

MLMS-Net:多层次多尺度点云分类网络

薛豆豆¹, 程英蕾¹, 文沛^{1,2}, 余旺盛¹, 秦先祥¹

(1. 空军工程大学信息与导航学院, 710077, 西安; 2. 中国人民解放军 93575 部队, 067000, 河北承德)

摘要: 针对传统点云分类网络提取特征较为单一, 分类精度较低的问题, 提出一种多层次多尺度点云分类网络 MLMS-Net。首先使用预处理算法将原始点云分割为小样本, 以得到批处理输入, 提高训练效率; 然后使用 K 近邻算法和边缘特征向量分别提取点云的低层次结构特征和边缘特征, 通过设置不同邻域值, 有效获取上下文信息, 通过点内和点间多层次表达获得局部细粒度描述; 接着对两种低层次特征分别构建卷积神经网络, 随着网络层次的加深, 特征抽象程度越来越高, 区分程度也随之增加, 从而有效提高准确性; 最后利用后处理模块融合深层特征, 完成点云分类任务。使用 Vaihingen 数据集对 MLMS-Net 网络进行测试, 其分类精度相较单层次网络提高了 0.6%~15.9%。

关键词: 点云分类; 卷积神经网络; 边缘特征; 局部细粒度

中图分类号: TP237 **文献标志码:** A

DOI: 10.7652/xjtuxb202012009 **文章编号:** 0253-987X(2020)12-0070-09



OSID 码

MLMS-Net: A Point Cloud Classification Network with
Multi-Level and Multi-Scale

XUE Doudou¹, CHENG Yinglei¹, WEN Pei^{1,2}, YU Wangsheng¹, QIN Xianxiang¹

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

2. The 93575 Unit, Chengde, Hebei 067000, China)

Abstract: A point cloud classification network with multi-level and multi-scale (MLMS-Net) is proposed to improve the problem that the traditional point cloud classification network extracts single-level features and the classification accuracy is low. First, a preprocessing algorithm is used to segment the original point cloud into small samples to obtain mini-batch and so as to improve training efficiency; Then the K-nearest neighbor algorithm and an edge feature vector are used to extract the low-level structure features and edge features of the point cloud, and the context information is effectively obtained through setting different neighborhood values. Local fine-grained descriptions are obtained through multi-level expression within and between points. Then convolutional neural networks are constructed for two low-level features separately. With the deepening of the network level, the degree of feature abstraction level is higher and higher, and the degree of distinction increases, so as to effectively improve the accuracy; Finally, the post-processing module is used to fuse the deep features, and the point cloud classification task is completed. The Vaihingen data set is used to test the MLMS-Net network, its classification accuracy is improved by 0.6% to 15.9% compared with that of the single-level network.

收稿日期: 2020-06-19。 作者简介: 薛豆豆(1996—),男,硕士生;程英蕾(通信作者),女,教授。 基金项目: 国家自然科学基金青年科学基金资助项目(61703423);国家自然科学基金基金资助项目(41601436)。

网络出版时间: 2020-09-02 网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20200902.1342.002.html>

Keywords: point cloud classification; convolutional neural network; edge features; local fine-grained

随着科技的发展,点云在自动驾驶、遥感测绘和机器人领域的应用日益增加。在遥感测绘领域,点云主要应用于 3D 建筑物重建^[1]、提取道路模型^[2]、植被覆盖率估计^[3]等。其中,对地表数据进行有效分类作为上述应用的关键步骤,已成为该领域研究的热点。由于点云具有排列无序、分布不均匀等性质,点云高精度分类与分割任务仍然是一项巨大的挑战。

传统点云分类网络通过人工构建的方式表示每个点的特征向量,这种方法受限于学者的先验知识,提取特征效率较低,点云分类精度较差^[4-6]。近年来,神经网络在计算机视觉方面取得巨大成功,其精度远超机器学习和传统算法。文献[7]的研究表明,神经网络将提取到的浅层邻域特征通过共享卷积核的方式训练得到深层抽象特征,可以有效提高分类精度,其具体结构如图 1a 所示。然而,神经网络的主要是处理规则栅格化的图像,而点云是不规则且无序的数据,因此如何有效地将卷积神经网络应用到点云分类任务是研究的重点和难点。

针对以上问题,学者提出了两种点云分类神经网络:点卷积神经网络和边缘卷积神经网络,如图 1b、图 1c 所示。点卷积提取网络是将传统神经网络的输入改为点本身的特征,边缘卷积神经网络是将传统神经网络的输入改为点之间的边缘特征。

目前,研究人员基于上述网络提出了 3 种不同的点云分类方法。第 1 类方法是先对点云进行规则化处理,然后使用点卷积神经网络进行训练,该类方法主要包括:基于多视角图像的方法^[8-10]和基于体素的方法^[11-13]。Su 等在 2015 年提出了多视图卷积神经网络(MVCNN),该网络从多视角对点云进行投影,并将投影特征池化为全局特征,最后通过卷积神经网络完成分类^[8]。由于网络使用二维图像表征点云的三维结构特征,忽略了大量关键的几何信息,并且投影中遮挡的部分不能有效处理,网络分类精度较低。Zhou 等在 2018 年提出了体素化网络(VoxelNet),其主要思想是均匀划分点云为三维网格,将网格内的点进行随机采样和归一化处理并输入到网格特征提取层(VFE),得到了稀疏、深层、区分度高的网格特征向量,最后通过三维卷积神经网络完成分类任务^[11]。该网络将点云预处理为网格结构,但需控制网格密度在合理范围,否则,密度过




图 1 传统神经网络和卷积神经网络示意图

低会造成分类精度损失,过高会造成内存占用和时间开销等指标呈指数型增加。

第 2 类方法是将原始点云数据和点卷积神经网络相结合,完成点云分类。Qi 等提出了 PointNet 网络,首次结合原始点云与神经网络成功提取点云全局特征^[14]。一方面,PointNet 使用对称函数实现了点云的输入不变性;另一方面,使用放射变换网络(T-Net)对输入点云进行对齐,通过矩阵乘法对输入数据进行空间变换,实现了点云的几何置换不变性;但是该网络未考虑点云局部特征,分类效果尚不理想。针对此问题,Qi 等基于卷积核捕获邻域特征的思想提出了 PointNet2 网络^[15],该网络使用最远点采样算法得到局部邻域,并使用层次神经网络提

取局部特征,最后结合局部特征与原始特征完成点云分类,一定程度上提高了网络分类精度。但由于忽略了点之间的几何信息,提取得到的特征仍不全面;白静等在2019年提出多尺度点云分类网络(MSP-Net)^[16],该网络使用多尺度邻域特征对点云进行分类,相较于单尺度网络分类精度更高,具有更好的感受视野,但是该网络结构简单,在特征融合后未进行深层特征提取。前两种方法忽略了点之间的局部关系信息,在提高网络分类精度方面仍存在一定的局限性。

第3类方法是将点云的边缘特征与边缘卷积神经网络相结合,完成点云分类。Simonovsky等将点视为图的顶点,通过边缘条件卷积网络得到邻域信息,使用VoxelGrid算法实现图优化,完成分类任务^[17]。Wang等提出了动态图网络(DGCNN),该网络利用边缘特征空间构建概率图模型,通过更新拉普拉斯矩阵动态更新特征图,并使用三阶切比雪夫近似降低算法的复杂度,完成点云分类和分割任务^[18]。该网络分类精度较高,但是网络不能有效获取点云全局结构特征,模型复杂,适用性差。

目前,大多点云分类网络只单方面考虑结构特征或者边缘特征,没有全面对点云特征进行提取,分类精度较低。针对以上问题,本文提出了面向点云的多层次多尺度分类网络MLMS-Net。该网络将不规则的点云作为输入,通过多尺度卷积神经网络和边缘卷积神经网络获取深层特征,最后通过后处理模块完成分类。实验证明,本文所提网络可以充分提取点云特征,精确分类点云得到地物目标,缩短计算时间。

1 多层次多尺度点云分类网络

1.1 点云预处理

点云预处理就是对点云进行分割。本文实验数据为大规模激光LiDAR点云,设分割长度阈值为 $l_{\min}$,具体分割步骤如下:

(1)以点云边界建立初始分割立方体 B ,边长为 $L_{\text{side},B}$, B 中有 N_B 个点;

(2)比较立方体 B 边长 $L_{\text{side},B}$ 与 $l_{\min}$,当 $L_{\text{side},B} \leq l_{\min}$,则块 B 分割结束; $N_B=0$,则丢弃块 B ;当 $L_{\text{side},B} > l_{\min}$ 且 $N_B > 0$,则将 B 等分割为8块,得到 $\{B_1, B_2, \dots, B_8\}$;

(3)对于任一 $B_i \in \{B_1, B_2, \dots, B_8\}$,其边长为 L_{side,B_i} ,有 N_{B_i} 个点,重复步骤2,直到分割结束。

1.2 多尺度结构特征提取网络

单尺度网络只能获取固定大小的邻域结构特征,但是树木、屋顶等地面物体通常在LiDAR遥感数据中以多尺度形式呈现,仅使用单尺度网络不能提取足够的特征,分类准确率较低,而多尺度可以使卷积核有不同的感受视野,更好地获取上下文信息,有效提高点云分类精度^[19]。

多尺度结构特征提取分为5个部分:局部特征构建、低层次结构特征构建、单尺度特征提取、多尺度特征提取和特征融合。设预处理后的点云块 B_i 中有 N' 个点 $\mathbf{P} = \{p_1, p_2, \dots, p_{n'}\}$,每个点具有 l 维特征,尺度个数为 M 。

(1)局部特征构建。首先以每个点 p_i 为中心进行 k 近邻搜索,选取半径 r 内的 k 个邻域点, r 表示搜索半径。在挑选 k 个邻域点时,如果半径内的点数小于 k ,采用随机法挑选其中的 m 个点并复制,直到总点数达到 k 为止,如果范围内的点数大于 k 个点,则随机挑选 k 个点。因此,每个点的特征为 $\mathbf{F}_i = [f_{i,1}, f_{i,2}, \dots, f_{i,k}]$,其中 $f_{i,k}$ 表示第 k 个近邻点的特征。

(2)低层次结构特征构建。得到局部特征 $\mathbf{F}_i$ 后,通过全连接层构建低层次特征,公式如下

$$\mathbf{F}_i^* = \mathbf{W}_p \mathbf{F}_i + \mathbf{b}_p \quad (1)$$

式中: $\mathbf{F}_i^*$ 表示低层次结构特征向量; $\mathbf{W}_p$ 表示权重矩阵; $\mathbf{b}_p$ 表示偏差矩阵。

(3)单尺度结构特征提取。在神经网络中,特征会依次通过卷积层、激活层和池化层进行训练。其中,卷积层是利用特征更新函数得到结构特征的深层表示;激活层是利用激活函数对输出进行非线性化处理,常见的激活函数有Sigmoid函数和Relu函数,Sigmoid函数会引起梯度消失的问题,Relu可以单向抑制负值输出,有效避免梯度消失,提高分类稳定性;池化层是使用对称函数实现点云的无序性,使点云输入顺序改变不会影响分类结果。基于上述考虑,卷积层使用多层感知机函数,用mlp表示;激活层使用Relu函数,用 σ 表示;池化层使用最大池化函数,用maxpooling表示。

在得到低层次结构特征 $\mathbf{F}_i^*$ 后,将其送入卷积层和最大池化层,得到浅层特征图,数据维度为 $N' \times 256 \times 1$;接着将特征图送入mlp(256,512,1024)层和最大池化层,得到 $N' \times 1024 \times 1$ 维的单尺度结构特征。随着网络层次的深入,特征图的抽象性越来越高,区分程度也随之增大。

(4)多尺度特征提取。设提取 M 个不同尺度结

构特征,对应的邻域半径为 $R = \{r_1, r_2, \dots, r_M\}$, 对于 $r_i \in R$, 分别执行步骤 1~3, 得到多尺度结构特征。

(5) 特征聚合。将各个尺度的特征进行联接, 得到 $N' \times 1\,024 \times M$ 维数据, 接着将所得数据送入 $\text{mlp}(1\,024, 1\,024)$ 层和 $\text{maxpooling}(M)$ 层进行训练, 得到深层多尺度结构特征。数据维度为 $N' \times 1\,024 \times 1$ 。最后采用均方误差函数^[20], 作为网络代价函数 δ , 计算公式如下

$$\delta = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (2)$$

式中: N 是训练点数; t_i 表示点 i 的分类标签; y_i 表示预测标签。

图 2 为多尺度结构特征提取网络示意图。




图 2 多尺度结构特征提取网络

1.3 边缘特征提取

边缘特征提取网络的基本原理是对点以及邻域点之间的几何关系进行学习, 从而得到点关系特征的高维表示。边缘特征提取主要分为 3 个部分: 定义边缘特征向量、构建低层次边缘特征和边缘特征提取。本文引入图神经网络模型进行边缘特征提取。设点云为有向图 G , v 表示顶点集合, e 表示点边缘。

(1) 定义边缘特征向量: 在本文中, 使用点之间的 L_1 范数、 L_2 范数、 L_∞ 范数以及点坐标构建中心点 i 与邻域点 j 的边缘特征向量 e_{ij} , 计算公式如下

$$\left. \begin{aligned} e_{ij} &= (L_1, L_2, L_\infty, P_i, P_j) \\ L_1 &= |x_i - x_j| + |y_i - y_j| + |z_i - z_j| \\ L_2 &= (|x_i - x_j|^2 + |y_i - y_j|^2 + |z_i - z_j|^2)^{1/2} \\ L_\infty &= \max(|x_i - x_j|, |y_i - y_j|, |z_i - z_j|) \end{aligned} \right\} \quad (3)$$

式中: x, y, z 表示点的三维坐标; L_1, L_2, L_∞ 分别为 i

和 j 之间的曼哈顿距离、欧氏距离以及切比雪夫距离; P_i 和 P_j 表示 i 和 j 的三维坐标。

(2) 低层次边缘特征构建: 通过 k 近邻算法搜索顶点 i 的 k 条相邻边, 由此得到每个点的边缘特征 $E_i = [e_{ij_1}, e_{ij_2}, \dots, e_{ij_n}]$, 通过特征聚合函数计算顶点 i 的低层次边缘特征

$$E_i^* = W_e E_i + b_e \quad (4)$$

式中: W_e 表示共享权重矩阵; b_e 表示全连接层中的偏置向量。

(3) 边缘特征提取: 边缘特征提取的网络框架如图 3 所示。主要步骤是, 在得到低层次边缘特征 E_i^* 后, 通过 $\text{mlp}(64, 128, 256)$ 层和 $\text{maxpooling}(256)$ 层进行初步训练, 得到浅层边缘特征; 接着将数据送入 $\text{mlp}(512, 512)$ 层和 $\text{maxpooling}(512)$ 层进一步训练, 得到深层边缘特征; 分别使用 $\text{maxpooling}(256)$ 和 $\text{maxpooling}(512)$ 层对浅层、深层特征进行池化, 将池化后的特征级联后送入 $\text{mlp}(512, 1\,024)$ 层和 $\text{maxpooling}(1\,024)$ 层进行特征聚合, 得到深层边缘特征向量, 数据维度为 $N' \times 1\,024 \times 1$ 。边缘特征提取公式如下

$$E_{\text{end}} = g(E_1^*, E_2^*, \dots, E_{N'}^*) \quad (5)$$

式中: E_{end} 表示深层边缘特征向量; 函数 $g(\cdot)$ 表示网络特征学习函数。边缘特征提取网络利用点云原始特征构建边缘特征向量, 接着提取浅层边缘特征向量, 最后通过神经网络得到深层边缘特征向量, 对邻域点几何关系进行抽象描述和高维表征。




图 3 边缘特征提取的网络框架

1.4 后处理

后处理网络通过融合点云的多尺度深层结构特征和深层边缘特征得到全局特征, 接着将全局特征通过后续网络进行训练得到预测标签, 从而完成点云分类。图 4 为后处理的具体网络结构。由图 4 可知, 融合后的特征需要通过 $\text{mlp}(1\,024)$ 层和 $\text{maxpooling}(1\,024)$ 层进一步提取特征, 得到 $1 \times 1\,024 \times 1$ 维的全局特征, 接着将全局特征堆叠, 并与输入特征联接得到 $N' \times 2\,048 \times 1$ 维的级联特征, 最后将其通过 $\text{mlp}(1\,024, 512, n)$ 层训练得到点云标签的预测结果, 完成分类, n 表示所分的总类别数。




图4 后处理模块示意图

2 实验与分析

2.1 数据集

本文使用由 ISPRS 竞赛提供的 Vaihingen 数据集。该数据集共有 753 876 个训练点、411 722 个测试点,平均密度为 4 m^{-2} 。在训练前,预先对数据进行适应性调整,将屋顶和外墙合并为建筑物,将电力线点去除。最后得到训练数据的总类别数为 7,分别是:建筑物、低矮植被、树木、地面、车辆、围栏、灌木丛。

2.2 评价指标

为了评估网络的准确性,本文引入 3 种指标,分别是:用户分类精度 A_c 、总体分类精度 A_o 、以及 kappa 系数 K 。具体计算公式如下

$$A_c = \frac{T_p^{(i)}}{N_p^{(i)}}, \quad i = 1, 2, \dots, n \quad (6)$$

$$A_o = \frac{\sum_{i=1}^n T_p^{(i)}}{N_p}, \quad i = 1, 2, \dots, n \quad (7)$$

$$K =$$

$$\frac{N_p \sum_{i=1}^m (T_p^{(i)}) - \sum_{i=1}^m ((T_p^{(i)} + F_p^{(i)})(T_p^{(i)} + F_p^{(i)}))}{N_p^2 - \sum_{i=1}^m ((T_p^{(i)} + F_p^{(i)})(T_p^{(i)} + F_p^{(i)}))} \quad (8)$$

式中: $T_p^{(i)}$ 表示第 i 类分类正确的个数; $F_p^{(i)}$ 表示第 i 类分类错误的个数; $N_p^{(i)}$ 表示第 i 类点云的总点数; N_p 表示点云总点数; n 表示总类别数。单类分类精度 A_c 用于衡量某一类物体的分类情况,总体分类精度 A_o 和 kappa 系数用于衡量整个网络的性能。

2.3 参数配置

在进行点云分割时, $l_{\min}$ 设置为 5 m。MLMS-Net 网络初始学习率为 0.01,每经过 2 000 次训练,学习率减半;使用动量随机梯度下降法训练,其中动量值为 0.9;批处理块的大小为 32, Dropping rate 为 0.1;使用 6 倍交叉验证方案,网络输入为点云的坐标,多尺度个数 M 为 3。机器配置如下: GPU 为 GTX 2070, CPU 为 i7-8750H, 实验环境为 python 3.6、tensorflow 等。

2.4 结果分析

对点云进行预处理,不仅能够减少单次训练数量,而且可以使用批处理策略进行训练,提高训练效率。图 5 为点云预处理示意图。



图5 预处理后分割示意图

图 6 为对屋顶、树木以及低矮植被测试数据的分类结果,黑色为分类错误点,灰色为分类正确点,黑色的面积越小,表明分类的准确性越高。从图 6 可以看出,本文网络在提取建筑物边缘细节方面性能良好,低矮植被以及树木的分类精度相较于屋顶精度较差,但整体分类效果良好。



(a) 屋顶分类结果



(b) 树木分类结果



(c)低矮植被分类结果

图 6 测试数据集分类结果图


本文使用 1~7 分别代表屋顶、围栏、低矮植被、地面、灌木丛、树木和车辆。表 1 为使用 Vaihingen 数据集进行测试时得到的分类结果混淆矩阵。由表 1 可以看出:第 4 类(地面)的分类精度为 93.66%;第 1 类(屋顶)的分类精度为 94.11%;第 3 类(低矮植被)的分类精度可以达到 80.71%;第 6 类(树木)的分类精度为 84.02%。这 4 类地物目标分类效果好的主要原因如下:①4 类的训练数据相较于其他数据更多,因此网络中有更多的神经元以及训练参数用来学习对应的特征;②训练时,这 4 类地物目标可以更好地结合结构特征和边缘特征进行分类;③由于数据点多于其他类,错误点对分类精度的影响远小于其他几类。

表 1 分类结果混淆矩阵


类别	分类精度/%						
	1	2	3	4	5	6	7
1	94.11	1.48	2.16	0.23	5.48	4.42	3.08
2	0.49	73.01	1.61	0.14	5.78	1.06	4.05
3	1.40	8.66	80.71	5.64	12.27	1.85	5.07
4	0.03	0.35	7.31	93.66	0.23	0.05	1.94
5	1.86	11.72	5.82	0.08	55.17	8.57	10.62
6	1.99	3.73	2.14	0.03	20.08	84.02	4.24
7	0.12	1.04	0.24	0.12	1.00	0.05	70.99

由表 1 可知:第 5 类(灌木)的分类精度为 55.17%;第 2 类(围栏)的分类精度为 73.01%,其中 11.72%的灌木丛点被分类为围栏,5.78%的围栏点被分类为灌木丛点。分类不佳的主要原因有以下 2 个方面:①图 7a 为围栏、灌木丛分布正视图,可以看出围栏点与灌木丛在位置上较为接近,使用激光雷达扫描时,生成的点云易混合;②图 7b 为围栏、灌木丛分布侧视图,可以看出二者高程值都在 0.1

~1.2 m 之间,特征区分度较小,易被错误分类。通过表 1 计算可得网络整体分类精度为 85.8%,kappa 系数为 0.92,综上所述,本文提出的多尺度多层次点云分类网络可以实现 LiDAR 点云数据的有效分类。



(a)围栏、灌木丛正视图




(b)围栏、灌木丛侧视图

图 7 本文网络对围栏、灌木丛分类结果


为了进一步验证本文网络的优越性,分别搭建了多尺度结构特征提取网络和边缘特征提取网络,并进行了实验对比。分类结果如图 8 所示。其中,黑色区域面积越大表示分类的准确性越高。图 8a 为多尺度结构特征提取网络的分类结果,总体分类精度为 82.5%,图 8b 为边缘特征提取网络的分类结果,总体分类精度为 70.3%;由于边缘特征提取网络结构简单,训练过程中大量几何关系特征丢失,导致分类精确度过低。图 8c 为本文网络测试结果,分类精度为 85.8%。从图 8 可以看出,本文网络对



(a)多尺度结构特征提取网络分类图



(b)边缘特征提取网络分类图



(c)本文网络分类图

图 8 3 种网络点云分类结果对比

分布复杂的区域分类效果更好,分类精度更高。

本文在构建多尺度网络时,引入超参数 k 表示邻域点的个数。为了检验 k 对实验结果的影响,设计了以下实验:将 k 分别设置为 6、8、10、12、14。结果如图 9 所示。从图 9 可以看出,随着超参数 k 的不断增大,总体分类精度呈现先增大后减小的趋势,训练时间不断增加。在 $k=10$ 时,分类精度达到了 85.5%,高于 $k=6,8$,训练时间为 467 min,小于 $k=12,14$ 。这说明使用 10 个邻域点的分类网络已经可以捕获到较为丰富的局部特征,同时由于点云局部信息有限,如果邻域点过多,网络容易出现过拟合,一定程度影响分类精度,并且网络训练时间也会增加。




图 9 不同邻域点数的准确率和训练时间对比

为了探究多尺度结构特征和边缘特征分配权重对点云分类结果的影响,设计了以下实验:①调整多尺度结构特征中各尺度特征所占的比重;②调整结构特征和边缘特征融合时各类特征所占的比重。表 2 为不同权重时网络的总体分类精度,其中权重比例的前 3 项表示结构特征、最后一项表示边缘特征。第 1 组与第 6 组实验只使用单尺度网络进行特征提取,网络对于点云结构的局部信息不够敏感,总体分类精度下降了 161%和 1.39%,第 6 组比第 1 组的邻域半径更大,感受视野更广,分类精度更高。第 2~5 组实验表示所有特征都参与训练,第 4 组实验的总体分类精度高于其他几种情况,表明各类特征在点云分类时都起到了一定的作用,权重均衡的点云特征区分度更高,各类特征对网络的贡献度接近。如无特殊说明,本文实验使用的权重分配方案是 $[1/6,1/6,1/6,1/2]$ 。

表 2 不同权重的网络分类精度

权重比例	总体分类精度/%
$[1/2,0,0,1/2]$	84.31
$[1/4,1/4,1/4,1/4]$	85.21
$[1/3,1/6,1/9,1/3]$	85.61
$[1/6,1/6,1/6,1/2]$	85.82
$[1/9,1/6,1/3,1/3]$	85.56
$[0,0,1/2,1/2]$	84.43

2.5 实验对比

采用本文网络、IIS_1 网络^[12]、HM_1 网络^[4]、UM 网络^[6]、LUH 网络^[1]、BIJ_W 网络^[22]、WhuY3 网络^[7]和 NANJ2 网络^[21]对 Vaihingen 数据集进行分类,结果如表 3 所示。由表 3 可知:ISS_1 网络的分类效果较差,这是因为该网络将点云体素化,丢失了过多点云原始特征;HM_1 网络、UM 网络时间开销小,这是因为网络使用了机器学习进行分类,但由于该种网络只使用了点云结构特征进行分类,因此分类准确性较低;BIJ_W 网络、WhuY3 网络、NANJ2 网络以及本文网络都引入神经网络进行深层特征提取,本文网络在分类性能上优于其他网络,并且时间开销相对于 BIJ_W 网络减少了 16.7 s,主要是由于本文使用点云原始数据作为输入,未转化为网格和图像。综上所述,本文所提出的 MLMS-Net 网络可以在保证时间开销的前提下有效提高点云的分类精度。

表 3 不同网络的分类精度和计算时间比较

网络名称	用户分类精度/%							总体分类精度/%	计算时间/s
	地面	屋顶	低矮植被	树木	车辆	灌木丛	围栏		
IIS_1	78.00	73.10	88.40	72.40	59.30	23.80	13.70	69.9	
HM_1	89.10	91.60	83.80	77.90	51.40	38.60	36.60	80.5	5.0
UM	88.00	93.60	78.60	71.80	89.60	38.80	28.80	80.8	2.1
LUH	91.80	97.30	83.00	87.40	86.40	34.10	49.50	81.6	
BIJ_W	88.50	92.50	77.10	80.10	61.60	39.20	55.70	81.5	85.3
WhuY3	88.40	91.40	80.90	77.50	58.40	41.70	64.20	82.3	70.2
NANJ2	89.20	95.70	90.00	88.30	83.40	45.40	50.50	85.2	54.2
MLMS-Net	93.66	94.11	80.71	84.02	70.99	55.17	73.01	85.8	68.6

3 结束语

针对目前传统分类网络不能充分利用点云特征的问题,本文提出了多层次多尺度网络 MLMS-NET,对大规模点云分割方法进行了阐述,设计了两个模块提取不同层次特征,其中多尺度特征提取模块通过更改邻域半径和 K 近邻算法得到多尺度结构特征;边缘特征提取模块通过构建特征向量和神经网络得到边缘关系特征,最后通过融合以及后处理模块完成分类任务。实验结果表明,本文的网络分类精度可达到 85.8%,能够实现对点云的精确分类。

参考文献:

[1] NIEMEYER J, ROTTENSTEINER F, SOERGEL U, et al. Hierarchical higher order crf for the classification of airborne lidar point clouds in urban areas [C] // 23rd International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vienna, Austria: International Society for Photogrammetry and Remote Sensing, 2016: 655-662.

[2] YANG Bisheng, FANG Lina, LI Qingquan, et al. Automated extraction of road markings from mobile lidar point clouds [J]. Photogrammetric Engineering & Remote Sensing, 2012, 78(4): 331-338.

[3] DALPONTE M, BRUZZONE L, GIANELLE D. A system for the estimation of single-tree stem diameter and volume using multireturn LIDAR data [J]. IEEE Transactions on Geoscience & Remote Sensing, 2011, 49(7): 2479-2490.

[4] YANG Zhishuang, TAN Bo, PEI Huikun, et al. Segmentation and multi-scale convolutional neural network-based classification of airborne laser scanner data [J]. Sensors, 2018, 18(10): 3347-3357.

[5] 李晓天,姜刚,张玉. 基于改进层次分析的机载 LiDAR 点云分类 [J]. 甘肃科学学报, 2019, 31(1): 86-91.

LI Xiaotian, JIANG Gang, ZHANG Yu. Classification of airborne LiDAR point cloud based on improved analytic hierarchy process [J]. Journal of Gansu Sciences, 2019, 31(1): 86-91.

[6] HORVAT D, ZALIK B, MONGUS D. Context-dependent detection of non-linearly distributed points for vegetation classification in airborne LiDAR [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 116(6): 1-14.

[7] YANG Zhishuang, JIANG Wanshou, XU Bo, et al. A convolutional neural network-based 3D semantic labeling method for ALS point clouds [J]. Remote Sensing, 2017, 9(9): 936-948.

[8] SU Hang, MAJI S, KALOGERAKIS E, et al. Multi-view convolutional neural networks for 3d shape recognition [C] // 2015 IEEE International Conference on Computer Vision. Piscataway, NJ, USA: IEEE, 2015: 945-953.

[9] RIEGLER G, ULUSOY A O, BISCHOF H, et al. OctNetFusion: learning depth fusion from data [C] // 7th International Conference on 3D Vision. Piscataway, NJ, USA: IEEE, 2017: 57-66.

[10] 何鄂龙,王红平,陈奇,等. 一种改进的空间上下文点云分类方法 [J]. 测绘学报, 2017, 46(3): 362-370.

HE Elong, WANG Hongping, CHEN Qi, et al. An improved contextual classification method of point cloud [J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(3): 362-370.

[11] ZHOU YIN, TUZEL O. Voxelnet: end-to-end learning for point cloud based 3d object detection [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE,

- 2018: 4490-4499.
- [12] ANANDAKUMAR M, RAMIYA, RAMA R, et al. A super voxel-based spectro-spatial approach for 3D urban point cloud labelling [J]. *International Journal of Remote Sensing*, 2016, 37(17): 4172-4200.
- [13] 邵磊, 董广军, 于英, 等. 结合多尺度体素和高阶条件随机场的点云分类 [J]. *计算机辅助设计与图形学学报*, 2019, 31(3): 385-392.
- SHAO Lei, DONG Guangjun, YU Ying, et al. A point cloud classification method based on multi-scale voxel and higher order random fields [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2019, 31(3): 385-392.
- [14] CHARLES R Q, SU HAO, KAICHUN M, et al. PointNet: deep learning on point sets for 3D classification and segmentation [C]// 30th IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2017: 77-85.
- [15] CHARLES R Q, YI Li, SU Hao, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [C]// 31st Annual Conference on Neural Information Processing Systems. New York, USA: Neural Information Processing Systems Foundation, 2017: 5100-5109.
- [16] 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.
- BAI Jing, XU Haojun. MSP-Net: multi-scale point cloud classification network [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2019, 31(11): 1917-1924.
- [17] SIMONOVSKY M, KOMODAKIS N. Dynamic edge-conditioned filters in convolutional neural networks on graphs [C]// 30th IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2017: 29-38.
- [18] WANG Yue, SUN Yongbin, LIU Ziwei, et al. Dynamic graph CNN for learning on point clouds [J]. *ACM Transactions on Graphics*, 2019, 38(5): 112-124.
- [19] FAUVEL M, CHANUSSOT J, BENEDIKTSSON J A, et al. A spatial-spectral kernel-based approach for the classification of remote-sensing images [J]. *Pattern Recognition*, 2012, 45(1): 381-392.
- [20] YOUSEFHUSSEIN M, KELBE D, IENTILUCCI EJ, et al. A multi-scale fully convolutional network for semantic labeling of 3D point clouds [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 143(5): 191-204.
- [21] ZHAO Ruibing, PANG Mingyong, WANG Jidong. 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.
- [22] WANG Zhen, ZHANG Liliqiang, ZHANG Liang, et al. A deep neural network with spatial pooling (DNNSP) for 3D point cloud classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(8): 4594-4604.

(编辑 刘杨)

(上接第 69 页)

- [20] DRAPER-GIL G, LASHKARI A H, MAMUN M S I, et al. Characterization of encrypted and VPN traffic using time-related [C]// Proceedings of the 2nd International Conference on Information Systems Security and Privacy. Rome, Italy: SciTePress, 2016: 407-414.
- [21] SUN G, CHEN T, SU Y, et al. Internet traffic classification based on incremental support vector machines [J]. *Mobile Networks and Applications*, 2018, 23(4): 789-796.
- [22] MUNTHER A, RAZIF R, ABUALHAJ M, et al. A preliminary performance evaluation of K-means, KNN and EM unsupervised machine learning methods for network flow classification [J]. *International Journal of Electrical and Computer Engineering*, 2016, 6(2): 778-784.
- [23] ZHAO Zhirou, MEHROTRA K G, MOHAN C K. Online anomaly detection using random forest [C]// 31st International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems. Berlin, Germany: Springer Verlag, 2018: 135-147.
- [24] WANG W, ZHU M, WANG J, et al. End-to-end encrypted traffic classification with one-dimensional convolution neural networks [C]// 15th IEEE International Conference on Intelligence and Security Informatics. Piscataway, NJ, USA: IEEE, 2017: 43-48.

(编辑 刘杨)