

融合光谱信息的机载 LiDAR 点云三维深度学习分类方法

王宏涛, 雷相达*, 赵宗泽

河南理工大学测绘与国土信息工程学院, 河南 焦作 454000

摘要 针对传统二维深度学习无法实现三维点云分类问题, 提出一种融合光谱信息的机载 LiDAR 点云三维深度学习分类方法。该方法首先融合机载 LiDAR 点云和多光谱航空影像进行点云光谱信息扩充, 进而在点云格网化和数据增强处理的基础上, 采用多层感知机提取出不同尺度下的点特征和全局特征, 最后基于三维深度学习算法实现机载 LiDAR 点云的准确分类。利用国际摄影测量与遥感协会提供的数据集进行所提方法验证, 结果表明, 融合光谱信息后, 机载 LiDAR 点云分类精度提高了 13.39 个百分点; 与已有方法的对比结果也进一步表明, 所提方法可以在减少特征向量提取的情况下, 取得较好的分类结果。

关键词 遥感; 机载 LiDAR; 多光谱影像; 数据融合; PointNet; 点云分类

中图分类号 P237

文献标志码 A

doi: 10.3788/LOP57.122802

3D Deep Learning Classification Method for Airborne LiDAR Point Clouds Fusing Spectral Information

Wang Hongtao, Lei Xiangda*, Zhao Zongze

School of Surveying and Land Information Engineering, Henan Polytechnic University, Jiaozuo, Henan 454000, China

Abstract Aiming at the problem that the traditional 2D deep learning method can not realize the 3D point cloud classification, this study proposes a novel classification method for airborne LiDAR point clouds based on 3D deep learning. First, airborne LiDAR point clouds and multi-spectral imagery are fused to expand the spectral information of point clouds. Then, 3D point clouds are placed on grids to make the LiDAR data suitable for the 3D deep learning. Subsequently, the local and global features in different scales are extracted by multi-layer perceptron. Finally, airborne LiDAR point clouds are classified into semantic objects using the 3D deep learning algorithm. The data sets provided by the International Society of Photogrammetry and Remote Sensing (ISPRS) are used to validate the proposed method, and the experimental results show that the classification accuracy can be increased by 13.39% by fusing the LiDAR point clouds and multi-spectral images. Compared with some of the methods submitted to ISPRS, the proposed method achieves better performance by simplifying the process of feature extraction.

Key words remote sensing; airborne LiDAR; multi-spectral imagery; data fusion; PointNet; point cloud classification

OCIS codes 280.3640; 100.4996; 100.6890

1 引言

现代城市正在由数字城市向智慧城市转变^[1], 传统的二维数据已经不能满足人们对真实三维空间

认知的需求。机载激光雷达 (LiDAR) 能够直接获取各种地物的三维空间信息, 在测绘、林业、电力等行业得到了广泛应用。然而, 从离散、不规则分布且包含有噪声的机载 LiDAR 点云数据中, 准确且自

收稿日期: 2019-09-26; 修回日期: 2019-10-24; 录用日期: 2019-10-29

基金项目: 河南省自然科学基金面上项目 (182300410115)、河南省科技攻关项目 (172102310350)、河南理工大学博士基金 (B2017-13)、河南理工大学基本科研业务费专项 (NSFRF170908)、河南理工大学青年骨干教师资助计划 (2018XQG-06)

* E-mail: 211804010013@home.hpu.edu.cn

动地分类和解译出各种典型地物目标仍有较大的难度,成为近些年来研究热点之一。

目前,针对点云数据进行分类的主要方法是传统的机器学习方法,该方法首先提取分类对象的特征,然后基于特征向量构建相应的判别模型,最后基于判别模型进行分类。如 Zhang 等^[2]使用支持向量机(SVM)对 LiDAR 数据进行分类,何曼芸等^[3]使用随机森林(RF)对城区 LiDAR 数据进行分类,而 Niemeyer 等^[4]则采用一种基于条件随机场(CRF)的上下文分类方法实现 LiDAR 点云分类。上述方法需要人工提取点云数据的各种特征,对于数据量较大的机载 LiDAR 数据提取,存在计算时间较长和特征表达受限的问题。为了解决上述问题,学者们开始研究基于深度学习的点云分类方法。该方法通过级联神经网络逐层抽象得到特征,不需要人工提取特征,可以在提高运算效率的同时,取得比传统机器学习方法更好的效果^[5]。早期基于深度学习的方法侧重于将点云处理成非点云的形式进行训练,例如:Yi 等^[6-7]从三维物体的不同视角生成二维图片,然后利用卷积神经网络进行三维点云分类;Maturana 等^[8-9]对三维点云进行体素化,再通过神经网络训练完成分类。这种分类方法会造成原始数据特征损失,同时产生一定程度的数据冗余。近些年来,基于点云数据的三维深度学习方法开始出现并受到了一定程度的关注,例如斯坦福大学的 Charles 等^[10]提出了 PointNet 框架。PointNet 是一个可以直接对三维点云进行训练的深度学习框架,它可以充分利用点云的数据特性,降低网络计算的复杂度^[11]。赵中阳等^[12]研究了基于 PointNet 的机载 LiDAR 点云数据分类方法,但是由于点云数据分布具有稀疏性和不规则性,且缺少其他辅助信息的有效支持,分类结果的精度仍有待提高。

针对上述问题,本文提出一种融合光谱信息的机载 LiDAR 点云三维深度学习分类方法。该方法首先利用多光谱航空影像来扩充点云的光谱信息,然后采用多层感知机提取出多尺度的点特征和全局特征,最后基于 PointNet 三维深度学习框架实现机载 LiDAR 点云的准确分类。

2 三维深度学习分类算法

为将传统深度学习方法应用于三维点云分类,多数学者通常将点云处理成二维图像或者进行体素化用于训练和分类。在此过程中,将三维数据投影为二维数据时会出现原始数据特征丢失,点云体素化则会

造成一定的数据冗余。为了解决这些问题,Charles 等^[10]提出了一种直接对三维点云进行训练和分类的深度学习框架 PointNet,并采用如下策略来保证 PointNet 框架能够直接对三维点云进行分类:1)使用规范化操作保证点云旋转不变性;2)使用最大池化操作来避免点云无序性;3)使用点特征和全局特征串联的方式进行信息聚合,以增加点云的空间关系描述。

点云旋转不变性是指点云数据发生旋转或平移时,其分类输出结果保持不变。PointNet 从输入数据中学习特征空间维度一致的变换矩阵,然后将变换矩阵与原始数据相乘,实现对输入特征空间的规范化(T-Net)操作。PointNet 通过两次 T-Net 变换操作来保证点云数据旋转不变性:第一次 T-Net 操作是对原始输入点云进行规范化操作;第二次 T-Net 操作则是对 64 维点特征进行规范化操作。

点云数据是一组无序的坐标向量集合,对于 N 个点会有 $N!$ 种输入组合,该特点即为点云的无序性。点云的无序性会导致无法直接对点云进行训练。PointNet 解决点云无序性的策略是最大池化操作,其基本思想就是将集合内所有成员进行比较,选取最大值。无论点云的输入组合如何变化,其集合最大值是唯一的,最大池化操作可保证点云输入的不变性,其表达式为

$$f(x_1, x_2, \dots, x_n) = g[h(x_1), h(x_2), \dots, h(x_n)], \quad (1)$$

式中: x 表示点云; h 表示多层感知机(MLP)特征提取层; g 表示最大池化的对称方法; f 表示相机的焦距。

PointNet 采用多层感知机首先提取每个点的 64 维特征,然后通过特征增维和最大池化操作提取出 1024 维全局特征(块特征),最大池化操作是对一个块内所有点的 1024 维特征进行每一个维度的最大特征值提取,从而构成一个 1024 维的全局特征(块特征)。最后将点特征以及全局特征联合,形成既有点特征又有全局特征的组合,以此为基础完成三维点云的精确分类。

基于 PointNet 的点云分类流程如图 1 所示,具体步骤为:1)对于输入点云数据,利用一个 T-Net 变换完成对输入点云的规范化操作;2)采用一个双层感知机(64,64)进行规范化点云的特征提取,通过对特征进行规范化得到每个点的 64 维点特征;3)对上述提取出来的 64 维点特征采用一个三层感知机(64,128,1024)进行点特征增维,得到每个点的 1024 维特征,进而通过最大池化操作得到一个 1024 维的全局特征;4)将每个点的 64 维点特征与 1024

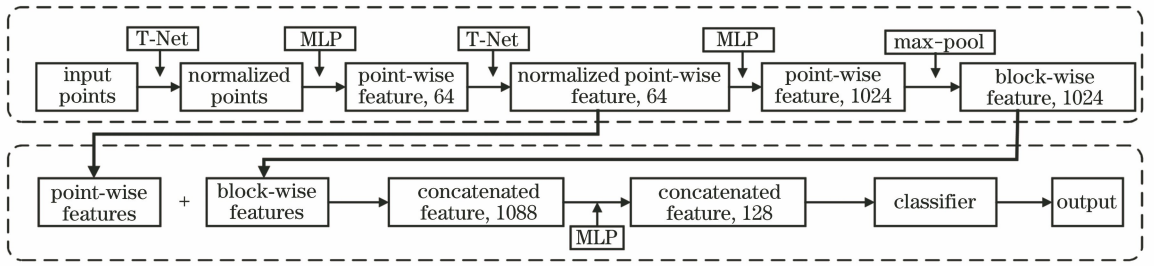


图 1 基于 PointNet 的三维点云分类流程

Fig. 1 Classification flow of 3D point clouds based on PointNet

维全局特征联合,得到 1088 维联合特征,并采用一个三层感知机(512,256,128)进行特征降维来获取每个点的 128 维特征,最后通过每个点的 128 维特征训练分类器输出每个点的类别标签。

3 融合光谱信息的机载 LiDAR 点云三维深度学习分类

为了提高机载 LiDAR 点云的分类精度,将多光谱影像与机载 LiDAR 点云数据进行融合,并采用三维深度学习算法进行点云分类:1)将机载 LiDAR 点云与航空多光谱影像数据融合;2)对融合

数据进行多尺度分块处理;3)点云分类。融合多光谱信息的机载 LiDAR 点云分类流程如图 2 所示。

3.1 机载 LiDAR 点云光谱信息融合

将机载 LiDAR 点云与多光谱航空影像融合,生成具有光谱信息的点云数据,以实现点云数据的光谱信息补充。在已知航摄像片内外方位元素的情况下,将 LiDAR 点云的三维坐标代入共线条件方程^[13],可计算得到对应三维点在影像上的像素位置,进而通过重采样获取近红外(NIR)、红色(R)以及绿色(G)通道的灰度值。共线条件方程可表示为

$$\begin{cases} x = -f \cdot \frac{a_1(X - X_s) + b_1(Y - Y_s) + c_1(Z - Z_s)}{a_3(X - X_s) + b_3(Y - Y_s) + c_3(Z - Z_s)} \\ y = -f \cdot \frac{a_2(X - X_s) + b_2(Y - Y_s) + c_2(Z - Z_s)}{a_3(X - X_s) + b_3(Y - Y_s) + c_3(Z - Z_s)} \end{cases}, \quad (2)$$

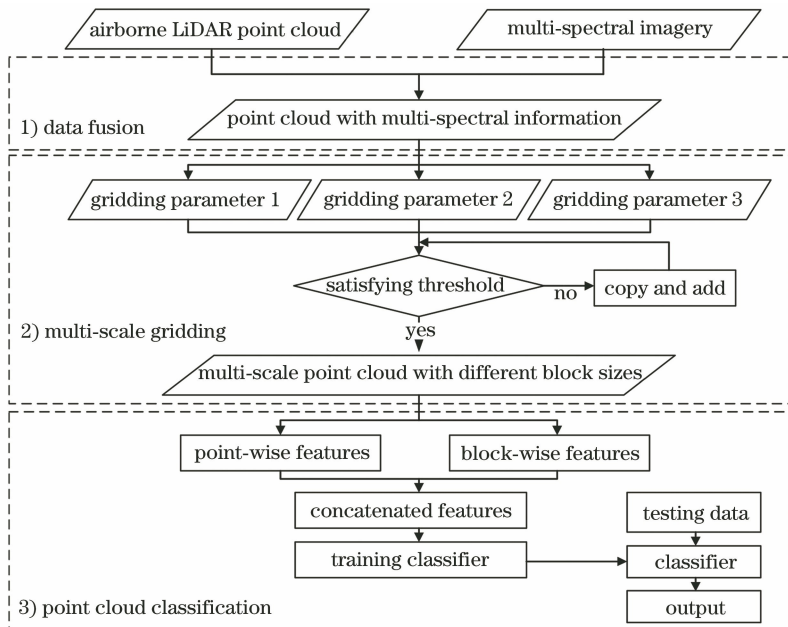


图 2 融合多光谱信息的机载 LiDAR 点云分类流程

Fig. 2 Flow chart of classification for airborne LiDAR point clouds fusing multi-spectral imagery

式中: (X, Y, Z) 为地面点的三维坐标; (X_s, Y_s, Z_s) 是外方位元素的三个线元素; $(a_1, b_1, c_1, a_2, b_2, c_2, a_3, b_3, c_3)$ 是由外方位元素中三个角元素计算得到的旋转矩阵参数。

计算出每个激光脚点对应的光谱信息 (NIR、R、G 三通道灰度值) 后, 将点云三维坐标、光谱信息以及点云强度信息组合得到增强的点云数据, 作为后续点云分类的输入数据。

3.2 融合点云数据多尺度分块

采用三维深度学习算法进行机载 LiDAR 点云分类时, 需要对点云数据进行分块处理并保证每个块内的点数量保持一致。为减小地物尺寸对分类结果的影响, 使提取的全局特征具有多尺度特性, 当

数据被分割成不同尺寸的块时, 训练样本的数量明显增加, 通过增强训练数据, 可以进一步提高对噪声和方向的鲁棒性^[14]。故本研究采用不同尺寸的格网进行机载 LiDAR 点云数据的分块处理 (图 3)。此外, 由于机载 LiDAR 点云的稀疏性和分布的不均匀性, 数据格网化后不能保证每个块内有足够数量的点可进行训练。针对这个问题, 本研究采用如下措施实现点云数据的分块处理: 设定保存阈值, 对格网化之后每个块内的点数量进行检查。若块内的点数量大于保存阈值, 则保存块作为训练和测试数据; 若块内点的数量小于保存阈值时, 需要对当前块内点云数据进行随机复制, 以满足块内点数要求。




图 3 点云数据的多尺度格网化处理

Fig. 3 Multi-scale grid processing on point cloud data

3.3 基于 PointNet 的机载 LiDAR 点云分类

基于 PointNet 进行点云分类, 其采用多层感知机自动提取点特征, 在此过程中, 需要定义相应的激活函数。本研究采用 ReLU 函数作为网络的激活函数^[15], 其可在一定程度上避免反向传播过程中的梯度爆炸和梯度消失问题。ReLU 函数的具体形式为

$$f(x) = \begin{cases} 0, & \text{for } x < 0 \\ x, & \text{for } x \geq 0 \end{cases} \quad (3)$$

提取出每个点的 64 维特征之后, 采用多层感知机和最大池化操作可获取每个点的 1024 维全局特征, 将上述计算得到的点特征和全局特征串联可得到 1088 维联合特征。以此特征向量作为输入, 通过训练分类器可得到相应的网络参数, 最终将测试数据输入训练好的分类器来实现机载 LiDAR 点云的分类。

网络训练过程中, 由于机载 LiDAR 点云的稀疏性和不均匀性, 使用相同的学习率, 网络将不能适应所有的参数更新, 从而影响分类结果。因此, 本研究采用 Adam 优化方法^[16]进行网络参数的更新, 该方法可以基于训练数据迭代更新神经网络权重, 从而解决参数更新过程中存在的问题。

4 实验与分析

4.1 数据集描述

采用国际摄影测量与遥感协会 (ISPRS) 提供的德国 Vaihingen 地区测试数据集^[17]进行所提方法的验证。实验数据集包括机载 LiDAR 点云数据及其相应的多光谱航空影像。其中, 机载 LiDAR 点云数据由徕卡 ALS50 系统获取, 点密度约为 4 m^{-2} , 每个激光脚点包含三维坐标、反射强度和回波次数等信息; 多光谱航空影像的地面分辨率为 8 cm, 每张影像的尺寸为 $7680 \text{ pixel} \times 13824 \text{ pixel}$, 并且提供了影像的内、外方位元素。为了对分类精度进行评定, 本研究同时提供了上述数据集的参考数据, 并给出了每个激光脚点对应的地物类别。该数据集包括训练数据集和测试数据集, 如图 4 和图 5 所示。

4.2 实验结果及分析

采用 PointNet 进行点云分类时, 需要将点云进行多尺度格网化处理。为确定格网化的最佳尺度, 根据实验区的地物尺寸, 选取不同的尺度进行格网划分, 并针对单个尺度以及多尺度分块分类总体精度 (OA) 以及 Kappa 系数进行对比, 结果如表 1 所示。

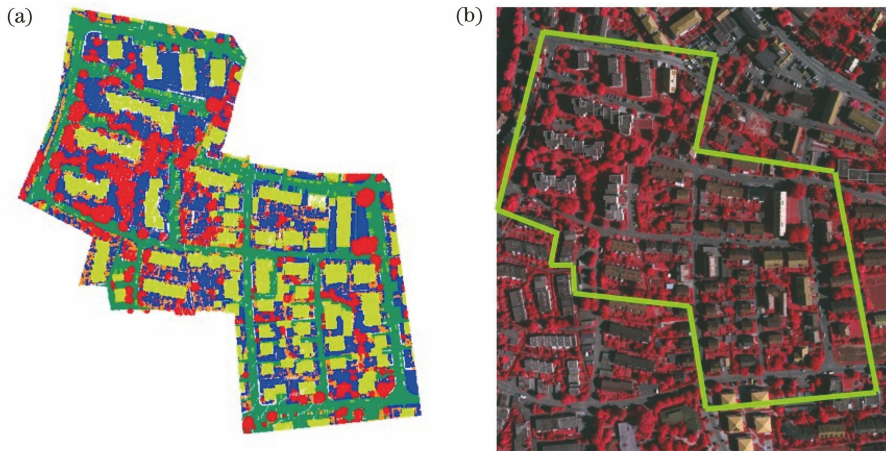


图4 训练数据集及其对应区域的多光谱影像。(a)训练数据集;(b)多光谱影像

Fig. 4 Training set and the corresponding multi-spectral imagery. (a) Training set; (b) multi-spectral imagery




图5 测试数据集及其对应区域的多光谱影像。(a)测试数据集;(b)多光谱影像

Fig. 5 Test set and the corresponding multi-spectral imagery. (a) Test set; (b) multi-spectral imagery

表1 不同尺度下点云分类精度对比

Table 1 Comparison of classification accuracy under different scales

| Size /m | OA /% | Kappa |
|---------|-------|--------|
| 2 | 74.88 | 0.6756 |
| 5 | 81.54 | 0.7592 |
| 10 | 81.14 | 0.7541 |
| 15 | 78.36 | 0.7178 |
| 2,5,10 | 80.00 | 0.7396 |
| 5,10,15 | 82.02 | 0.7658 |

从表1可以看出,相较于单个分块(单一尺度)的点云分类结果,采用多尺度策略,尤其是采用5 m、10 m、15 m的尺度进行点云分类时,总体精度和Kappa系数最优。因此,本研究采用5 m、10 m、15 m的尺度进行分块,组成训练数据集后进行点云分类。同时,依据点云密度,并在保证每个分块都有足够数量的点进行特征表达的约束下,将1024作为块保留阈值,完成机载LiDAR点云数据分类。在

点云分类过程中,将ISPRS提供数据集中训练数据的三维坐标信息、强度信息以及融合多光谱影像的光谱信息作为输入数据进行模型训练,使用测试数据进行所提方法的精度验证。

为验证所提方法的可行性和有效性,采用如下两种方案对分类结果进行分析和评价:1)对融合光谱数据前后的机载LiDAR点云分类结果进行评价;2)将所提分类方法与其他方法的分类结果进行对比。

1)融合光谱数据前后的机载LiDAR点云分类结果

融合光谱信息前、后的点云分类结果分别如图6和图7所示。从图6可以看出,基于原始点云进行分类时,错分现象较为明显,尤其是在建筑物和树木等区域。如图7所示,融合光谱信息后,错分现象得到了有效抑制,分类精度显著提升。

为了对分类结果进行更加客观的评价,采用总

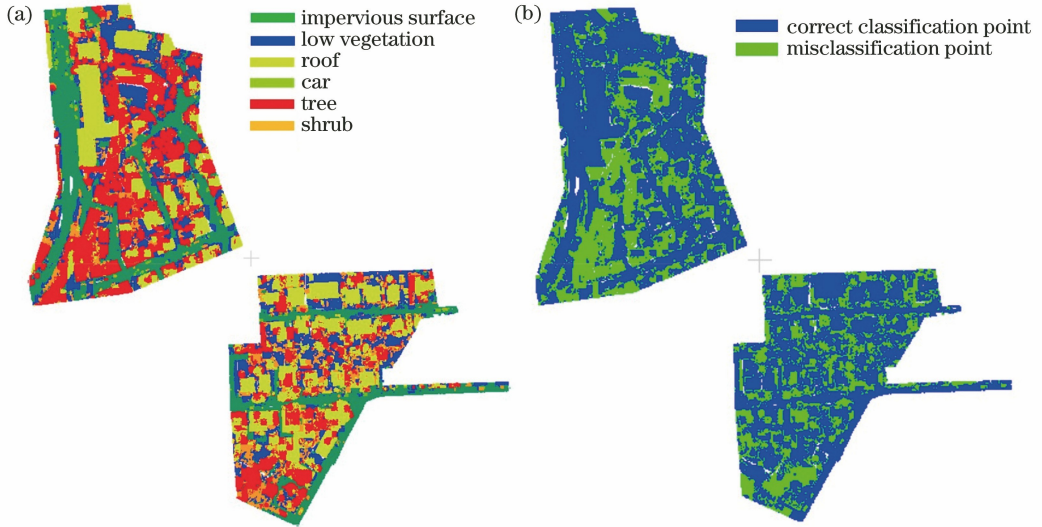


图 6 未融合光谱信息的点云分类结果。(a)不同地物的分类结果;(b)错误分类结果

Fig. 6 Classification results of original LiDAR point clouds. (a) Classification results of different objects; (b) misclassification results

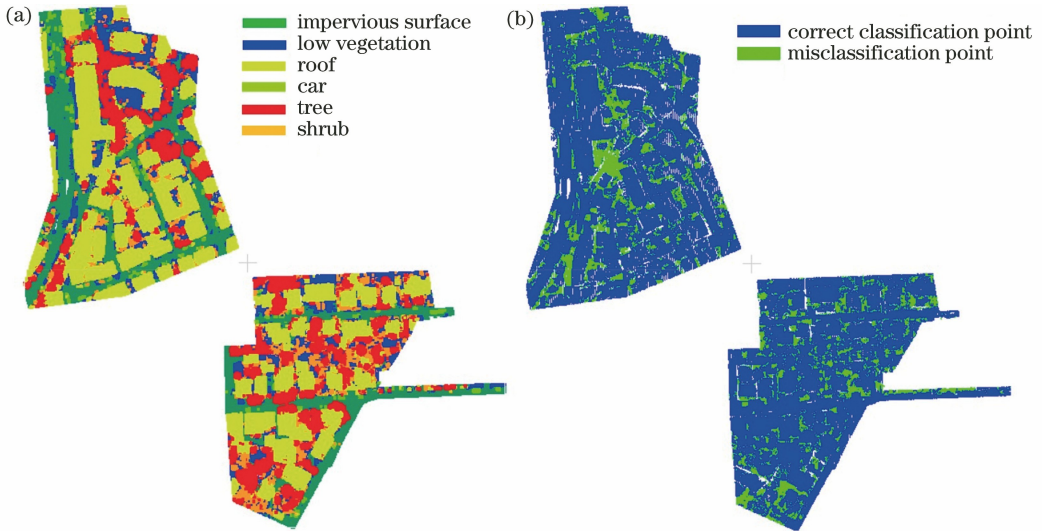


图 7 融合多光谱信息的点云分类结果。(a)不同地物的分类结果;(b)错误分类结果

Fig. 7 Classification results of multi-spectral point clouds. (a) Classification results of different objects; (b) misclassification results

体精度、Kappa 系数以及综合评价指标 F_1 分数对分类结果进行定量分析。 F_1 分数计算公式为

$$F_1 = 2 \cdot \frac{P_{\text{precision}} \cdot R_{\text{recall}}}{P_{\text{precision}} + R_{\text{recall}}}, \quad (4)$$

式中: F_1 为综合考虑查准率和查全率的一种评价指标; $P_{\text{precision}}$ 为查准率; R_{recall} 为查全率。融合光谱信

息前、后的点云分类结果如表 2 所示。

从量化的评价结果来看,融合光谱信息后,所有地物的点云分类精度都有较大提升。其中,总体精度提高了 13.39 个百分点,Kappa 系数提高 0.1689,且每类地物的综合评价指标 F_1 分数均有不同程度的提高,屋顶、树木和车辆的 F_1 分数提升效

表 2 融合多光谱信息前、后的点云分类结果

Table 2 Point cloud classification results of unfused and fused spectral information

| Type of data | $F_1 / \%$ | | | | | | OA / % | Kappa |
|---------------|----------------|--------------------|-------|-------|-------|-------|--------|--------|
| | Low vegetation | Impervious surface | Car | Roof | Shrub | Tree | | |
| Original data | 73.60 | 83.28 | 35.88 | 69.06 | 37.01 | 51.86 | 68.63 | 0.5969 |
| Fused data | 75.92 | 85.90 | 54.03 | 94.08 | 42.69 | 79.47 | 82.02 | 0.7658 |

果尤为明显,分别提高了 25.02 个百分点、27.61 个百分点和 18.15 个百分点。由此可见,融合光谱特征后,点云的属性信息可以得到有效增强,从而实现了对各种地物目标更加准确的分类。

2) 与其他研究方法的结果对比

为了对不同的研究方法进行对比,ISPRS 网站提供了不同方法的实验结果。本研究将所提方法的精度测量结果与部分提交结果 (<http://www2.isprs.org/commissions/comm2/wg4/vaihingen-3d-semantic-labeling.html>, 2019 年 9 月 24 日) 进行了对比,结果如表 3 所示。

表 3 不同分类方法的精度对比

Table 3 Accuracy comparison of different classification methods

| Method | $F_1/\%$ | | | | | |
|--------|----------------|--------------------|-------------|-------------|-------------|-------------|
| | Low vegetation | Impervious surface | Car | Roof | Shrub | Tree |
| Ours | 75.9 | 85.9 | 54.0 | 94.1 | 42.7 | 79.5 |
| IIS_7 | 65.2 | 85.0 | 57.9 | 90.9 | 39.5 | 75.6 |
| UM | 79.0 | 89.1 | 47.7 | 92.0 | 40.9 | 77.9 |
| NANJ | 77.7 | 90.9 | 51.7 | 93.6 | — | 77.1 |

从表 3 可以看出:相较于同样使用光谱信息的 IIS_7 方法,本文方法采用三维深度学习框架,可以更好地对点云特征进行抽象和表达,分类效果较好。相较于 UM 方法以及 NANJ 方法,本文方法是基于点云的原始属性信息,并未对相关特征进行手工提取,但这两种方法都进行了点云的局部特征提取,所以其对低矮植被以及不透水表面的分类精度要高于本文方法。本文方法中加入了光谱信息,可有效弥补点云空间几何特征的不足,提高了点云分类精度,对屋顶、灌木以及树木的分类精度更高。

5 结 论

提出一种融合光谱信息的机载 LiDAR 点云三维深度学习分类方法。该方法首先将机载 LiDAR 点云与多光谱影像进行融合,以扩充输入端的点云属性信息,进而采用点云网格化操作和数据增强处理来解决点云的稀疏性和不均匀性问题,最后采用多层感知机提取出点特征和全局特征,并基于 PointNet 实现了机载 LiDAR 点云的准确分类。实验结果表明,所提出的点云分类方法可以在不进行人工提取特征的前提下,保证分类精度,同时提高了运算效率。此外,将三维点云与光谱信息融合,可有效解决点云属性数据不足而导致的无法准确分类问题,特别是对树木和建筑物的分类精度提升较为显著。然而在实验中发现,当描述电力线、栅栏以及建筑物立面等点数较少的地物特征时,分块处理方法

表 3 中,IIS_7^[18]首先对点云进行基于超体素的分割以及基于颜色的区域增长分割,将点云分割为三维对象,然后对分割对象的几何和光谱特征进行提取,最后采用机器学习的方法进行点云分类。UM 是基于特征的监督机器学习分类方法,其通过局部拟合曲面以及 k 近邻方法获取点云的纹理特征,通过形态学方法获取点云的几何属性以及点云的属性信息,并采用多级机器学习方法进行点云分类。NANJ^[19]通过给每个激光点生成一组多尺度语义图像,采用多尺度卷积神经网络对多尺度语义图像进行深层特征提取,进而完成点云分类。

具有一定的局限性,分类精度不高,但本研究未进行上述三类地物的分类,接下来将考虑加入点云局部特征描述,以实现点云的精细化分类。

参 考 文 献

- [1] Li D R, Shao Z F, Yang X M. Theory and practice from digital city to smart city [J]. Geospatial Information, 2011, 9(6): 1-5.
李德仁, 邵振峰, 杨小敏. 从数字城市到智慧城市的理论与实践[J]. 地理空间信息, 2011, 9(6): 1-5.
- [2] Zhang J X, Lin X G, Ning X G. SVM-based classification of segmented airborne LiDAR point clouds in urban areas [J]. Remote Sensing, 2013, 5(8): 3749-3775.
- [3] He M Y, Cheng Y L, Liao X J, et al. Building extraction algorithm by fusing spectral and geometrical features [J]. Laser & Optoelectronics Progress, 2018, 55(4): 042803.
何曼芸, 程英蕾, 廖湘江, 等. 融合光谱特征和几何特征的建筑物提取算法[J]. 激光与光电子学进展, 2018, 55(4): 042803.
- [4] Niemeyer J, Rottensteiner F, Soergel U. Conditional random fields for lidar point cloud classification in complex urban areas [J]. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2012, 1-3: 263-268.
- [5] Wei S F. Scene understanding based on point clouds and 2D images [D]. Beijing: University of Chinese

- Academy of Sciences, 2016.
- 魏书法. 基于三维点云与二维图像的场景理解[D]. 北京: 中国科学院大学, 2016.
- [6] Yi L, Su H, Guo X W, et al. SyncSpecCNN: synchronized spectral CNN for 3D shape segmentation [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE, 2017: 17355428.
- [7] Bai S, Bai X, Zhou Z C, et al. GIFT: a real-time and scalable 3D shape search engine [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 5023-5032.
- [8] 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), September 28-October 2, 2015, Hamburg, Germany. New York: IEEE, 2015: 922-928.
- [9] Wang L, Huang Y C, Shan J, et al. MSNet: multi-scale convolutional network for point cloud classification [J]. Remote Sensing, 2018, 10 (4): 612.
- [10] Charles R Q, Hao S, Mo K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE, 2017: 17355473.
- [11] Zhang J Y, Zhao X L, Chen Z. A review of semantic segmentation of point cloud based on deep learning [J]. Laser & Optoelectronics Progress, 2020, 57 (4): 040001.
张佳颖, 赵晓丽, 陈正. 基于深度学习的点云语义分割综述 [J]. 激光与光电子学进展, 2020, 57 (4): 040001.
- [12] Zhao Z Y, Cheng Y L, Shi X S, et al. Terrain classification of LiDAR point cloud based on multi-scale features and PointNet [J]. Laser & Optoelectronics Progress, 2019, 56(5): 052804.
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]. 激光与光电子学进展, 2019, 56(5): 052804.
- [13] Zhang J Q, Pan L, Wang S G. Digital photogrammetry [M]. 2nd ed. Wuhan: Wuhan University Press, 2009: 26-30.
张剑清, 潘励, 王树根. 数字摄影测量 [M]. 2 版. 武汉: 武汉大学出版社, 2009: 26-30.
- [14] Yousefhussein M, Kelbe D J, Ientilucci E J, et al. A multi-scale fully convolutional network for semantic labeling of 3D point clouds [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 143: 191-204.
- [15] Shang W L, Sohn K, Almeida D, et al. Understanding and improving convolutional neural networks via concatenated rectified linear units [EB/OL]. [2019-09-01]. <https://arxiv.org/abs/1603.05201>.
- [16] Kingma D P, Ba J. Adam: a method for stochastic optimization [EB/OL]. [2019-09-10]. <https://arxiv.org/abs/1412.6980>.
- [17] Niemeyer J, Rottensteiner F, Soergel U. Contextual classification of lidar data and building object detection in urban areas [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 87: 152-165.
- [18] Ramiya A M, Nidamanuri R R, Ramakrishnan K. A supervoxel-based spectro-spatial approach for 3D urban point cloud labelling [J]. International Journal of Remote Sensing, 2016, 37(17): 4172-4200.
- [19] Zhao R B, Pang M Y, Wang J D. Classifying airborne LiDAR point clouds via deep features learned by a multi-scale convolutional neural network [J]. International Journal of Geographical Information Science, 2018, 32(5): 960-979.