

基于融合图卷积的深度学习点云分类方法

徐田野, 丁海勇*

南京信息工程大学遥感与测绘工程学院, 江苏 南京 210044

摘要 针对深度学习模型 PointNet 仅以独立点卷积进行特征提取导致的局部特征缺乏问题, 提出了一种融合空间域特征和谱域特征的图卷积深度学习模型。该模型基于空间方法和谱方法分别构造图结构, 以提取不同的邻域特征, 并通过融合邻域特征与独立点特征得到深层次的抽象特征, 其池化层采用空间金字塔池化方法加深细粒度描述。在国际摄影测量与遥感协会提供的机载 LiDAR 扫描点云和多光谱航空影像上的实验结果表明, 相比其他对比方法, 本方法的分类效果更好, 分类精度为 84.3%, 可实现城市场景下点云数据的有效分类。

关键词 遥感; 点云分类; 深度学习; 图卷积; 机载 LiDAR

中图分类号 P237

文献标志码 A

doi: 10.3788/LOP202259.0228005

Deep Learning Point Cloud Classification Method Based on Fusion Graph Convolution

Xu Tianye, Ding Haiyong*

School of Remote Sensing & Geomatics Engineering, Nanjing University of Information Science & Technology, Nanjing, Jiangsu 210044, China

Abstract In order to solve the problem that the deep learning model PointNet only uses independent point convolution for feature extraction, which leads to the lack of local information, a fusion graph convolution deep learning model based on spatial domain features and spectral domain features is proposed in this paper. In this model, the graph structure is constructed by spatial and spectral methods to extract different neighborhood features, the deep abstract features are obtained by fusing neighborhood features and independent point features, the spatial pyramid pooling method is used to deepen the fine-grained description in the pooling layer. Experimental results on airborne LiDAR scanning point clouds and multispectral aerial images provided by the International Photogrammetry and Remote Sensing Association show that compared with other comparison methods, the classification effect of the method is better, the classification accuracy is 84.3%, and urban scenes can be realized effective classification of point cloud data.

Key words remote sensing; point cloud classification; deep learning; graph convolution; airborne LiDAR

1 引言

三维点云数据是表示物体信息的空间点集合, 具有非结构化、无序、置换不变等特性, 可维持物体

的空间结构及表面特征, 是三维空间感知的重要数据源。随着传感器技术的发展, 机载 LiDAR 扫描点云的获取更加容易, 推动了数字城市建设、电力线巡检、城市规划、地形图测绘等产业的发展。点云

收稿日期: 2021-07-22; 修回日期: 2021-08-09; 录用日期: 2021-09-02

基金项目: 国家自然科学基金(41571350, 41801386)、江苏省研究生科研创新计划(KYCX21_1010)

通信作者: *409803028@qq.com

分类是数据处理过程中的基础工作,对后续的数据处理及应用至关重要。而机载 LiDAR 扫描点云受场景复杂度及扫描分辨率的限制,在精细化的分类工作中具有较大难度。

传统点云分类方法通过人工设计提取各项属性特征并建立用于描述数据点空间几何信息的局部特征描述子,再利用机器学习方法进行分类^[1]。支持向量机(SVM)^[2]、随机森林(RF)^[3]等经典分类方法对复杂城市场景下的单点局部特征不敏感,导致分类效果不理想,将 RF 分类器集成到条件随机场(CRF)中并结合上下文信息的方法改进效果一般^[4]。此外,传统分类方法需要过多的人工干预,合适特征的选取受先验知识的影响,随机性较大且提取有效点云特征的能力有限,泛化性较差。卷积神经网络(CNN)在二维图像领域中具有强大的特征抽象能力,Su 等^[5]对点云数据在不同视角下进行投影,得到多个视角图后再利用 CNN 进行分类,但该方法使用的特征是某一视角下的全局特征,会导致信息丢失且存在投影误差。顾尚泰等^[6]采用分层墨卡托投影方式描述点云的局部特征,将特征点附近的相对几何关系投影到特征平面,但这种投影方式不可避免地会产生几何畸变。Le 等^[7-8]采用体素化编码方式对点云进行三维卷积并分类,但其指数级的内存增加不适用于密集点云。Charles 等^[9]将点云用张量形式表示后,直接对点云数据中的每个独立点进行卷积。先基于 T-Net 将点云转换到合适的分割角度,再利用共享参数的多层感知机(MLP)抽象独立点特征,最后采用最大池化(MaxPooling)对称函数对全局特征进行聚合。这种处理方式解决了点云数据的无序性,为深度学习在点云分类中的应用提供了新思路,但独立点卷积缺乏局部特征的学习过程。Qi 等^[10]设计了一种采样、分组、特征提取的层级结构,改善了局部信息缺失的问题,但在分组层中随机选择邻域点的策略导致无法准确描述邻域信息,且在特征提取层中仍以独立点卷积提取特征。白静等^[11-15]从多尺度、多分辨率、多源信息融合等方面进行局部特征描述,一定程度上弥补了独立点卷积的不足,但对邻域的描述仍然不准确。为了减少网络的复杂度及训练时间,雷相达等^[16]采用迁移学习结合全卷积网络的方法进行分类,但在数据处理过程中涉及到多投影特征图的生成及图割优化,流程复杂且只对小样本数据的效率提升比较明显,难以适用于城市大场景扫描数据。图是一

种特殊的数据结构,对非欧氏数据的表示十分有效,其结构形式包含了空间依赖关系,对点云数据具有较强的适用性。图的构造方法分为空间方法^[17]和谱方法^[18]两大类。空间方法以顶点和边描述每个点的空间关系,通过聚合边特征与顶点特征构造卷积内核。动态图卷积神经网络(DGCNN)在原始点云空间中构造图模型并在每一层抽象出的特征空间中重新构造图模型,其核心模块边卷积(EdgeConv)以动态方式聚合邻域边的特征。王江安等^[19]通过增加网络层数和残差连接方式改进了 DGCNN,可以更深入地描述抽象特征且顾及了更多的局部信息。谱方法以谱域图理论为基础,在谱域中定义图信号处理的滤波器,进而构造卷积内核。

针对上述方法中存在的问题及图卷积处理无序点云的优势,本文提出了一种融合图卷积的机载 LiDAR 点云深度学习分类方法。首先,根据邻域点的距离信息构造空间图以提取点云的空间域局部特征,利用 Chebyshev 多项式提取点云的谱域特征。然后,通过特征融合的方式进行点云数据的深层次特征抽象描述,实现全局特征和局部特征的有效提取。最后,经过空间金字塔池化(SPP)后得到融合特征描述符,利用 MLP 实现机载 LiDAR 点云的准确分类。

2 融合图卷积的机载 LiDAR 点云分类

2.1 融合图卷积的点云分类网络

为了解决 PointNet 缺乏局部特征的学习问题,通过谱方法和空间方法分别构造谱域图结构和空间域图结构,以抽象局部特征。该点云分类网络由三部分组成,分别是空间图(Spatial graph)卷积模块、谱域图(Spectral graph)卷积模块、基础模块,整体网络结构如图 1 所示。其中, N 为点的数量, M 为待分类的类别数量, D 为点云的维度, q 为 Chebyshev 多项式的阶数, K 为邻域点的数量, $S_1 \sim S_p$ 为 p 层空间金字塔池化层,dp 表示 dropout 层。空间图卷积模块采用 MLP 进行独立点特征提取,利用 K 最近邻(KNN)算子构造空间图并以距离为度量进行邻域划分,从而提取局部特征。该模块包含 4 个卷积层,先通过 2 个 64 维 MLP 将点云映射到低维度独立点浅层空间特征,再利用 2 层 KNN 在特征空间中构造图结构,将点云的低维独立点特征以欧氏距离为度量进行相关性描述。通过聚合邻域点的信息进行局部特征抽象,在 K 维池化后得到包含独立点与邻域点特征的高维映射(128 维)。谱域

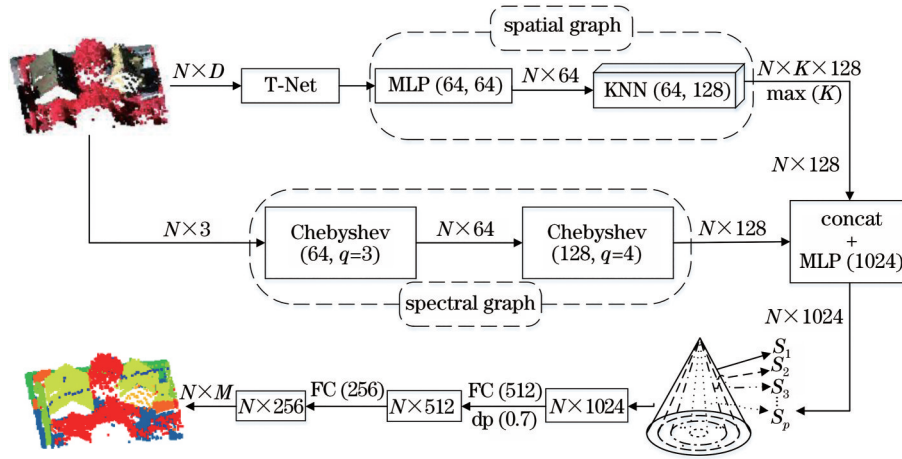


图 1 深度学习分类网络的结构

Fig. 1 Structure of the deep learning classification network

图卷积模块以 Chebyshev 多项式构造卷积核进行谱域图的特征提取,共包含 2 个谱域图卷积层。首先通过 3 阶 Chebyshev 多项式将 3 维点云映射到 64 维浅层谱域特征,再通过 4 阶 Chebyshev 多项式将 64 维谱域特征映射到 128 维的空间中,随着特征抽象层次的递进,多项式阶数的增加有利于全局特征的聚合。基础模块包括 T-Net 空间旋转网络、池化层和全连接层(FC)。

2.2 空间图卷积模块

设计图模型的目的是解决点云无法用固定大小卷积核进行学习的问题,从而寻找适用于非欧氏数据局部范围内的特征抽象方法。空间域图卷积以 CNN 加权求和为出发点,重点在于设计聚合函数聚集邻域点的特征。根据选择的指标寻找每个

顶点的邻域点,再由顶点和邻域点形成由点对构成的边,以邻接矩阵描述图的结构特征。通过层级递进的网路融合节点特征和结构特征,从而实现特征提取,其原理如图 2 所示。将输入点云中的每个点称为节点,用空心点表示,通过设计聚合函数利用无序点云的相关性构造出空间图结构。其中,箭头的指向为节点之间的相关性,箭头末端的节点为图顶点,虚线箭头表示点对构成的边,实心点表示每个邻域内的聚合边特征,实线箭头表示聚合边特征的来源,虚线圈为划分的邻域。由节点与节点之间的关联形成点对后根据点对构成边,再由某一规则对构造的空间图进行邻域划分,然后提取邻域内点的边特征,得到包含节点特征与结构特征的特征点,最后输出点云的代表性特征点。




图 2 空间域图卷积的原理

Fig. 2 Principle of the spatial domain graph convolution

对于点对生成的边,其 KNN 原理如图 3 所示。以逐点遍历的方式选择中心节点,并计算每个中心节点与其他点之间的欧氏距离,通过系数选取距离中心节点最近的 K 个点作为当前中心节点的邻域点,从而实现邻域节点的规范化。

若 x_i 为中心节点, x_{j_1}, \dots, x_{j_k} 为当前中心节点 x_i 的邻域点, e_{ij} 为 k 个邻域点与节点生成的边缘特征,图

模型的输出为节点所有有向边的特征聚合,可表示为

$$x_i = \sum_{j:(i,j) \in 1, \dots, k} h(x_i, x_j), \quad (1)$$

式中, h 为卷积操作 MLP, $h(x_i, x_j)$ 为边缘函数,可表示

$$h(x_i, x_j) = h_b(x_j - x_i), \quad (2)$$

式中, h_b 为对边缘描述的卷积操作 MLP。节点 x_i 的特征向量 e_{ij} 可表示为




图 3 KNN 的示意图

Fig. 3 Schematic diagram of the KNN

$$e_{ij} = g \left(\mathbf{w} \sum_{i=1}^k \mathbf{x}_{j_i} \right), \quad (3)$$

式中, \mathbf{w} 为节点分配的权重, g 为 MaxPooling 对称函数, 可用来聚合邻域点的特征向量。

2.3 谱域图卷积模块

谱域的图卷积将傅里叶变换和卷积迁移到图上, 拉普拉斯算子的物理定义为空间二阶导数, 可描述物理量的流入和流出。谱域图卷积利用图的拉普拉斯矩阵导出谱域的拉普拉斯算子, 核心工作就是将拉普拉斯算子的特征函数变为图对应的拉普拉斯矩阵的特征向量。给定一个包含 n 个数据点 $p_i, i = 1, \dots, n$ 的点集, 以 KNN 构造包含 k 个邻域点的边集合 E_p , 若 (p_i, p_j) 满足 $\left\{ (p_i, p_j) \mid p_j \in \{p_j \mid j = 1, \dots, k\} \right\}$, 则 (p_i, p_j) 为点对构成的边, $(p_i, p_j) \in E_p$, 拉普拉斯矩阵 \mathbf{L} 可表示为

$$\mathbf{L} = \mathbf{I}_n - \mathbf{D}^{-1/2} \mathbf{W}_p \mathbf{D}^{-1/2}, \quad (4)$$

式中, \mathbf{I}_n 为单位矩阵, \mathbf{D} 为度矩阵, \mathbf{W}_p 为点对在欧氏空间的距离或点对的卷积输出值在特征空间的距离确定的加权邻接矩阵, 可用高斯核函数表示为

$$\mathbf{W}_p(i, j) = \begin{cases} \exp \left(-\frac{\|p_i - p_j\|^2}{\sigma^2} \right), & (p_i, p_j) \in E_p \\ 0, & (p_i, p_j) \notin E_p \end{cases}, \quad (5)$$

式中, σ^2 为高斯函数的方差。假设一组 m 个可学习参数 $\delta_0, \dots, \delta_m$ 将输入的 \mathbf{x} 转换为输出 \mathbf{y} , 则谱域的图卷积可表示为

$$\mathbf{y} = h_\delta(\mathbf{L}) \mathbf{x} = \sum_0^m \delta_m \mathbf{L}^m \mathbf{x}_0. \quad (6)$$

若 $\mathbf{L} = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^T, \mathbf{U} = (\mu_1, \dots, \mu_n)$ 为 \mathbf{L} 的标准正交

特征向量, \mathbf{L} 的特征值 $\mathbf{\Lambda} = \text{diag}(\lambda_1, \dots, \lambda_n)$, 则谱域图卷积可表示为

$$\mathbf{y} = \mathbf{U} h_\delta(\mathbf{\Lambda}) \hat{\mathbf{x}}, \hat{\mathbf{x}} = \mathbf{U}^T \mathbf{x}_0. \quad (7)$$

深度学习中需要对谱域图卷积设计可学习的共享参数卷积核, 但特征向量矩阵 \mathbf{U} 的复杂度较高, 导致(7)式难以计算, 且面向数据量较大的点云构建 \mathbf{L} 并进行特征值分解的计算量也较大。基于文献[18]对谱域图卷积的简化方法, 采用 Chebyshev 多项式近似谱域图卷积的卷积核, 以降低计算复杂度、缓解计算机的内存压力, Chebyshev 多项式可表示为

$$C = \begin{cases} C_0(\mathbf{L}) = \mathbf{I}, t = 0 \\ C_1(\mathbf{L}) = \mathbf{L}, t = 1 \\ C_t(\mathbf{L}) = 2\mathbf{L}C_{t-1}(\mathbf{L}) - C_{t-2}(\mathbf{L}), t \geq 2 \end{cases}, \quad (8)$$

Chebyshev 多项式近似的卷积核可表示为

$$h_\delta(\mathbf{L}) = \sum_{i=0}^q \delta_i C_i(\hat{\mathbf{A}}), \quad (9)$$

式中, $\hat{\mathbf{A}} = 2\mathbf{L}/\lambda_{\max} - \mathbf{I}_n$ 为归一化特征值, λ_{\max} 为 \mathbf{L} 的最大特征值。不同图的拉普拉斯矩阵范围不同, 采取归一化方式构建卷积核有利于提高训练过程的稳定性。 q 为 Chebyshev 多项式的阶数, 可用来表示卷积核的感受野半径, 即将距离中心节点的 q 层节点作为邻域点。 $q = 1$ 及 $q = 2$ 时聚合中心节点的邻域信息情况如图 4 所示。




图 4 不同阶数下聚合的中心节点信息。(a) $q=1$; (b) $q=2$
Fig. 4 Central node information aggregated under different orders. (a) $q=1$; (b) $q=2$

2.4 基础模块

基础模块包括 T-Net 空间旋转网络、池化层、FC。T-Net 空间旋转网络的作用是将输入点云旋转到一个合适的角度进行分类, 通过数据规范对齐的方式实现点云的置换不变性, 空间旋转矩阵则通过网络学习得到。池化层采用了二维图像目标检测网络 SPP-Net^[20] 中的空间金字塔方法, 构造不同的池化窗口以捕获不同层次下的局部细粒度特征, 使网络对地物特征的描述更接近真实情况。FC 共

有 2 层,通过 512 维的 FC 对池化后的 1024 维融合特征进行降维,同时设置比率为 0.7 的 dropout 层防止模型在训练过程中出现过拟合,再利用 2 层 FC (256, M) 得到输入点云对应 M 个类别的概率矩阵,实现点云分类。

3 实验仿真

3.1 实验仿真数据

用国际摄影测量与遥感协会 (ISPRS) 提供的德国 Vaihingen 小镇 3D 语义标签竞赛数据集作为实验仿真数据,包括机载 LiDAR 扫描点云和多光谱航空影像,如图 5、图 6 所示。数据覆盖区域地物类型复杂,可用来验证城市大场景下点云地物分类方法的精度。

多光谱航空影像包含近红外 (IR)、红色 (R)、绿色 (G) 三通道信息,地面分辨率为 8 cm,每张影像的尺寸为 7680 pixel \times 13824 pixel,每平方米约包含 4 个扫描点云,每个激光点包含三维点坐标、激光强度、回波次数和对应的语义标签类别。数据集中共有 1165598 个点,包含电力线 (p_l)、低矮植被 (l_v)、不透水层 (i_s)、车辆 (car)、栅栏 (f_h)、屋顶 (r_f)、外墙 (f_e)、灌木 (s_b)、树 (t_e) 9 个地物类别。将 753876 个点作为训练数据 (Training data), 411722 个点作为测试数据 (Testing data), 各类别点的数量如表 1 所示。

为了扩充有限的信息量,利用共线方程^[11]对扫描点云进行光谱特征融合,融合光谱信息后的训练数据和测试数据如图 7 所示。

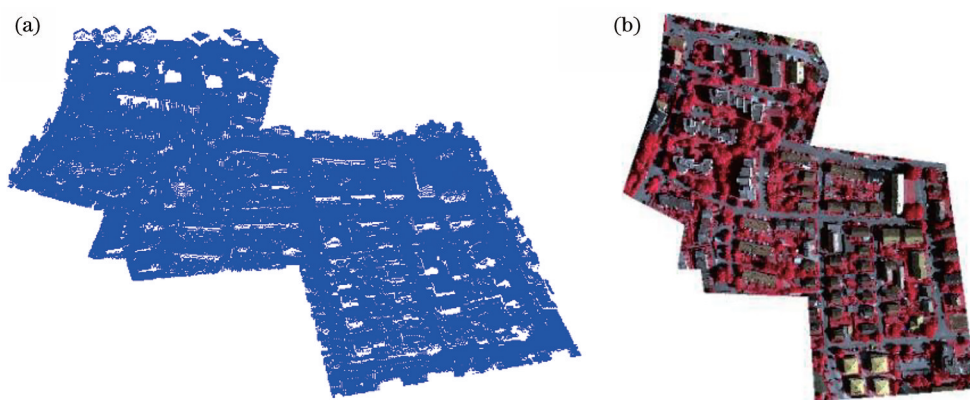


图 5 训练数据及对应区域的多光谱航空影像。(a)点云;(b)航空影像

Fig. 5 Training data and multispectral aerial image of corresponding region. (a) Point cloud; (b) aerial image




图 6 测试数据及对应区域的多光谱航空影像。(a)点云;(b)航空影像

Fig. 6 Testing data and multispectral aerial images of corresponding region. (a) Point cloud; (b) aerial image

表 1 Vaihingen 数据集中各类地物点的数量

Table 1 Number of various classes points in Vaihingen data set

Class	p_l	l_v	i_s	car	f_h	r_f	f_e	s_b	t_e
Training data	546	180850	193723	4614	12070	152045	27250	47605	135173
Testing data	600	98690	101986	3708	7422	109048	11224	24818	54226




图 7 点云数据与光谱影像的融合结果。(a)训练数据;(b)测试数据

Fig. 7 Fusion result of point cloud data and spectral images. (a) Training data; (b) testing data

3.2 实验仿真环境

实验的硬件环境: Inter Core i7-9700、GTX1660 Ti 6 G 显存、16 G RAM 联想 GeekPro 台式机。软件环境: 系统为 Windows 10(64 位)、CUDA8.0、cuDNN5.1、TensorFlow1.0、Python3.5。

3.3 仿真数据的多尺度采样

深度网络在训练过程中需要足够多的数据量更新权重。城市场景下的机载 LiDAR 点云密度分布不均匀,为了尽可能地不破坏地物的完整性,在减少地物尺寸对分类精度影响的同时扩增有限的的数据量,用多尺度网格策略对数据进行采样。首先,设置网格采样点阈值对整个区域进行网格划分,当网格内的点数量小于阈值时,随机复制网格内的点使其达到阈值;当网格内的点数量大于阈值时,用不放回抽样的方式将点数量降采样到阈值。实验采用尺寸为 10 m 的正方形网格对数据进行划分,设置的采样阈值为 1024,网格在数据区域的滑动步长为 5 m,从而实现多尺度网格采样,采样示意图如图 8 所示。



图 8 多尺度采样示意图

Fig. 8 Schematic diagram of multiscale sampling

3.4 分类网络参数

分类网络中的参数:将 KNN 模块的 K 设置为 20,空间金字塔池化模块中的池化窗口为 N 、 $N/2$ 、 $N/4$ 、 $N/8$ 、 $N/16$,其中, $N \times 1024$ 为待池化的特征图

尺寸, N 为特征图的高,池化步长与窗口尺寸相同。网络训练过程中相同的学习率无法适用所有参数的更新,因此,基于 Adam 方法用不同参数计算不同的学习率,以提高训练精度及效率,设置的初始学习率为 0.001。网络中每层卷积层后均设置批归一化(BN)层,同时在全连接层中设置比例为 0.7 的 dropout 层,防止模型出现过拟合。选用线性整流单元(ReLU)作为激活函数,避免反向传播过程中出现梯度弥散情况。

3.5 分类结果的评价指标

总体精度(X_{OA})可衡量所有类别地物作为一个整体的准确度,定义为整个测试数据集中正确分类点数占所有点数的比例;精确度(P)为预测结果中类别为正的点数占预测为正点数的比例;召回率(R)为原始数据中预测类别为正的点数占类别为正的点数的比例;F1 分数(F_1)是精确度和召回率的调和均值,适用于评估分布不均的数据。因此,用总体精度、精确度、召回率、F1 分数评价分类结果,可表示为

$$X_{OA} = \frac{X_{TP} + X_{TN}}{X_{TP} + X_{TN} + X_{FP} + X_{FN}}, \quad (10)$$

$$P = \frac{X_{TP}}{X_{TP} + X_{FP}}, \quad (11)$$

$$R = \frac{X_{TP}}{X_{TP} + X_{FN}}, \quad (12)$$

$$F_1 = 2 \times \frac{P \times R}{P + R}, \quad (13)$$

式中, X_{TP} 为正样本被正确判定为正样本的点数, X_{TN} 为负样本被正确判定为负样本的点数, X_{FN} 为正样本被错误判定为负样本的点数, X_{FP} 为负样本被错误判定为正样本的点数。

4 实验结果与分析

4.1 实验结果

原始数据标签及本方法的分类结果如图 9 所

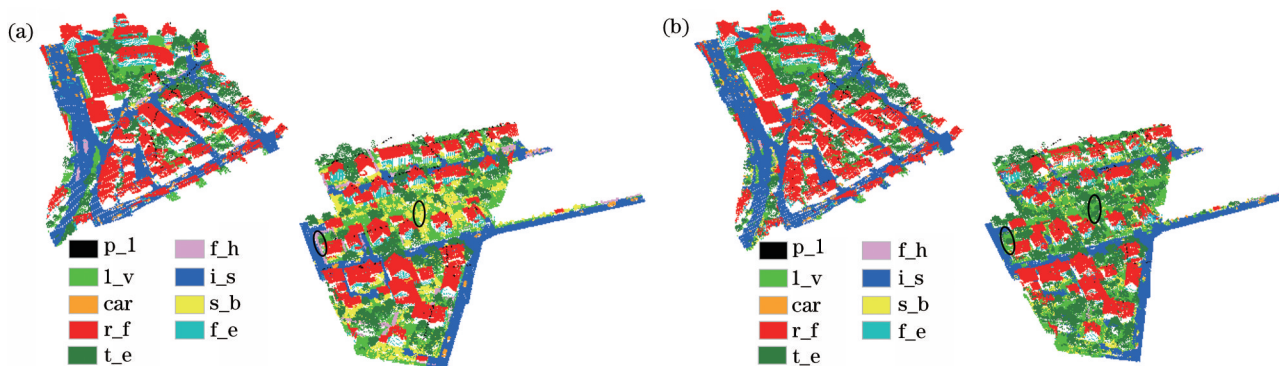


图9 测试数据标签及分类结果。(a)真实标签;(b)本方法的分类结果

Fig. 9 Testing data labels and classification results. (a) True label; (b) classification result of our method

示,对比发现,本方法对大部分数据点进行了正确预测,但对部分地物的区分存在一定欠缺。椭圆区域为两处明显的错误分类,分别是将栅栏错分为低矮植被和将灌木错分为树。

本方法的分类结果误差图如图10所示,其中,椭圆区域中的错误分类较为集中。对比标签发现,错分集中区域均为树、低矮植被、灌木3种地物的混合区域,而城市场景中这3种地物都具有单体结构特征复杂且相近的特点,对分类方法提出了更高的要求。

为了量化本方法的分类效果,给出了分类结果的混淆矩阵并计算其精确度、召回率、F1分数,结果如表2所示。可以发现,本方法的总体分类精度为84.3%。在不透水层和屋顶类别的F1分数均超过了90%,分别达到91%和93.7%,在树和低矮植被类别的F1分数达到80%左右。而对电力线、车辆,外墙类别的F1分数在50%~70%之

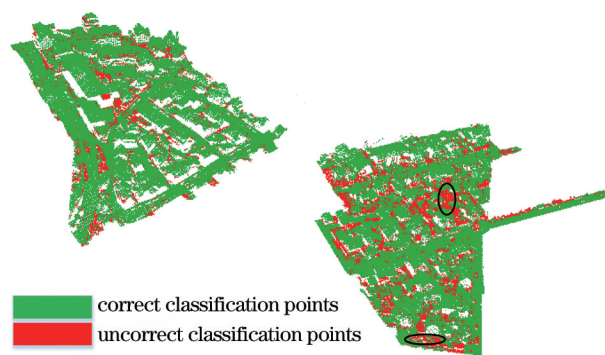


图10 分类结果的误差图

Fig. 10 Error map of the classification result

间,效果一般。在栅栏和灌木类别上的分类性能相对较低,F1分数均低于30%。从混淆矩阵可以发现,分类效果一般的外墙主要受屋顶的影响,而树对灌木和栅栏类别的区分均造成了较大影响,具体表现为较多的栅栏地物点和灌木地物点被错分为树。

表2 分类结果的混淆矩阵及评价指标

Table 2 Confusion matrix and evaluation indexes of the classification result

unit: %

Class	p_l	l_v	i_s	car	f_h	r_f	f_e	s_b	t_e
p_l	60.6	0.2	0.0	0.0	0.0	27.2	3.6	0.0	8.5
l_v	0.0	79.3	10.5	0.4	0.4	0.9	0.7	2.9	4.9
i_s	0.0	6.4	92.0	0.3	0.0	0.8	0.1	0.1	0.2
car	0.0	9.9	11.3	55.0	3.4	5.4	5.4	5.5	4.0
f_h	0.0	25.7	3.8	0.2	19.3	9.2	1.1	11.3	29.3
r_f	0.1	1.2	0.9	0.0	0.0	93.9	1.7	0.2	1.9
f_e	0.2	6.4	2.4	1.3	0.1	26.2	48.6	3.2	11.6
s_b	0.0	18.7	2.3	0.6	1.0	3.4	1.5	19.1	53.3
t_e	0.0	3.1	0.5	0.1	0.1	3.3	1.3	0.9	90.6
Precision	80.9	80.9	90.1	66.5	64.1	93.5	53.4	41.5	70.1
Recall	60.6	79.3	92.0	55.0	19.3	93.9	48.6	19.1	90.6
F1 score	69.3	80.1	91.0	60.2	29.6	93.7	50.9	26.1	79.1

4.2 分类实验的对比分析

为验证融合图卷积方法的可行性及有效性,用 2 种方案进行对比分析与分类结果评价:1)与仅以独立点卷积的 PointNet、以空间方法构造图的 DGCNN 及分组采样的 PointNet++ 进行对比实验,以验证本方法对缺乏局部特征问题的改进效果;2)将本方法的分类结果与其他针对城市大场景下的激光点云数据研究成果进行对比,以验证本方法对这类数据的适用性。

本方法与 PointNet、DGCNN 及 PointNet++ 的分类结果误差图如图 11 所示,椭圆区域为具有明显差异的地物错分情况。从图 11(a)可以发现,独

立点卷积的方式对复杂城市场景下的地物特征不敏感,难以实现对有效特征的提取,且忽略点云相关性方法的分类结果较差。从图 11(b)可以发现,以空间方法构造图结构顾及了点云数据的邻域信息,提取了局部特征,相比 PointNet 有一定改进,但分类结果仍然不理想。从图 11(c)可以发现,以采样、分组进行不同邻域划分的 PointNet++ 分类效果较好,但每个划分的邻域内仍以独立点进行卷积,面对地物类别较多的场景改善效果一般。从图 11(d)可以发现,本方法在提取空间局部特征的同时也加深了谱特征描述,融合特征取得了更好的分类结果。

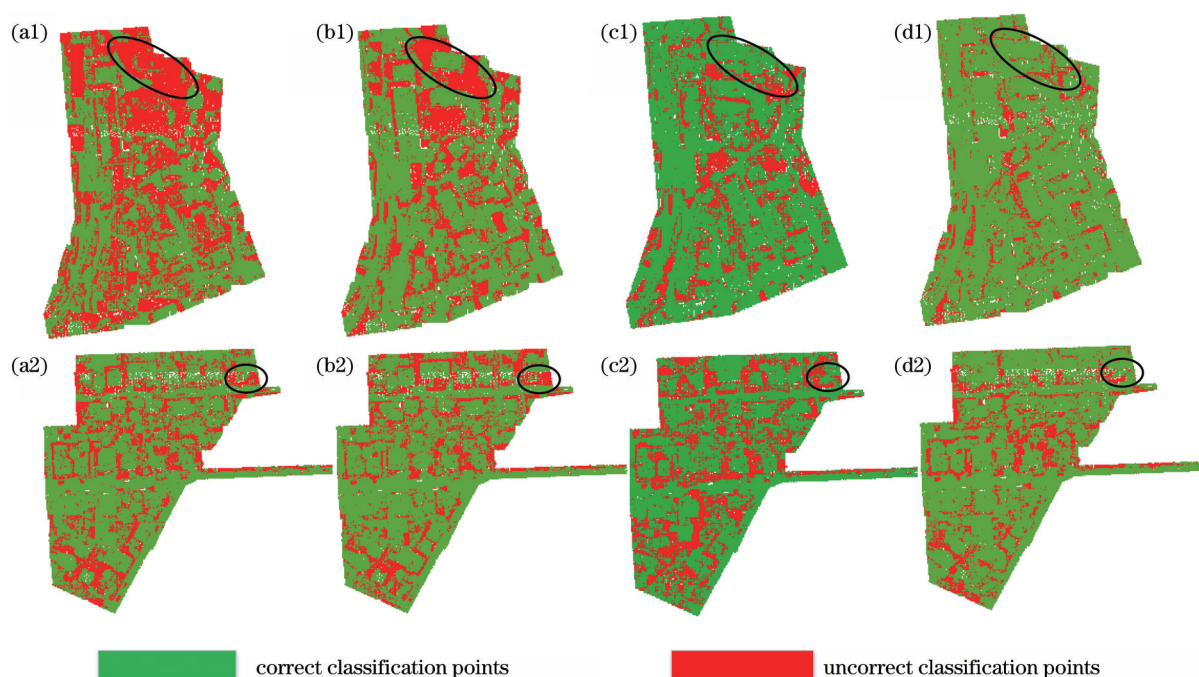


图 11 不同方法的分类结果误差图。(a) PointNet; (b) DGCNN; (c) PointNet++; (d) 本方法

Fig. 11 Error maps of classification results of different methods. (a) PointNet; (b) DGCNN; (c) PointNet++; (d) our method

不同方法在 9 种地物上的评价指标均值如表 3 所示,可以发现,本方法对所有地物的分类精确度均优于 PointNet,除了低矮植被和树外也都优于 DGCNN, PointNet++ 仅在类别车上优于本方法。此外,本方法的总体精度分别比 PointNet、DGCNN、

PointNet++ 提升了 23.4、13.7、10.7 个百分点, F1 分数均值分别提升了 30.8、22.8、14.3 个百分点,这验证了融合图卷积方法的可行性和有效性。

ISPRS 官方网站中 (<https://www2.isprs.org/commissions/comm2/wg4/results/vaihingen->

表 3 不同方法的定量评价指标

Table 3 Quantitative evaluation index of different methods

unit: %

Method	p_l	l_v	i_s	car	f_h	r_f	f_e	s_b	t_e	OA	F1 score
PointNet	1.7	68.9	77.6	30.6	16.7	69.1	6.8	33.3	46.5	60.9	33.6
DGCNN	80.3	81.2	78.9	26.8	52.0	67.1	18.9	31.1	79.5	70.6	41.6
PointNet++	71.5	72.0	90.0	68.3	16.7	74.0	38.4	39.2	52.7	73.6	50.1
Ours	80.9	80.9	90.1	66.5	64.1	93.5	53.4	41.5	70.1	84.3	64.4

3d-semantic-labeling, 2021 年 7 月 20 日) 提供了不同研究方法的实验结果, 部分方法的实验结果与本方法在相同数据集中每个类别对应的 F1 分数、总体精度如表 4 所示。可以发现, UM 方法通过纹理分析和几何属性进行点云特征提取, 弊端在于监督机器学习的方式过于依赖先验知识。WhuY3 方法基于激光点提取窗口内的几何、波形特征, 利用特征生成的图像作为 CNN 模型的输入实现分类, 但使用的数据投影方式造成了数据本身的信息缺失。BIJ_W 方法基于距离最小生成树的池化方式抽象激光点之间的空间信息, 缺乏点簇的局部特征有效表示。RIT_1

方法应用归一化激光点及光谱数据以端到端的方式隐式学习上下文特征, 但一维全卷积网络对非结构化数据的局部特征抽象能力较弱。文献[21]提出的方向约束全卷积神经网络 D-FCN, 其核心模块 D-Conv 从投影的二维感受野中提取三维点云的局部代表性特征, 结合投影处理方式的分类精度为 82.2%, F1 分数均值为 70.7%。而本方法直接对点云数据进行卷积, 无须额外引入二维投影的点云特征, 复杂度上优于文献[21]的方法, 分类精度为 84.3%, F1 分数均值为 64.4%, 总体精度相对较高, 验证了空间图结构与谱域图结构相结合方法的有效性。

表 4 本方法与现有方法的分类结果

Table 4 Classification results of our method and existing methods

unit : %

Method	p_l	l_v	i_s	car	f_h	r_f	f_e	s_b	t_e	OA	F1 score
UM	46.1	79.0	89.1	47.7	5.2	92.0	52.7	40.9	77.9	80.8	59.0
WhuY3	37.1	81.4	90.1	63.4	23.9	93.4	47.5	39.9	78.0	82.3	61.6
BIJ_W	13.8	78.5	90.5	56.4	36.3	92.2	53.2	43.3	78.4	81.5	60.3
RIT_1	37.5	77.9	91.5	73.4	18.0	94.0	49.3	45.9	82.5	81.6	63.3
Ref. [21]	68.4	80.2	91.4	78.1	37.0	93.0	60.5	46.0	79.4	82.2	70.7
Ours	69.3	80.1	91.0	60.2	29.6	93.7	50.9	26.1	79.1	84.3	64.4

5 结 论

提出了一种融合图卷积的深度学习点云分类方法, 该方法改进了 PointNet 的弊端。首先, 融合点云的光谱信息扩增原始信息量; 然后, 采用多尺度网格采样缓解点云数据密度不均带来的影响; 最后, 通过融合空间图结构和谱域图结构抽象的特征并以空间金字塔池化加深细粒度描述, 实现城市场景下机载 LiDAR 点云的准确分类。对相关理论和具体流程进行了详细阐述, 通过仿真实验验证了本方法的有效性。实验结果表明, 融合图卷积的方式顾及了更多的局部特征, 对复杂场景的描述更加深入, 能取得更好的分类效果。相比现有方法, 本方法在不预先设计特征的前提下取得了较高的分类精度, 但对于 F1 分数的提升仍有进步空间。

参 考 文 献

- [1] Zhang J X, Lin X G, Liang X L. Advances and prospects of information extraction from point clouds [J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(10): 1460-1469.
张继贤, 林祥国, 梁欣廉. 点云信息提取研究进展和展望[J]. 测绘学报, 2017, 46(10): 1460-1469.
- [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. Contextual classification of lidar data and building object detection in urban areas[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 87: 152-165.
- [5] Su H, Maji S, Kalogerakis E, et al. Multi-view convolutional neural networks for 3D shape recognition[C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 945-953.
- [6] Gu S T, Wang L, Ma Y X, et al. Local feature description of LiDAR point cloud data based on hierarchical Mercator projection[J]. Acta Optica Sinica, 2020, 40(20): 2015001.
顾尚泰, 王玲, 马燕新, 等. 基于分层墨卡托投影的

- 激光雷达点云数据局部特征描述[J]. 光学学报, 2020, 40(20): 2015001.
- [7] Le T, Duan Y. PointGrid: a deep network for 3D shape understanding[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 9204-9214.
- [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 Press, 2015: 922-928.
- [9] 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, USA. New York: IEEE Press, 2017: 77-85.
- [10] 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, December 4-9, 2017, Long Beach, CA, USA. [S.l.: s.n.], 2017: 5099-5108.
- [11] Bai J, Xu H J. MSP-Net: multi-scale point cloud classification network[J]. Journal of Computer-Aided Design & Computer Graphics, 2019, 31(11): 1917-1924.
白静, 徐浩钧. MSP-Net: 多尺度点云分类网络[J]. 计算机辅助设计与图形学学报, 2019, 31(11): 1917-1924.
- [12] 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.
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.
- [13] Kowalczyk Z, Szymański K. Classification of objects in the LiDAR point clouds using deep neural networks based on the PointNet model[J]. IFAC-PapersOnLine, 2019, 52(8): 416-421.
- [14] 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.
- [15] Shi X S, Cheng Y L, Xue D D, et al. Object classification method for multi-source fusion point clouds based on Point-Net[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081019.
释小松, 程英蕾, 薛豆豆, 等. 基于 Point-Net 的多源融合点云地物分类方法[J]. 激光与光电子学进展, 2020, 57(8): 081019.
- [16] Lei X D, Wang H T, Zhao Z Z. Small-sample airborne LiDAR point cloud classification based on transfer learning and fully convolutional network[J]. Chinese Journal of Lasers, 2021, 48(16): 1610001.
雷相达, 王宏涛, 赵宗泽. 整合迁移学习与全卷积网络的小样本机载激光雷达点云分类[J]. 中国激光, 2021, 48(16): 1610001.
- [17] Wang Y, Sun Y B, Liu Z W, et al. Dynamic graph CNN for learning on point clouds[J]. ACM Transactions on Graphics, 2019, 38(5): 1-12.
- [18] Zhang Y X, Rabbat M. A graph-CNN for 3D point cloud classification[C]//2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), April 15-20, 2018, Calgary, AB, Canada. New York: IEEE Press, 2018: 6279-6283.
- [19] Wang J A, He J, Pang D W. Point cloud classification and segmentation network based on dynamic graph convolutional network[J]. Laser & Optoelectronics Progress, 2021, 58(12): 1215008.
王江安, 何娇, 庞大为. 基于动态图卷积网络的点云分类和分割网络[J]. 激光与光电子学进展, 2021, 58(12): 1215008.
- [20] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [21] Wen C C, Yang L N, Li X, et al. Directionally constrained fully convolutional neural network for airborne LiDAR point cloud classification[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 162: 50-62.