

基于多尺度特征和 PointNet 的 LiDAR 点云地物分类方法

赵中阳¹, 程英蕾^{1*}, 释小松¹, 秦先祥¹, 李鑫²

¹空军工程大学信息与导航学院, 陕西 西安 710077;

²东北电力大学理学院, 吉林 吉林 132000

摘要 针对复杂场景下激光雷达测量(LiDAR)点云数据的地物分类问题,提出了一种基于多尺度特征和 PointNet 的深度神经网络模型,该方法改进了 PointNet 提取局部特征的能力,实现了复杂场景下 LiDAR 点云的自动分类。在 PointNet 网络基础上添加多尺度网络提取点的局部特征,将不同尺度点的局部特征通过全连接层组成一个多维特征,并与 PointNet 提取的全局特征相结合,返回每个点类的分数以完成点云分类标签。利用 Semantic 三维数据集和 ISPRS 提供的 Vaihingen 数据集,验证了所提深度神经网络模型。研究结果表明,与其他用于点云分类的神经网络相比,所提算法达到了更高的分类精度。

关键词 遥感; 激光雷达测量; 点云分类; 多尺度特征; PointNet

中图分类号 P237

文献标识码 A

doi: 10.3788/LOP56.052804

Terrain Classification of LiDAR Point Cloud Based on Multi-Scale Features and PointNet

Zhao Zhongyang¹, Cheng Yinglei^{1*}, Shi Xiaosong¹, Qin Xianxiang¹, Li Xin²

¹Information and Navigation College, Air Force Engineering University, Xi'an, Shaanxi 710077, China;

²School of Science, Northeast Electric Power University, Jilin, Jilin 132000, China

Abstract For the terrain classification problem of light detection and ranging (LiDAR) point cloud data in complex scenes, a deep neural network model based on multi-scale features and PointNet is proposed. The method improves the ability of PointNet to extract local features and realizes the automatic classification of LiDAR point cloud under complex scenes. Multi-scale network on the basis of PointNet network is added to extract the local features of points, and the local features of different scale points are formed into a multi-dimensional feature through the full connection layer, and combined with the global features extracted by PointNet, the score of each point class is returned to complete the point cloud classification label. The proposed deep neural network model is verified by using the Semantic three-dimensional dataset and the Vaihingen dataset provided by ISPRS. The research results show that the proposed algorithm achieves higher classification accuracy compared with other neural networks for point cloud classification.

Key words remote sensing; light detection and ranging; classification of point cloud; multi-scale features; PointNet

OCIS codes 280.3640; 100.4996; 100.6890

1 引言

激光雷达测量(LiDAR)是一种将激光测距、动态全球定位系统(GPS)差分以及惯性导航姿态测定

高度集成的技术^[1]。LiDAR 技术通过主动向目标发射激光脉冲来获取多种目标信息,例如点位信息、距离信息、目标反射物材质信息等^[2],对三维(3D)城市建模和城市规划、森林资源调查、灾害评估、变

收稿日期: 2018-09-04; 修回日期: 2018-09-10; 录用日期: 2018-09-21

基金项目: 国家自然科学基金(41601436)、陕西省自然科学基金(2018JM4029)

* E-mail: ylcheng718@163.com

化检测等民用领域应用和目标识别、精确制导等军事应用有着非常重要的作用。LiDAR 点云数据应用的关键是 LiDAR 点云数据的分类。

LiDAR 点云数据分类方法目前主要有两类：1) 基于特征提取的分类方法。一般通过提取点云数据高程、强度、回波次数等信息, 以及其他空间信息设计特征来进行分类。如吴军等^[3]提取了点云高程 Z 坐标 (LH)、高程变化率 (HV)、平面拟合误差 (PFE) 以及回波强度 (LRI) 4 个特征, 然后利用加权支持向量机 (W-SVM) 分类器进行分类。MacFaden 等^[4]利用 LiDAR 高度数据生成了 4 个 GLCM 度量 (即均匀性、对比度、熵和相关性), 实现三种不同类别的土地覆盖分类。何曼芸等^[5]融合航空影像光谱特征与 LiDAR 点云几何特征对建筑物进行提取。程效军等^[6]利用颜色对点云的强度信息进行补充, 提高点云的分类精度。2) 机器学习的方法, 训练分类器进行分类, 常用的分类器包括随机森林、支持向量机 (SVM)、Joint Boost 和深度学习等。文献^[7]在分析点云场景基础上, 提取点云的 26 个几何特征, 同时考虑一定空间先验信息利用 Joint Boost 实现场景分类。文献^[8-9]将点云转化成体素网格, 在体素网格上应用三维卷积神经网络进行点云分类和分割, 然而点云体素网格表示由于点云数据的稀疏性和三维卷积的计算成本受到其体素分辨率限制, 且体素网格表示会产生信息损失, 分类精确度会受到影响。文献^[10-11]将三维点云投影到二维 (2D) 图像中, 应用 2D 卷积神经网络进行分类。Charles

等^[12]提出了一种新型网络体系结构 PointNet, 直接使用原始点云作为输入而不将其转换为其他格式。

目前在利用深度学习对点云进行分类的研究中, 对点云进行体素化或投影到 2D 图像处理会产生信息损失, 直接将点云作为输入的 PointNet 网络在局部特征提取能力上稍弱。因此, 本文在 PointNet 的基础上, 对网络进行改进, 提出构建多尺度邻域的深度神经网络模型, 将不同尺度邻域提取的局部特征与 PointNet 提取得到的全局特征结合, 增强网络对点云中点局部信息的利用, 实现 LiDAR 点云数据大规模场景分类并提高分类精度。

2 算法描述

PointNet 网络对点云局部特征描述能力稍弱, 因此对 PointNet 网络进行改进, 在 PointNet 网络基础上, 增加多尺度网络结构提取点的局部特征, 提高点云分类精度。算法以原始点云作为网络输入, 通过三个不同尺度对点云中的每个点选取邻域, 利用 PointNet 提取邻域特征作为每个点的局部特征, 将不同尺度下的局部特征通过全连接层组合, 并与 PointNet 从原始点云中提取的全局特征结合, 最后返回每个点的分类结果。具体神经网络模型如图 1 所示, 图中神经网络输入为点云三维坐标 (x, y, z) , T-net 为空间变换矩阵预测网络, MLP 为多层感知机, D, D', D'' 为特征维数, C 表示全连接层, max pool 为最大池化层, 最后输出为每个点的 M 个类别分数。

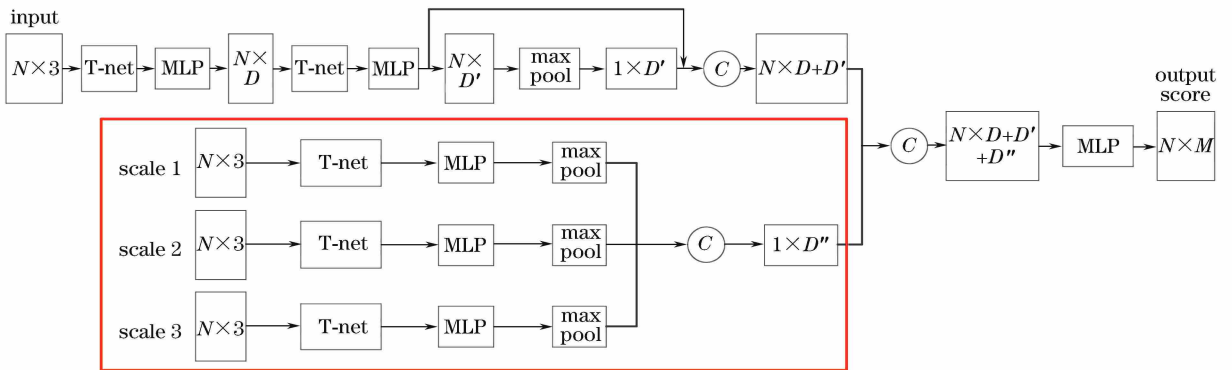


图 1 多尺度特征与 PointNet 结合的深度神经网络模型

Fig. 1 Deep neural network model combining multiscale features with PointNet

2.1 PointNet

所提方法是在 PointNet 网络结构基础上对机载 LiDAR 点云数据进行分类的。PointNet 是一种直接处理无序点云数据的深度神经网络。一般情况下, 深度神经网络要求输入信息具有规范化的格

式, 比如 2D 图像、时序性的语音等。而原始 3D 点云数据通常是空间中一些无序点集, 假设某一个点云中包含 N 个 3D 点, 每一个点用 3D 坐标 (x, y, z) 表示, 即使不考虑遮挡、视角等变化, 单就这些点的先后顺序排列组合, 就有 $N!$ 种可能。因此需要

设计一个函数,使得函数值与输入数据的顺序无关。实际上,在代数组组合学中,这类函数称为对称函数。PointNet 中,使用 max pooling 层作为主要对称函数,这种处理虽然简单,但是实验证明效果较好。PointNet 网络表示为

$$f(x_1, x_2, \dots, x_n) = \gamma \left\{ \max_{i=1, \dots, n} [h(x_i)] \right\}, \quad (1)$$

式中: x_1, x_2, \dots, x_n 是输入的无序点云; $x_i \in \mathbf{R}^d$, \mathbf{R} 表示实数, d 表示维度; n 表示输入的点的数量; x_i 表示输入点云中的第 i 个点; f 为连续集函数,将一组点映射到一个向量; γ 和 h 都是连续函数,代表了多层感知机 (MLP) 网络。(1) 式中连续集函数 f 对输入点的排列不变,并且可以近似任意连续集函数,输入点中少量的噪声点对函数值没有

影响。

图 2 是 PointNet 网络架构,输入是包含 N 个点的 3D 点云的 3D 坐标 ($N \times 3$), 原始数据通过一个 3D 空间变换矩阵预测网络 T-net(3), 估计出 3×3 的变换矩阵 $\mathbf{T}(3)$ 并作用在原始数据上, 实现数据的对齐。对齐后的数据以点为单位, 通过一个共享参数的 MLP 模型 (64, 64) 进行特征提取。每个点提取出 64 维特征, 再通过特征空间变换矩阵预测网络 T-net(64) 预测 64×64 变换矩阵, 作用到特征上, 实现特征的对齐。然后继续利用三层感知机 (64, 128, 1024) 进行以特征点为单位的特征提取, 直到把特征的维度变为 1024, 再通过最大池化层提取出点云的全局特征向量。

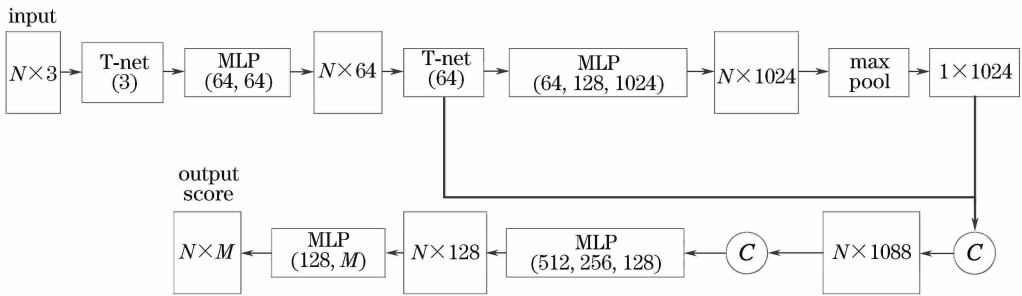


图 2 PointNet 网络架构

Fig. 2 PointNet network architecture

PointNet 中将经过特征对齐后的 64 维特征看作点的特征, 把最后的 1024 维特征看作点的全局特征。因此, 通过简单的拼接, 将局部和全局特征捆绑在一起得到 1088 维特征, 利用 MLP 进行融合, 将特征维数降为 128, 最后训练分类器输出每个点对应 M 个类别的分数, 实现逐点的分类。

PointNet 网络中的 T-net 是一个预测特征空间变换矩阵的子网络, 它从输入数据中学习出与特征空间维度一致的变换矩阵, 然后与原始数据相乘, 实现对输入特征空间的变换操作, 使得后续的每一个点都与输入数据中的点有关系。通过数据融合, 实现对原始点云数据包含特征的逐级抽象。

2.2 多尺度的生成

PointNet 提取每一个独立点的特征描述以及全局点云特征的描述, 并没有考虑点的局部特征和结构约束, 因此与多视图卷积神经网络 (MVCNN)^[10] 等其他神经网络相比, 其在局部特征描述方面的能力稍弱。先为点云中的点选取邻域, 再利用 PointNet 网络提取邻域内点的特征, 作为点的局部特征增强 PointNet 网络对点局部特征的描述能力。

将不同尺度邻域下提取的局部特征通过组合作为点的局部特征, 并应用于 PointNet 网络, 提高机载 LiDAR 点云分类精度。

Lindeberg^[13] 提出了尺度空间及对于图像进行多尺度表示的基本概念, 并且通过大量数学证明和运算对该概念进行了完善和发展。生成尺度空间的目的是模拟图像数据多尺度特征, 在尺度空间中进行多尺度分析更容易获得图像的本质特征^[14]。在获得的机载 LiDAR 点云数据中, 将邻域视为一个尺度参数, 改变邻域大小相当于对 LiDAR 点云应用一个平滑滤波器。因此, 可以通过改变邻域大小建立尺度空间, 进行多尺度分析。对 LiDAR 点云中每个点 p 处建立半径为 r 的空间球 s , 若点 p 的近邻点在此空间球内, 则利用 PointNet 网络提取空间球内点的特征。通过改变半径 r 的大小, 形成不同大小的空间球, 得到点 p 不同大小的邻域, 从而建立不同的尺度, 不同大小的邻域组成了一个尺度空间。

图 3 所示为点云中不同尺度下构建的邻域情况, 蓝色点为邻域内的点。由于机载 LiDAR 扫描方式导致点云数据并不是均匀的, 不同区域点的密




图3 点云中不同尺度下的邻域。(a)尺度一;(b)尺度二;(c)尺度三

Fig. 3 Neighbors of different scales in point clouds. (a) Scale 1; (b) scale 2; (c) scale 3

度不同,同一目标的不同位置点的密度也不同。当选取单一大小尺度时,尺度过小会导致部分邻域内的点过少,影响对局部特征的提取效果。而且点云中不同的尺度能够提取不同维度的特征^[15],图3中第一个尺度提取一维特征,第二个尺度提取2D特征,第三个尺度提取3D特征。因此,需要对不同尺度的局部特征进行组合,增强对点局部特征的描述能力,满足对稀疏和密度不均匀的LiDAR点云分类的要求。

不同数据具有不同的点云密度,因此尺度大小对于不同的激光点云数据也不相同。由于点云的密度越大,点云的平均点距越小,所以根据点云的平均点距确定尺度大小。首先利用八叉树组织点云计算点云的平均点距 d_m ,然后将最小尺度层级 L_1 (所提用 L_i 表示不同的尺度层级,其中序号 $i=1\sim n$, n 为最大尺度层级)根据点云的平均点距来增强适应性^[16],即

$$L_1 = s d_m, \quad (2)$$

式中 s 为放大因子。确定最小尺度层级 L_1 后,同样利用放大因子 s 确定其他尺度层级,比如,所提取最大尺度层级为3,放大因子 $s=2$,则

$$\begin{cases} L_1 = 2d_m \\ L_2 = 2^2 d_m \\ L_3 = 2^3 d_m \end{cases} \quad (3)$$

2.3 多尺度网络架构

完整的多尺度网络架构如图1所示,红框中为多尺度提取点局部特征的网络结构。采用三个不同尺度构建点云中每个点的邻域,对于每个尺度下的网络,输入为该尺度下邻域内的点,同样采用PointNet网络架构,对输入的点采用T-net(3)网络进行变换,然后通过双层感知机(64,128)对邻域内点的特征进行提取。采用max-pooling层作为对称函数,提取出 1×384 维点的局部特征,再利用全连接层网络将三个尺度下学习到的特征组合为

一个多尺度特征。该多尺度特征作为点的局部特征与PointNet提取的特征结合,完成对每个点的分类。

由于机载LiDAR点云数据的稀疏性,当网络在进行参数更新时,相同的学习率不能适应所有参数更新。使用梯度下降算法及其变体随机梯度下降(SGD)会影响网络训练的效率 and 精度,因此所提神经网络使用Adam优化算法。

Adam最开始是由Kingma等^[17]提出。Adam优化算法是SGD算法的扩展式,近来广泛用于深度学习,尤其是计算机视觉和自然语言处理等任务中。Adam是一种替代传统SGD过程的一阶优化算法,能基于训练数据迭代地更新神经网络权重。

同时神经网络使用ReLU和Softmax分别作为激活函数和损失函数,ReLU在2016年被提出^[18],其数学表达式为

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (4)$$

Softmax函数是Logistic函数的推广,用于多分类,正确类别得分的概率表示为

$$S_k = \frac{\exp(f_k)}{\sum_j \exp(f_l)}, \quad (5)$$

式中: f_k, f_l 分别为Softmax函数输入向量的第 k, l 个值; S_k 为函数输出向量 S 的第 k 个值,表示该样本属于第 i 个类别的概率。

3 实验仿真及结果

使用两种LiDAR数据集对所提出的神经网络进行评估,一是Semantic 3D户外数据集^[19],二是ISPRS提供的德国Vaihingen城市测试数据集。

Semantic 3D数据集是一个大型户外数据集,使用地面激光扫描仪获得,总共包含40亿个点。数据集包含了各种城市和乡村场景,如农场、市政厅、

运动场、城堡和广场。该数据集包含 15 个训练数据集和 15 个测试数据集,另外还包括 4 个缩减了的测试数据集,如图 4 所示。数据集中的点都含有 RGB 和强度信息,并被标记为 8 个语义类别。

Vaihingen 数据集由 ISPRS 提供,使用 Leica

ALS50 机载 LiDAR 系统扫描得到,文献[20]提供了该数据集的相关说明。数据集包含了丰富的地理环境、城区环境及建筑物类型,如图 5 所示,能够充分验证所提算法在室外大规模场景下的应用。LiDAR 点云数据密度为 4 m^{-3} 。




图 4 Semantic 3D 数据集的点云。(a)区域 1;(b)区域 2

Fig. 4 Point cloud of Semantic 3D dataset. (a) Area 1; (b) area 2




图 5 Vaihingen 城市数据集的点云。(a)区域 1;(b)区域 2;(c)区域 3

Fig. 5 Point cloud of Vaihingen city dataset. (a) Area 1; (b) area 2; (c) area 3

利用 Semantic 3D 数据集对所提出的网络进行测试,并与其他神经网络方法进行对比。当训练网络时,网络批量归一化的衰减率从 0.5 逐渐增加到 0.99,使用 Adam 优化器时,初始学习率为 0.001,样本大小为 32,其余超参设置与 PointNet 网络相同。

训练时每个点由 $(X, Y, Z, R, G, B, X', Y', Z')$ 9 维向量表示,RGB 为点的颜色的三个通道, X', Y', Z' 为基于环境的归一化坐标。多尺度网络训练时按照 (1) 式的方法确定三个尺度为 $[0.01, 0.02, 0.04]$ 。分类结果如图 6 所示。

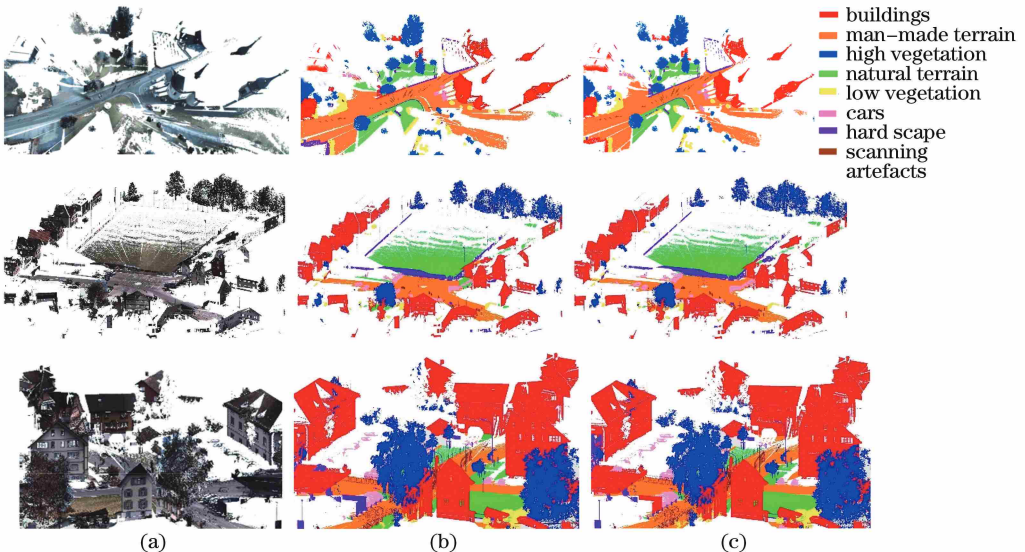


图 6 Semantic 3D 数据集的分类结果。(a)输入点云;(b) PointNet;(c)所提算法

Fig. 6 Classification results of Semantic 3D dataset. (a) Input point cloud; (b) PointNet; (c) proposed algorithm

在 Vaihingen 城市数据集中,使用 PointNet 网络和所提算法进行测试,数据集中点的语义标签包含 9 类(电力线、车辆、低矮植物、不透水表面、护栏、屋顶、墙面、灌木、树)。数据集共包含 753876 个点,

选取 301550 个点作为训练数据集,452326 个点作为测试数据集。多尺度网络中选取[0.5,1,2]三个尺度提取点的局部特征。分类结果如图 7 所示,由于部分类别的分类结果点太少,因此只标注了 5 个标签。

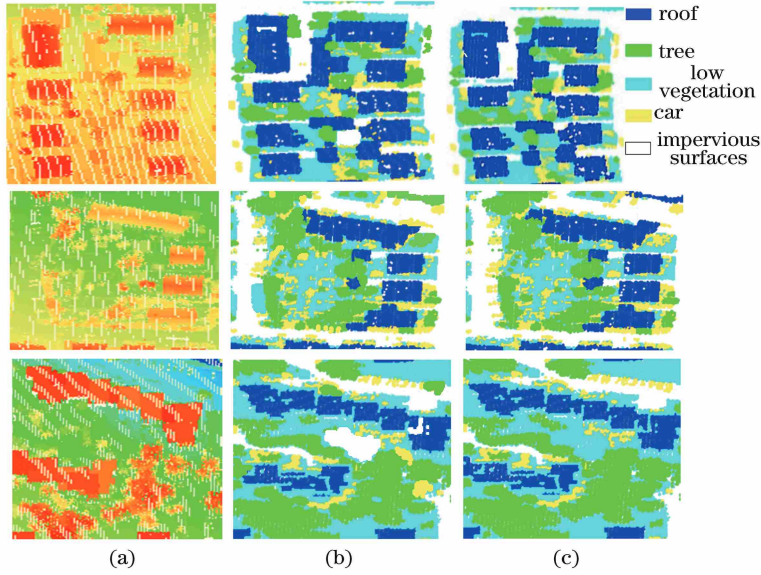


图 7 Vaihingen 城市数据集的分类结果。(a)输入点云;(b) PointNet;(c)所提算法

Fig. 7 Classification results of Vaihingen city dataset. (a) Input point cloud; (b) PointNet; (c) proposed algorithm

4 实验结果分析

采用交并比(IoU)^[21]、平均每类精度和整体精度对分类结果进行评价,IoU 值用百分比表示。假设原始样本中有两类,其中有 P 个类别为 1 的样本,有 N 个类别为 0 的样本,IoU 的计算公式为

$$f_{IoU} = \frac{P_{TP}}{P_{TP} + P_{FP} + P_{FN}}, \quad (6)$$

式中: P_{TP} 为类别为 1 的样本被系统正确判定为类别 1 的点数; P_{FN} 为类别为 1 的样本被系统误判定为类别 0 的点数; P_{FP} 为类别为 0 的样本被系统误判定为类别 1 的点数。

表 1 展示了不同放大因子 s 下多尺度以及单一尺度的分类结果,实验在 Semantic 3D 数据集上进行。对于点云数据,多尺度空间相较于单尺度空间具有明显的优势,选取的尺度过大时,会增加运算复

杂度、降低分类精度。表 2 展示了所提算法和文献 [22] 算法、文献 [23] 算法、文献 [24] 算法在 Semantic 3D 数据集上 8 个类别(路面、草地、树木、灌木、建筑物、人造物、扫描伪影、车辆)的 IoU 和平均 IoU 值,所提算法在 IoU 平均值和大部分类别的 IoU 上优于其他神经网络。表 3 对所提算法和其他算法在 Semantic 3D 数据集上的平均 IoU 值和整体分类精度上进行了比较,并列出了各算法的时间消耗,所提算法的分类精度均高于其他算法。

表 1 不同尺度下的实验结果

Table 1 Experimental results of different scales

Scale	$s=2$	$s=3$	$s=4$
Multi-scale	90.7	89.8	89.2
Scale 1	85.2	85.2	85.2
Scale 2	86.4	87.3	86.1
Scale 3	86.1	84.9	84.3

表 2 Semantic 3D 数据集的各类别 IoU

Table 2 Each category IoU of Semantic 3D dataset

Algorithm	Mean IoU	Man-made terrain	Natural terrain	High vegetation	Low vegetation	Buildings	Hard scape	Scanning artefacts	Cars	%
Ref. [22]	58.5	85.6	83.2	74.2	32.4	89.7	18.5	25.1	59.2	
Ref. [23]	59.1	82.0	77.3	79.7	22.9	91.1	18.4	37.3	64.4	
Ref. [24]	61.3	83.9	66.0	86.0	40.5	91.1	30.9	27.5	64.3	
Proposed	67.4	85.6	87.1	90.5	42.3	93.2	31.6	40.8	67.8	

表3 Semantic 3D数据集的分类精度以及运行时间

Table 3 Classification accuracy and runtime of Semantic 3D dataset

Algorithm	Mean	Overall	Runtime /s
	IoU /%	accuracy /%	
Ref. [22]	58.5	88.9	—
Ref. [23]	59.1	88.6	3600.00
Ref. [24]	61.3	88.1	1881.00
Proposed	67.4	90.7	4300.00

表4展示了所提算法和 PointNet 在 Vaihingen 城市数据集上 9 个类别(电力线、车辆、低矮植物、不透水表面、护栏、屋顶、墙面、灌木、树)的 IoU 和平

表4 Vaihingen 城市数据集的各类别 IoU

Table 4 Each category IoU of Vaihingen city dataset

Algorithm	Mean	Power line	Car	Low vegetation	Impervious surfaces	Roof	Fence / hedge	Facade	Shrub	Tree
	IoU /%									
PointNet	32.0	0.8	23.2	32.1	47.6	84.7	2.3	5.7	15.4	76.2
Proposed	34.9	1.2	34.3	36.9	49.3	86.8	2.6	4.8	13.3	85.7

表5 Vaihingen 城市数据集的分类精度以及运行时间

Table 5 Classification accuracy and runtime of Vaihingen city dataset

Algorithm	Mean IoU /%	Overall accuracy /%	Average class accuracy /%	Runtime /s
PointNet	32.0	65.2	38.1	1500.00
Proposed	34.9	74.3	43.6	2300.00

5 结 论

提出了一种将多尺度特征与 PointNet 网络结合的深度神经网络,用于 LiDAR 点云数据的分类。在 PointNet 网络结构的基础上,采用多尺度对点云内点的邻域特征进行提取,并作为点的局部特征与 PointNet 提取的全局特征结合,完成对 LiDAR 点云的分类。通过在 Semantic 3D 数据集和 Vaihingen 城市数据集上进行测试,对不同尺度的分类结果进行评估,选出最优尺度,相比于其他神经网络算法,所提算法能取得更好的分类结果。同时从实验结果可知,相比于地面 3D 激光扫描仪,机载 LiDAR 由于高度和扫描角度等问题,得到的点云数据更加稀疏,点云的分类具有更高的难度,需要与航空影像等融合实现更高的分类精度。另外所提算法由于需要提取局部特征,在算法效率上有所降低,需要继续改进。

参 考 文 献

[1] Lai X D. Basic principle and application of airborne laser radar [M]. Beijing: Publishing House of Electronics Industry, 2010.
赖旭东. 机载激光雷达基础原理与应用 [M]. 北京:

均 IoU 值,所提算法在机载 LiDAR 扫描获得的大规模场景点云数据中也能获得优于 PointNet 的分类精度。表5对所提算法和 PointNet 在 Vaihingen 城市数据集上的平均 IoU 值、平均分类精度、整体分类精度和运行时间进行了比较,从分类结果可以看出,由于机载 LiDAR 点云数据相比其他 LiDAR 点云数据更加稀疏和分布不均匀,机载 LiDAR 点云数据的分类精度低于 Semantic 3D 数据集。由于实验所用的点云数据并不包含颜色等光谱信息,因此算法的分类精度不高,实现 LiDAR 点云与航空影像的融合^[25],能够有效提高点云的分类精度。

电子工业出版社, 2010.

[2] Hui Z Y, Cheng P G, Guan Y L, *et al.* Review on airborne LiDAR point cloud filtering [J]. *Laser & Optoelectronics Progress*, 2018, 55(6): 060001.
慧振阳, 程朋根, 官云兰, 等. 机载 LiDAR 点云滤波综述 [J]. *激光与光电子学进展*, 2018, 55(6): 060001.
[3] Wu J, Liu R, Guo N, *et al.* Aerial LiDAR data classification using weighted support vector machines [J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(1): 1-5.
吴军, 刘荣, 郭宁, 等. SVM 加权学习下的机载 LiDAR 数据多元分类研究 [J]. *武汉大学学报·信息科学版*, 2013, 38(1): 1-5.
[4] MacFaden S W, O'neil-Dunne J P M, Royar A R, *et al.* High-resolution tree canopy mapping for New York City using LIDAR and object-based image analysis [J]. *Journal of Applied Remote Sensing*, 2012, 6(1): 063567.
[5] 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.
- [6] Cheng X J, Guo W, Li Q, *et al.* Joint classification method for terrestrial LiDAR point cloud based on intensity and color information[J]. Chinese Journal of Lasers, 2017, 44(10): 1010007.
程效军, 郭王, 李泉, 等. 基于强度与颜色信息的地面 LiDAR 点云联合分类方法[J]. 中国激光, 2017, 44(10): 1010007.
- [7] Guo B, Huang X F, Zhang F, *et al.* Classification of airborne laser scanning data using JointBoost [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 100: 71-83.
- [8] Wu Z R, Song S R, Khosla A, *et al.* 3D ShapeNets: a deep representation for volumetric shapes [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1912-1920.
- [9] Maturana D, Scherer S. VoxNet: a 3D convolutional neural network for real-time object recognition[C] // IEEE/RSJ International Conference on Intelligent Robots and Systems, 2015: 922-928.
- [10] Qi C R, Su H, Nießner M, *et al.* Volumetric and multi-view CNNs for object classification on 3D data [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016: 5648-5656.
- [11] Yi L, Su H, Guo X W, *et al.* SyncSpecCNN: synchronized spectral CNN for 3D shape segmentation [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6584-6592.
- [12] Charles R Q, Su H, Mo K C, *et al.* PointNet: deep learning on point sets for 3D classification and segmentation [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 77-85.
- [13] Lindeberg T. Scale-space theory in computer vision [M]. Berlin: Springer, 1994: 349-382.
- [14] Cai J R, Kuang L Q, Han X. Multi-scale feature point extraction algorithm based on scattered point cloud[J]. Computer Engineering and Design, 2016, 37(12): 3255-3259.
蔡晋茹, 况立群, 韩燮. 基于散乱点云的多尺度特征点提取算法[J]. 计算机工程与设计, 2016, 37(12): 3255-3259.
- [15] Yue C, Liu C J, Wang X F. Classification algorithm for laser point clouds of high-steep slopes based on multi-scale dimensionality features and SVM [J]. Geomatics and Information Science of Wuhan University, 2016, 41(7): 882-888.
岳冲, 刘昌军, 王晓芳. 基于多尺度维度特征和 SVM 的高陡边坡点云数据分类算法研究[J]. 武汉大学学报(自然科学版), 2016, 41(7): 882-888.
- [16] Zhu J F, Hu X Y, Zhang Z X, *et al.* Hierarchical outlier detection for point cloud data using a density analysis method [J]. Acta Geodaetica et Cartographica Sinica, 2015, 44(3): 282-291.
朱俊锋, 胡翔云, 张祖勋, 等. 多尺度点云噪声检测的密度分析法[J]. 测绘学报, 2015, 44(3): 282-291.
- [17] Kingma D P, Ba J. Adam: a method for stochastic optimization [C] // 3rd International Conference for Learning Representations, 2015.
- [18] Shang W, Sohn K, Almeida D, *et al.* Understanding and improving convolutional neural networks via concatenated rectified linear units [C] // International Conference on Machine Learning, 2016: 2217-2225.
- [19] Hackel T, Savinov N, Ladicky L, *et al.* Semantic3D. net: a new large-scale point cloud classification benchmark [J]. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2017, IV-1/W1: 91-98.
- [20] Rottensteiner F, Sohn G, Gerke M, *et al.* ISPRS test project on urban classification and 3D building reconstruction [J]. Commission III-Photogrammetric Computer Vision and Image Analysis, Working Group III/4-3D Scene Analysis, 2013: 1-17.
- [21] Garcia-Garcia A, Orts-Escolano S, Oprea S, *et al.* A survey on deep learning techniques for image and video semantic segmentation [J]. Applied Soft Computing, 2018, 70: 41-65.
- [22] Lawin F J, Danelljan M, Tosteberg P, *et al.* Deep projective 3D semantic segmentation [C] // International Conference on Computer Analysis of Images and Patterns, 2017: 95-107.
- [23] Boulch A, Saux B L, Audebert N. Unstructured point cloud semantic labeling using deep segmentation networks [C] // Eurographics Workshop on 3D Object Retrieval, 2017: 17-24.
- [24] Tchapmi L, Choy C, Armeni I, *et al.* SEGCloud: semantic segmentation of 3D point clouds [C] // International Conference on 3D Vision, 2017: 537-547.
- [25] Zhao Z Y, Cheng Y L, He M Y. Registration of LiDAR point cloud and aerial image based on surface feature and SIFT feature [J]. Journal of Air Force Engineering University (Natural Science Edition), 2018, 19(5): 65-70.
赵中阳, 程英蕾, 何曼芸. 基于面特征和 SIFT 特征的 LiDAR 点云与航空影像配准[J]. 空军工程大学学报(自然科学版), 2018, 19(5): 65-70.