

# 整合图卷积与 PointNet 的机载激光雷达点云分类

缪建起, 王宏涛\*, 田普光

河南理工大学测绘与国土信息工程学院, 河南 焦作 454000

**摘要** 针对三维深度学习网络 PointNet 中缺少点局部特征描述而导致的分类精度较低的问题, 提出了一种整合图卷积模型与 PointNet 的机载激光雷达点云分类方法。该方法首先通过最小香农熵准则确定点的最优邻域, 计算出点云的浅层特征; 然后将点云的浅层特征输入深度学习网络中, 通过图卷积提取点云局部特征, 并将该特征与 PointNet 提取的点特征、全局特征组合得到特征向量; 最后, 将上述特征向量输入设计的多层感知机实现点云的准确分类。利用国际摄影测量与遥感协会提供的 Vaihingen 点云数据集进行了验证, 实验结果表明, 所提方法相较于 PointNet 点云分类方法精度提高了 9.58 个百分点。

**关键词** 遥感; 机载激光雷达; 点云分类; 图卷积; 最优 k 邻域; PointNet

中图分类号 P237 文献标志码 A

DOI: 10.3788/LOP202259.2228003

## Airborne Light Detection and Ranging Point Cloud Classification via Graph Convolution and PointNet Integration

Miao Jianqi, Wang Hongtao\*, Tian Puguang

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

**Abstract** This paper proposes an airborne light detection and ranging point cloud classification method that integrates the graph convolution model and PointNet to address the problem of low classification accuracy, which is caused by the lack of point local features description in the three-dimensional deep learning network PointNet. This method first determines the optimal neighborhood of each point using the minimum Shannon entropy criterion, and then the shallow features of each point are calculated to feed into the deep learning network. Second, the shallow features of point clouds are used to derive local features via a graph convolution operation, which are combined with the point-based and global features extracted by PointNet to obtain the feature vectors. Finally, the above features are combined to obtain the feature vectors. The proposed method is validated using the Vaihingen dataset provided by the International Society for Photogrammetry and Remote Sensing, and the experimental results show that the proposed method improves accuracy by 9.58 percentage points compared with the PointNet point cloud classification method.

**Key words** remote sensing; airborne light detection and ranging; point cloud classification; figure convolution; optimal k proximity; PointNet

## 1 引言

相较于传统测量方式, 机载激光雷达(LiDAR)技术可以快速、高效且高精度地获取目标地物三维点云, 在基础测绘、电力、林业、防灾减灾及自动驾驶等领域有着广泛的应用<sup>[1]</sup>。机载 LiDAR 获取的原始三维点云, 具有高度的离散性和不规则性, 从中准确识别并提

取出感兴趣的各种地物目标, 是上述领域开展应用的关键, 成为近年来研究的热门问题。

目前, 机载 LiDAR 点云分类方法主要采用传统机器学习分类器对人工提取的点云特征进行判别, 常用的分类器有随机森林(RF)、支持向量机(SVM)<sup>[2-3]</sup>等。例如, Gevaert 等<sup>[4]</sup>通过提取点云的光谱特征、纹理特征、几何特征等基于随机森林分类器进行点云分类。

收稿日期: 2021-08-23; 修回日期: 2021-09-23; 录用日期: 2021-10-27

基金项目: 河南省自然科学基金面上项目(182300410115)、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)

通信作者: \*wht\_31@hpu.edu.cn

但人工设计的特征表达效果不明显,模型适应性有一定局限,难以达到理想效果。除此之外,分类器的选择也受人经验控制,缺乏一定普适性。对此,文献[5-6]采用深层神经网络进行点云数据的分类,该方法首先将三维点云数据转换成相对规整的数据(如网格化或者图像化)格式,然后使用多层神经网络对其进行分类处理。将三维点云栅格化会在一定程度上造成数据冗余和信息缺失,同时也需要大量的计算时间,限制了数据处理的效率。

斯坦福大学 Qi 等<sup>[7]</sup>提出的 PointNet 模型可直接在原始点云上进行分类。该方法避免了人工设计特征选择的局限和数据转换的复杂流程,近些年来在三维点云分类中得到了广泛应用。赵中阳等<sup>[8]</sup>研究了基于 PointNet 的机载 LiDAR 点云分类方法,但由于原始点云的不规则性且缺乏辅助信息(特征不充分),分类结果精度仍有待提高。然而,PointNet 分类框架忽略了点云的局部信息,对于复杂场景的识别较弱。为了提高点云的分类效果,研究者对 PointNet 进行了改进,提出了 PointNet++<sup>[9]</sup>,该算法通过在网络中建立分层模块,分别完成局部邻域质心的选择、邻域子集的建立和邻域特征的提取,但其仍然独立处理点集中的点,并没有考虑点与点之间的关系。对此,文献[10]提出了

PointCNN 模型,其将特定点的邻域信息聚合到该点,扩充特定点的节点信息,但该方法只对选定点进行特征聚合,局部特征提取不足,在一定程度限制了分类精度。文献[11]针对 PointNet 未引入局部特征,分割精度有待提高的问题,在深度神经网络 PointNet 基础上,提出了一种结合改进 KNN 算法的局部特征提取方法,获得了更好的分类结果。

针对以上问题,本文提出了一种整合图卷积与 PointNet 的机载 LiDAR 点云分类方法。该方法首先将人工提取的点云特征融入 PointNet 分类中,解决点云特征不充分造成分类精度低问题;其次,通过图卷积操作提取点云局部信息,解决 PointNet 模型忽略点云局部特征描述的问题,从而提高 LiDAR 点云分类的准确率。

## 2 整合图卷积与 PointNet 的点云分类方法

为了进一步提高 LiDAR 点云分类精度,在提取点云几何特征的基础上,采用 PointNet 模型和图模型提取点云的点特征、全局特征及局部特征进行点云分类。所提方法主要分为 3 步:1)浅层特征提取;2)基于图卷积的点云局部特征提取;3)点云分类。具体流程如图 1 所示。

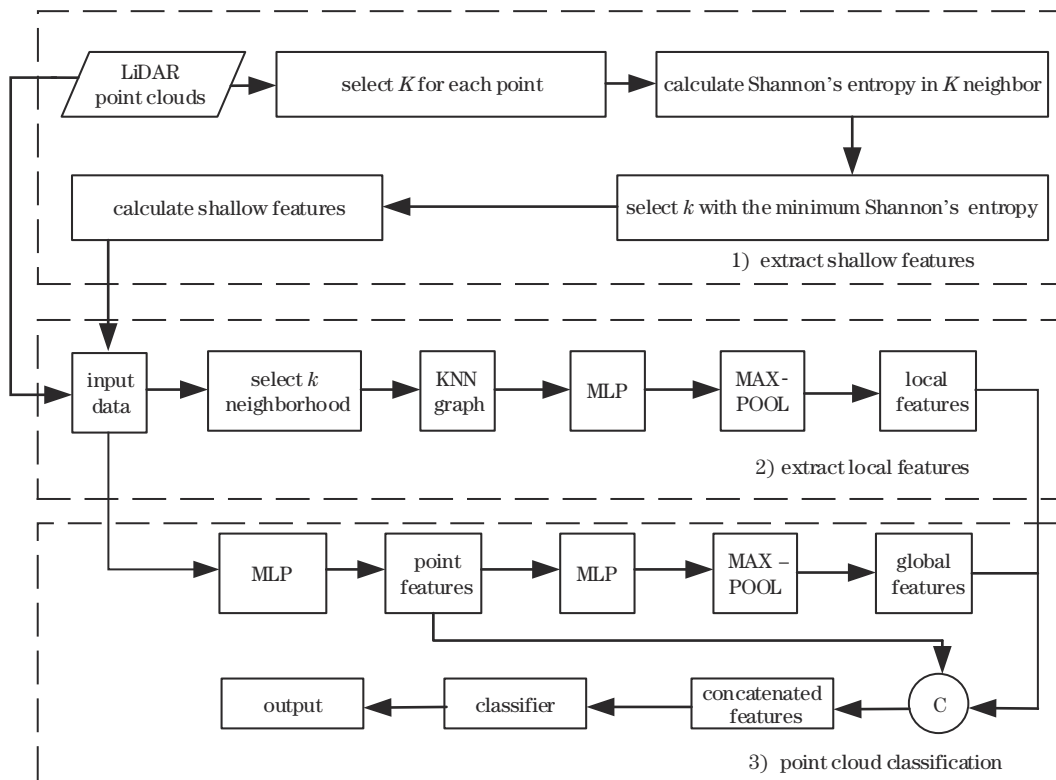


图 1 点云分类流程图

Fig. 1 Flow chart of point cloud classification

### 2.1 浅层特征提取

由于原始点云信息不充分,会造成分类精度低,对

此何曼芸等<sup>[12]</sup>通过融合点云的光谱信息和几何信息,基于随机森林分类器进行点云分类。本实验组通过提

取点云的形状和高度等浅层特征,来弥补点云分类过程中特征描述不足而导致的分类精度较低问题。在提取浅层特征过程中,邻域选择易受点云密度、噪声的影响,单一邻域难以提取有效的特征。因此,本实验组采用了香农熵计算最优邻近点个数<sup>[13]</sup>,该方法可以灵活定义每个点的最优邻域。将邻近点个数定义在[15, 40]的范围内,然后按照5的步长分别计算不同邻近点个数( $k$ )下的香农熵,进而根据香农熵衡量邻域的准则,把取得最小香农熵时的 $k$ 值作为最优邻近点个数。香农熵 $E_k$ 的表达式为

$$E_k = -e_1 \ln e_1 - e_2 \ln e_2 - e_3 \ln e_3, \quad (1)$$

式中: $e_1, e_2, e_3$ 是根据 $k$ 个邻近点坐标计算的归一化特征值。参考文献[13]的特征计算方法,所提方法共提取了26维几何特征。1)通过对 $e_1, e_2, e_3$ 的代数运算,得到三维局部形状特征:线性度、平整度、零散度、总方差、异同度、特征熵、特征值的和、曲率变化率、垂直度、

局部点密度、局部点云半径、高程变化范围、高程标准差和3个归一化特征值 $e_1, e_2, e_3$ 。2)把上述局部三维点集投影到二维空间,得到局部二维形状特征:邻域点密度、邻域点半径、二维特征值的和、特征值比率、2个归一化特征值。3)高程中值、点数、高程标准差和高程范围(高程的90%分位数与10%分位数之差)。将得到的26维特征作为输入的浅层特征,用于后续机载LiDAR点云分类。

## 2.2 基于图卷积的点云局部特征提取

上述浅层特征提取过程中,以每个三维点为研究对象,通过一定邻域建立其特征描述,缺乏点与点之间的拓扑关系描述。为了进一步提高三维点云的特征表达能力,采用边缘卷积(EdgeConv)来建立点与点之间的拓扑关系描述,以增强三维点云的局部特征表达能力。基于边缘卷积提取点云局部特征的流程如图2所示。

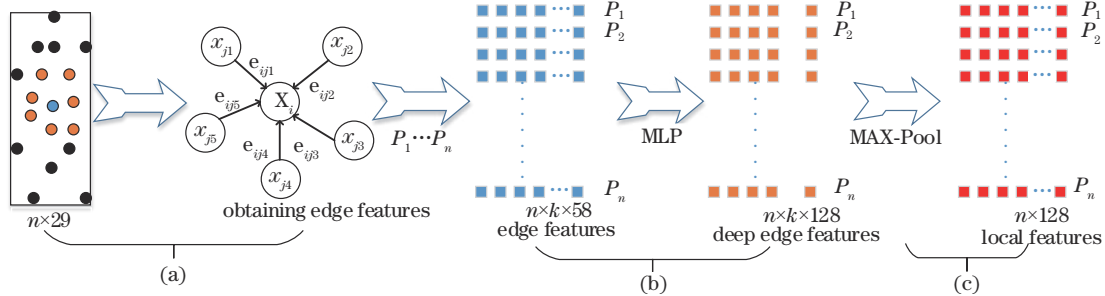


图2 局部特征提取流程图。(a)边缘特征提取;(b)深度特征提取;(c)局部特征提取

Fig. 2 Flowchart of local feature extraction. (a) Edge feature extraction; (b) depth feature extraction; (c) local feature extraction

首先选取 $k$ 个邻近点,构建KNN图;对输入的点特征使用EdgeConv操作提取边缘特征;然后通过多层感知机(MLP)进行深层特征提取,最后通过最大池化得到点云局部特征。具体步骤如下:

1) 边缘特征提取。提取边缘特征时,输入数据为 $n \times 29$ (点云中有 $n$ 个点,每个点有29维特征,包括2.1节计算得到的26维浅层特征和每个点的三维坐标值,共29维);选取中心点 $x_i$ ,确定周围 $k$ 个邻近点,计算周围 $k$ 个邻近点与中心点的特征差,中心点特征(29维)与特征差(29维)的组合为边缘特征,共 $(n \times k \times 58)$ 个,过程如[图2(a)]所示。边缘特征 $e_{ij}$ 的表达式为

$$e_{ij} = [f(x_i), f(x_j - x_i)], \quad (2)$$

式中: $f(x_i)$ 为中心点的特征; $f(x_j - x_i)$ 为邻域节点特征减中心点的特征。

2) 深度特征提取。通过多层感知机对上述边缘特征进行深层特征提取,可得到 $(n \times k \times 128)$ 个边缘特征,过程如[图2(b)]所示。提取的深度边缘特征 $e'_j$ 的表达式为

$$e'_j = h\Theta(e_{ij}) [f(x_i), f(x_j - x_i)], \quad (3)$$

式中: $h$ 为多层感知机; $\Theta$ 为训练参数。

3) 局部特征提取。最后采用最大池化操作

(Maxpooling)选取每个点的128维局部特征 $x'$ ,如[图2(c)]所示。局部特征的表达式为

$$x'_i = \text{Maxpooling}_{(i,j \in E)} h\Theta [f(x_i), f(x_j - x_i)]. \quad (4)$$

最终以池化操作计算得到的点局部信息作为接下来点云分类的局部特征,通过增加点云局部特征提高点云分类精度。

## 2.3 点云分类

经过上述过程,可以获取点云的局部特征描述向量( $n \times 128$ ),将此特征与PointNet提取的点特征和全局特征组合,作为多层感知机的输入进行机载LiDAR点云的分类。具体过程如下:

1) 特征组合。将输入点云( $n \times 29$ )通过双层感知机MLP(64, 64)进行特征提取,得到 $(n \times 64)$ 的点特征数据;然后,再利用一个三层感知机(64, 128, 1024)将其映射到更高维的1024空间,得到每个点的 $(n \times 1024)$ 特征数据;最后,通过最大池化操作,得到所有点的全局特征( $1 \times 1024$ ),进而,将64维点特征与1024维全局特征进行特征组合得到每个点的1088维特征。在上述MLP提取点特征的过程中,需要使用激活函数,本实验组选择Relu函数作为模型的激活函数<sup>[14]</sup>,Relu函数可以在一定程度避免反向传播中的梯度爆

炸和梯度消失的问题。

2) 点云分类。将上述提取的点特征(64维)、全局特征(1024维)和局部特征(128维)进行特征组合,共得到每个点的1216维特征。然后,将每个点的1216维特征通过三层感知机(512, 256, 128)将每个点特征降到128维,用于训练分类器进行机载LiDAR点云分类。分类器由softmax函数输出每个点的类别标签和属于每个类别的概率,进而完成点云的分类过程。

### 3 实验及分析

#### 3.1 实验数据集

采用国际摄影测量与遥感协会(ISPRS)提供的Vaihingen地区的LiDAR数据集<sup>[15]</sup>进行实验验证。该

数据集包含的机载LiDAR数据由徕卡ALS50三维激光扫描系统获取,每个点包含三维坐标、反射强度、回波次数等信息。原始点云数据集包括9个类别,由于数据集中电力线、栅栏、立面点云数量少,无法进行有效分类,本实验组选取低矮植被(low vegetation)、不透水表面(impervious surfaces)、汽车(car)、屋顶(roof)、灌木(shrub)和树木(tree)等6类数据<sup>[16]</sup>,如图3所示。训练数据有714010个点,测试数据包含两个区域,共有392476个点。采用总体分类精度(OA)及考虑查准率和查全率的综合评价指标F1分数作为评价指标。F1分数的表达式为

$$S_{F1} = 2 \cdot \frac{P_{\text{precision}} \cdot R_{\text{recall}}}{P_{\text{precision}} + R_{\text{recall}}}, \quad (5)$$

式中: $P_{\text{precision}}$ 为查准率; $R_{\text{recall}}$ 为查全率。

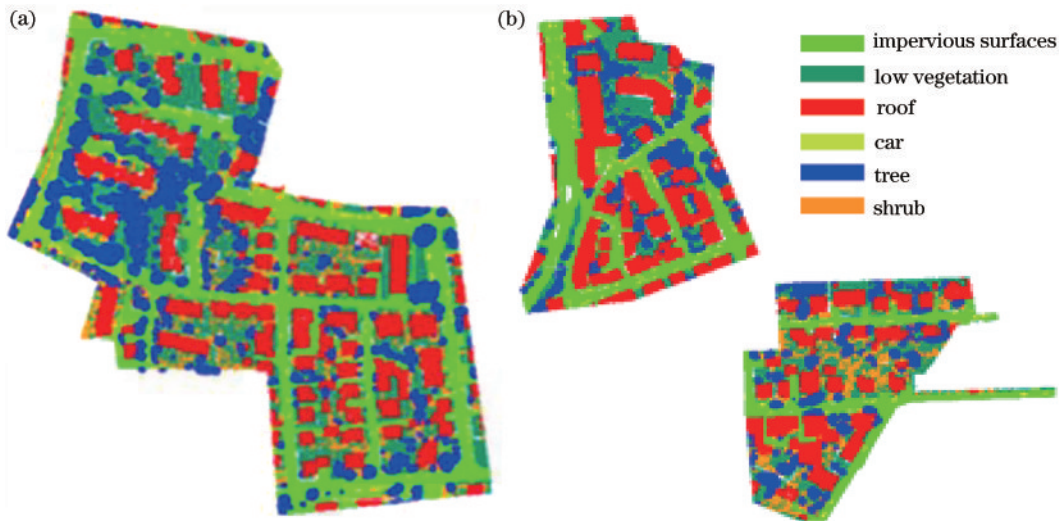


图3 Vaihingen数据集中的训练数据和测试数据。(a)训练数据;(b)测试数据

Fig. 3 Training data and test data from Vaihingen dataset. (a) Training data; (b) test data

#### 3.2 实验结果与分析

为验证所提方法的可行性,分别设计了图卷积、浅层特征及图卷积与浅层特征结合等不同的实验方案,并对实验结果进行了对比和分析。

1) 图卷积提取局部特征对分类结果的影响分析。为了验证图卷积提取的局部特征对LiDAR点云分类结果的影响,以原始三维点云作为输入,首先对比了PointNet和加入图卷积后PointNet的实验结果。图4为PointNet的分类结果,图5为加入图卷积的分类结果。

从图4和图5的对比可以明显看出:PointNet分类结果中屋顶分类较为杂乱,错分现象明显;在加入图卷积提取的局部特征后,PointNet分类结果中错误点明显减少,且分类结果图中的屋顶部分比较规整。由此可见,图卷积提取的局部特征可增加点与点之间的拓扑关系描述,有效提高点云分类精度。

为了更加客观地评价分类结果,采用总体分类精度和综合评价指标F1分数对分类结果进行定量分析,

加入图卷积与未加图卷积的点云分类结果如表1所示。

由表1可以看出:相较于原始PointNet,加入图卷积后,点云分类的整体分类精度由74.38%上升到77.04%,提高了2.66个百分点;除此之外,所有地物类别分类精度均有一定程度的提高,其中树木、汽车和屋顶的F1分数提高最为明显,分别提高了4.34个百分点、7.26个百分点和4.39个百分点,这进一步验证了图卷积提取的点云局部特征对提高点云分类精度的有效性。

2) 浅层特征对分类结果的影响分析。为了验证浅层特征对LiDAR点云分类结果的影响,基于图卷积PointNet的分类方法,对比了采用原始点云数据和加入浅层特征数据的点云分类结果,具体如表2所示:其中Original data为原始点云数据,包含XYZ坐标信息;Fused data包含XYZ坐标信息和浅层特征。

从表2可以看出:将浅层特征与XYZ坐标信息融合作为图卷积PointNet的输入,可使OA提高6.92个

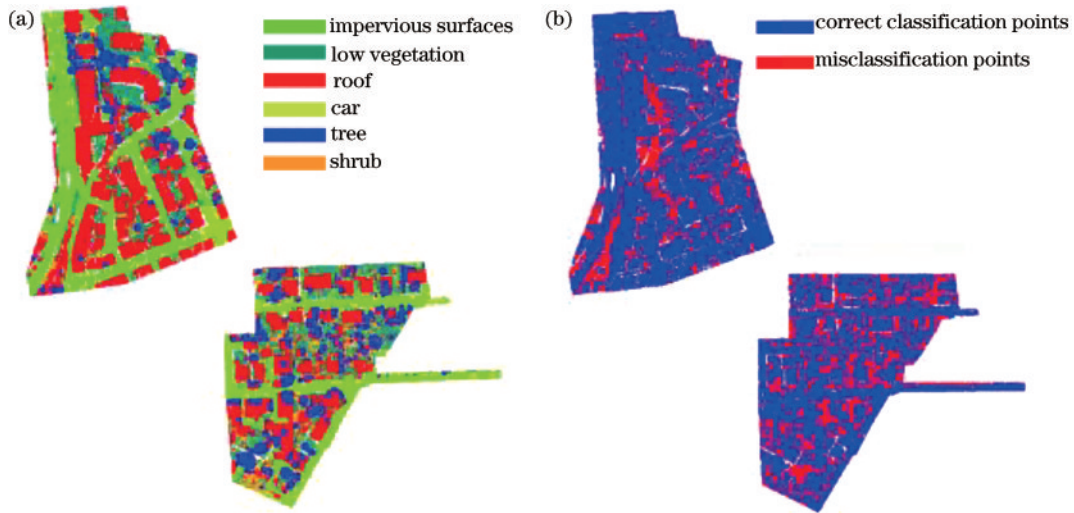


图 4 未加入图卷积分类结果。(a)地物分类结果;(b)正确错误分类图

Fig. 4 Classification results without graph convolution. (a) Classification results of different features; (b) right and wrong classification comparison

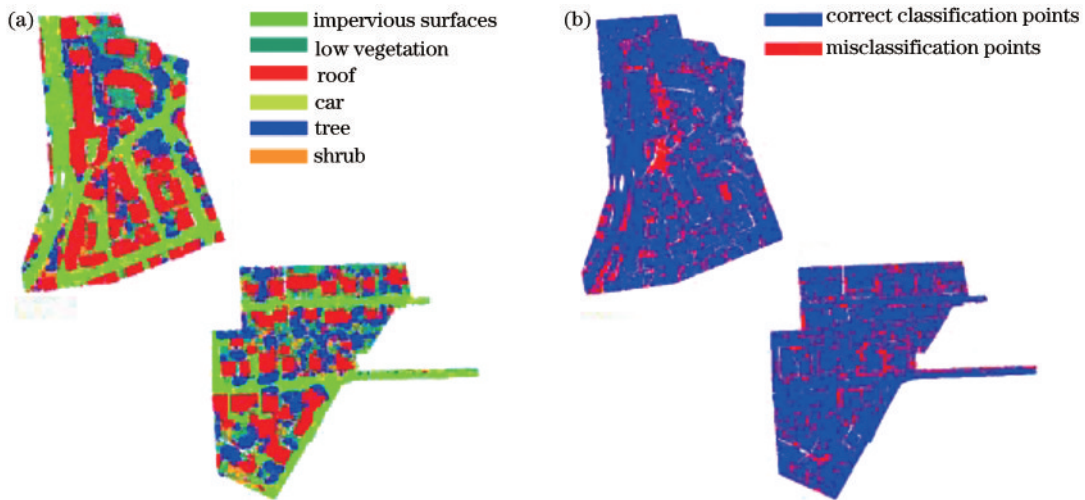


图 5 加入图卷积分类结果。(a)分类结果图;(b)正确错误分类图

Fig. 5 Classification results with graph convolution. (a) Classification results of different features; (b) right and wrong classification comparison

表 1 PointNet 与图卷积 PointNet 的对比分类结果

Table 1 Classification results of original PointNet and added graph models

unit: %

Method	F1 score						OA
	Tree	Low_veg	Imp_sur	Car	Shrub	Roof	
PointNet	60.14	75.16	86.42	49.16	38.51	78.7	74.38
PointNet + EdgeConv	64.48	77.34	88.29	56.42	38.92	83.09	77.04

表 2 浅层特征对分类结果的影响

Table 2 Influence of shallow features on classification results

unit: %

Data	F1 score						OA
	Tree	Low_veg	Imp_sur	Car	Shrub	Roof	
Original data	64.48	77.34	88.29	56.42	38.92	83.09	77.04
Fused data	80.88	78.23	88.31	67.43	43.7	95.76	83.96

百分点;与此同时,每一类别地物分类精度均有提高,其中树木、汽车、灌木和屋顶分类精度提高较为明显,F1 分数分别提高了 16.4 个百分点、11.01 个百分点、4.78 和 12.67 个百分点。由此可见,加入点云浅层特征,可有效解决点云特征不充分造成分类精度低问题,进一步提高点云分类精度。

3)与其他研究方法的结果对比。为了验证所提方法的有效性:首先将所提方法与随机森林、PointNet 点云分类方法结果进行了对比,结果如表 3 所示;其次,也将所提方法实验结果与 ISPRS 网站提供的部分方法实验结果进行了对比,结果如表 4 所示。

表 3 不同分类方法对比结果  
Table 3 Comparison results of different classification methods

unit: %

Method	F1 score						OA
	Tree	Low_veg	Imp_sur	Car	Shrub	Roof	
RF	64.48	77.34	88.29	56.42	38.92	83.09	74.96
PointNet	60.14	75.16	86.42	62.14	38.92	78.7	74.38
Proposed method	80.88	78.23	88.31	67.43	43.7	95.76	83.96

表 4 不同分类方法 F1 对比结果  
Table 4 Comparison results of different classification methods

unit: %

Method	F1 score					
	Tree	Low_veg	Imp_sur	Car	Shrub	Roof
Wang et al <sup>[17]</sup>	79.5	75.9	85.9	54	42.7	94.1
UM	77.9	79	89.1	47.7	40.9	92
NANJ <sup>[18]</sup>	77.1	77.7	90.9	51.7		93.6
Proposed method	80.88	78.23	88.31	67.43	43.7	95.76

表 3 中,RF 的输入数据为点云的三维坐标及强度信息,PointNet 的输入数据为点云的三维坐标信息。从表 3 可以看出:与 RF 的分类结果相比,所提方法各类地物的 F1 分数均有提高,其中在树木、汽车和屋顶类别的分类精度上提高最为明显,分别提高了 16.4 个百分点、11.01 个百分点和 12.67 个百分点,OA 提高了 9.0 个百分点;与 PointNet 分类结果相比,所提方法各类地物 F1 分数也均有提高,其中在树木和屋顶类别的分类精度上提高最为明显,分别提高了 20.74 个百分点和 17.06 个百分点,OA 也提高了 9.58 个百分点。由此可见,融合浅层特征和局部特征可以显著提高点云分类精度。

表 4 中,Wang 等<sup>[17]</sup>将光谱影像的信息与点云融合,扩充点云的光谱信息,采用深度学习的算法进行点云分类。所提方法与之相比各类地物分类精度均有提高,其中在汽车的分类精度上提高最为明显,提高了 13.43 个百分点。UM 是通过获取点云的纹理特征用机器学习方法进行点云分类的方法。所提方法与之相比在汽车的分类精度精度上有显著提高,提高了 19.73 个百分点。NANJ<sup>[18]</sup>采用多尺度卷积神经网络进行深层特征提取,进行点云分类。所提方法与之相比在汽车的分类精度精度上有显著提高,提高了 15.73 个百分点。所提方法由香农熵选择邻域并提取特征,通过添加图卷积的 PointNet 进行点云分类,与表中其他分类方法相比,除低矮植被和不透水表面其他所有类别的分类精度均有提升,尤其在汽车这种样本数量少的

地物上分类效果更佳。

4)计算效率对比。为进一步验证所提方法的计算效率,在相同的计算机配置和相同的实验参数设置下,对比了 PointNet、PointNet+EdgeConv 和所提方法的模型训练时间。PointNet、PointNet+EdgeConv 两种方法的输入数据均为点云的三维坐标信息;所提方法的输入数据为点云的三维坐标及 26 维浅层特征。实验结果表明,上述三种方法的模型训练时间分别为 0.83 h、2.1 h 和 2.2 h。即加入图卷积和浅层特征后,模型的训练时间有所延长,一定程度上影响了计算效率,但是点云分类精度得到了显著提高。

## 4 结 论

提出了一种整合图卷积与 PointNet 的机载 LiDAR 点云分类方法。该方法首先提取点云的浅层特征,然后通过图卷积操作提取点云的局部特征,最后融合局部特征与 PointNet 提取的点特征和全局特征,采用多层感知实现机载 LiDAR 点云分类。实验结果表明:相较于传统 PointNet 分类方法,所提方法的总体分类精度提高了 9.58 个百分点;相较于国内外其他点云分类方法,所提方法可以将点云的局部特征描述有效整合到 PointNet 的点云分类过程中,显著提高点云分类精度。需要说明的是,所提方法在实际执行过程中,需要首先人工提取较多的浅层特征,这在一定程度上影响了图卷积操作时的计算效率,接下来研究主要考虑优化浅层特征<sup>[19-20]</sup>,进一步提高分类精度和计算效率。

## 参 考 文 献

- [1] 杨必胜, 梁福逊, 黄荣刚. 三维激光扫描点云数据处理研究进展、挑战与趋势[J]. 测绘学报, 2017, 46(10): 1509-1516.  
Yang B S, Liang F X, Huang R G. Progress, challenges and perspectives of 3D LiDAR point cloud processing[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(10): 1509-1516.
- [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] Wei Y, Yao W, Wu J, et al. Adaboost-based feature relevance assessment in fusing lidar and image data for classification of trees and vehicles in urban scenes[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2012, I-7: 323-328.
- [4] Gevaert C M, Persello C, Sliuzas R, et al. Classification of informal settlements through the integration of 2d and 3d features extracted from UAV data[J]. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, 3: 317-324.
- [5] Wu Z R, Song S R, Khosla A, et al. 3D ShapeNets: a deep representation for volumetric shapes[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1912-1920.
- [6] 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 Press, 2015: 922-928.
- [7] Qi C R, Su H, Nießner M, et al. Volumetric and multi-view CNNs for object classification on 3D data[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 5648-5656.
- [8] 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.  
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.
- [9] Qi C R, Yi L, Su H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [C]//Advances in Neural Information Processing Systems 2017, December 4-9, 2017, Long Beach, CA, USA. [S.l.: s.n.], 2017: 5105-5114.
- [10] Li Y Y, Bu R, Sun M C, et al. PointCNN: convolution on X-transformed points[C]// Annual Conference on Neural Information Processing Systems 2018, December 3-8, 2018, Montreal, Canada. [S. l.: s. n.], 2018: 820-830.
- [11] 杨晓文, 王爱兵, 韩燮, 等. 基于 KNN-PointNet 的点云语义分割[J]. 激光与光电子学进展, 2021, 58(24): 2410013.  
Yang X W, Wang A B, Han X, et al. Point cloud semantic segmentation based on KNN-PointNet[J]. Laser & Optoelectronics Progress, 2021, 58(24): 2410013.
- [12] 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.  
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.
- [13] Weinmann M, Jutzi B, Hinz S, et al. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 105: 286-304.
- [14] Shang W L, Sohn K, Almeida D, et al. Understanding and improving convolutional neural networks via concatenated rectified linear units[EB/OL]. (2016-03-16) [2021-02-05]. <https://arxiv.org/abs/1603.05201>.
- [15] 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.
- [16] Xu S D, Vosselman G, Oude Elberink S. Detection and classification of changes in buildings from airborne laser scanning data[J]. Remote Sensing, 2015, 7(12): 17051-17076.
- [17] 王宏涛, 雷相达, 赵宗泽. 融合光谱信息的机载 LiDAR 点云三维深度学习分类方法[J]. 激光与光电子学进展, 2020, 57(12): 122802.  
Wang H T, Lei X D, Zhao Z Z. 3D deep learning classification method for airborne LiDAR point clouds fusing spectral information[J]. Laser & Optoelectronics Progress, 2020, 57(12): 122802.
- [18] 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.
- [19] 杨杰, 高伟, 段茜茜, 等. 面向对象的特征自动选择的建筑物信息提取[J]. 遥感信息, 2021, 36(2): 130-135.  
Yang J, Gao W, Duan X X, et al. Extraction of building information based on object-oriented feature automatic selection[J]. Remote Sensing Information, 2021, 36(2): 130-135.
- [20] 申毫, 孟庆浩, 刘胤伯. 基于轻量卷积网络多层特征融合的人脸表情识别[J]. 激光与光电子学进展, 2021, 58(6): 0610005.  
Shen H, Meng Q H, Liu Y B. Facial expression recognition by merging multilayer features of lightweight convolutional networks[J]. Laser & Optoelectronics Progress, 2021, 58(6): 0610005.