building change detection.

Keywords: airborne LiDAR; point cloud; change detection; 3D semantic segmentation

(责任编辑: 陈 理)