



融合特征选择的点云语义分割方法

杨森¹ 花向红¹ 李丞¹ 崔淇¹ 叶小川¹

¹ 武汉大学测绘学院, 湖北, 武汉, 430079

A Point Cloud Semantic Segmentation Method Based on Fusion Feature Selection

YANG Sen¹ HUA Xianghong¹ LI Cheng¹ CUI Qi¹ YE Xiaochuan¹

¹ School of Geodesy and Geomatics, Wuhan University, Wuhan 430079, China

摘要: 针对 RandLA-Net 网络进行点云语义分割存在局部特征提取模块缺乏细粒度特征描述能力、缺乏全局上下文信息, 影响分割精度和效率问题, 提出了融合点云多维特征点云语义分割方法。该方法首先利用传统的点云特征算法计算点云的单点特征、形状特征和快速点特征直方图(fast point feature histograms, FPFH)特征, 然后利用 LightGBM 作为基本分类器, 提出改进的递归特征选择算法, 从而获得最重要的 t 个特征, 然后将筛选出的 t 个特征和点云数据输入到点云语义分割网络进行训练, 该网络是 RandLA-Net 网络架构改进形式, 通过局部特征聚合模块得到最终的聚合特征, 利用 4 层解码层和 3 层全连接层实现室内点云的语义分割, 输出点云语义标签。在 S3DIS 数据集上实验验证, 结果表明: 与 PointNet、PointNet++、RandLA-Net 算法相比, 该算法充分利用了点云数据的多维特征, 有效的提高了点云语义分割的准确性。

关键词: 点云多维特征提取; 改进的递归特征选择; 多特征融合; 点云语义分割网络; 点云语义标签

中图分类号: P208; TP751

文献标志码: A

Abstract: In order to solve the problem that the local feature extraction module of RandLA-Net lacks fine-grained feature description ability and global context information, which affects the segmentation accuracy and efficiency, we propose a point cloud semantic segmentation method that fuses multi-dimensional features of point clouds. Our method first uses the traditional point cloud feature algorithm to calculate the single point features, shape features and FPFH features of the point cloud, and then we use LightGBM as the basic classifier to propose an improved recursive feature selection algorithm to obtain the most important t features, and then, the filtered t

features and point cloud data are input into the point cloud semantic segmentation network for training. The network is an improved form of RandLA-Net network architecture, which obtains the final aggregation features through the local feature aggregation module, realizes the semantic segmentation of indoor point clouds by using 4 layers of decoding layer and 3 layers of fully connected layers, and outputs point cloud semantic labels. Experimental results on the S3DIS dataset show that compared with the PointNet, PointNet++ and RandLA-Net algorithms, the proposed algorithm makes full use of the multi-dimensional features of point cloud data and effectively improves the accuracy of point cloud semantic segmentation.

Key words: point cloud multi-dimensional feature extraction; improved recursive feature selection; multi-feature fusion; point cloud semantic segmentation network; point cloud semantic labels

随着三维激光扫描仪和深度相机等的技术发展, 点云的获取方法更加丰富, 点云的数据量更大, 点云分割和语义标注对深层信息挖掘具有重要意义, 在自动驾驶、机器人、智慧城市等领域具有重要意义^[1]。由于点云数据具有密度不均匀, 数据量大等特点, 点云的分类和分割算法存在许多难点, 是目前研究的热点^[2]。

早期的点云语义分割采用传统的机器学习算法, 如随机森林算法^[3](random forest, RF)、支持向量机算法(support vector machine, SVM)等, 这些算法一般需要手动选择特征, 然后根据特征选择分类器去分割点, 对于小数据量来说, 机器学习算法的效果较优, 但是随着采集设备的更新, 点云的密度和数

引用格式: 杨森, 花向红, 李丞, 等. 融合特征选择的点云语义分割方法[J]. 测绘地理信息, 2025, 50(2): 19-25 (YANG Sen, HUA Xianghong, LI Cheng, et al. A Point Cloud Semantic Segmentation Method Based on Fusion Feature Selection[J]. Journal of Geomatics, 2025, 50(2): 19-25)

基金项目: 国家自然科学基金(42271452, 42201457)。

据量不断变大,机器学习的方法容易受到噪声点和离群点的影响,导致分割时间过长且结果不准确^[4]。而基于深度学习的点云语义分割算法凭借非线性拟合能力能有效学习点云中包含的语义特征。并且随着GPU技术的进步,对大规模点云进行语义分割成为可能。基于深度学习的方法主要包括基于投影的方法^[5,6]、基于体素的方法^[7,8]和基于点的方法^[9-12]。

基于投影的方法主要思想是将三维点云投影到二维平面上,利用二维图像的算法进行处理。在2D图像算法的启发下,Su等^[13]首次在2015年提出多视图卷积神经网络(multi-view convolutional neural networks, MVCNN)。通过不同位置、角度的视点(虚拟相机)来捕获多个视角下的2D视图,然后经过卷积层(convolutional neural network, CNN),池化层(Pooling)转化为3D形状描述符,最后将聚合特征输入网络剩余部分,返回分割和分类结果。相比于传统方法MVCNN有较好的计算效率,在分割和分类任务中取得了较好的结果,但是MVCNN忽略了大量关键的几何信息,其结果受视点位置的影响,无法动态选择视图,不适合大规模点云场景。Boulch等^[6]提出SnapNet网络,将深度图像与RGB视图结合在一起,然后使用2D卷积技术进行特征提取,然后通过反投影对点云实现语义分割,虽然减少了三维点云数据的信息损失,但分割的精度仍受投影角度的影响。总体而言,基于投影方法的性能容易受视角和遮挡的影响。此外,投影步骤不可避免地存在信息损失,不能充分利用潜在的几何和结构信息。

基于体素的方法首先将无序点云转为体素网格,再用三维卷积网络处理体素单元。三维体素化很好地解决了原始点云无序和非结构化的问题。Daniel等提出的VoxelNet是最早基于体素数据的三维CNN模型,VoxelNet将体素单元作为输入对体素进行归一化处理,但是算法较复杂,对于大型点云数据需要较大的计算资源,网络性能受体素大小影响,需要根据实际情况设置参数。

Qi等^[9]提出的PointNet开启了直接在点云上进行深度学习分割的新时代。PointNet将点云作为输入,采用共享MLP学习每点的特征,采用最大池化聚合全局特征,克服了点云不规则、置换不变性和旋转不变性的问题。PointNet虽然取得了较好的分割效果,但是其忽略了点云的局部领域信息,未考虑到点云的邻近点关系,对密度不均匀的数据处理效果不好。为了解决PointNet缺少局部特征的问题,Qi等^[10]在PointNet的基础上提出了PointNet++,通过分层采样和特征提取提高了算法在稀疏点云上的鲁棒性,PointNet++网络考虑了点与点直接的距

离度量,解决了点云采样不均匀的问题,通过多层结构学习局部领域特征,使网络结构更稳健有效。但是PointNet++和PointNet一样,没有建立点与点之间的关系,对局部特征学习不够充分。

为了实现大规模点云的语义分割,Hu等^[11]提出了RandLA-Net,RandLA-Net采用随机采样算法取代了PointNet++的最远点采样算法,提高了点云采样的速度,使处理大规模点云成为可能。为了弥补随机采样带来的关键点信息丢失,RandLA-Net通过局部特征聚合模块来逐渐增加每个神经层的感受野大小,提高了模型对点云复杂结构的学习能力。首先,对每个3D点引入局部空间编码单元以保留局部几何结构信息,然后采用注意力机制聚合有用的局部特征,并通过堆叠多个局部空间编码和池化层来增加每个点的感受范围。文献[14]在以RandLA-Net为主干网络的基础上,将点云的法向量与网络提取出的特征进行融合,提高了语义分割的精度。文献[15]以RandLA-Net网络为基础将其应用到城市变化检测中,验证了深度学习方法进行城市提取和变化检测的可能性,取得了较好的成果。

尽管RandLA-Net可直接处理大规模点云,然而该网络的局部特征提取模块缺乏细粒度特征描述能力,网络缺乏全局上下文信息。为此,本文对RandLA-Net网络架构进行改进,将特征选择融入改进的RandLA-Net网络中,实现室内场景的点云语义分割,在S3DIS数据集上验证了本文算法的有效性。

1 方法原理与流程

为了充分利用点云的空间信息,提取点云深层的语义信息,本文融合点云多维特征选择的点云语义分割方法保留了RandLA-Net网络随机采样的特性,并将原始网络由5层编解码层缩减为4层,将经过特征排序的特征融入网络的局部特征聚合模块,增强网络提取高级特征的能力。本文方法主要流程如图1所示,首先计算点云的多维特征,包括点云的单点特征、形状特征和局部特征共 A 维,然后利用LightGBM作为基本分类器的改进的递归增加特征选择算法,根据与点云标签的相关性对特征进行排序,然后将最相关的前 t 维特征输入到点云语义分割网络进行网络学习,实现点云语义分割网络,最终输出点云的语义标签($N, label$)。

1.1 点云多维特征提取

点云多维特征包括单点特征、形状特征和局部特征等。

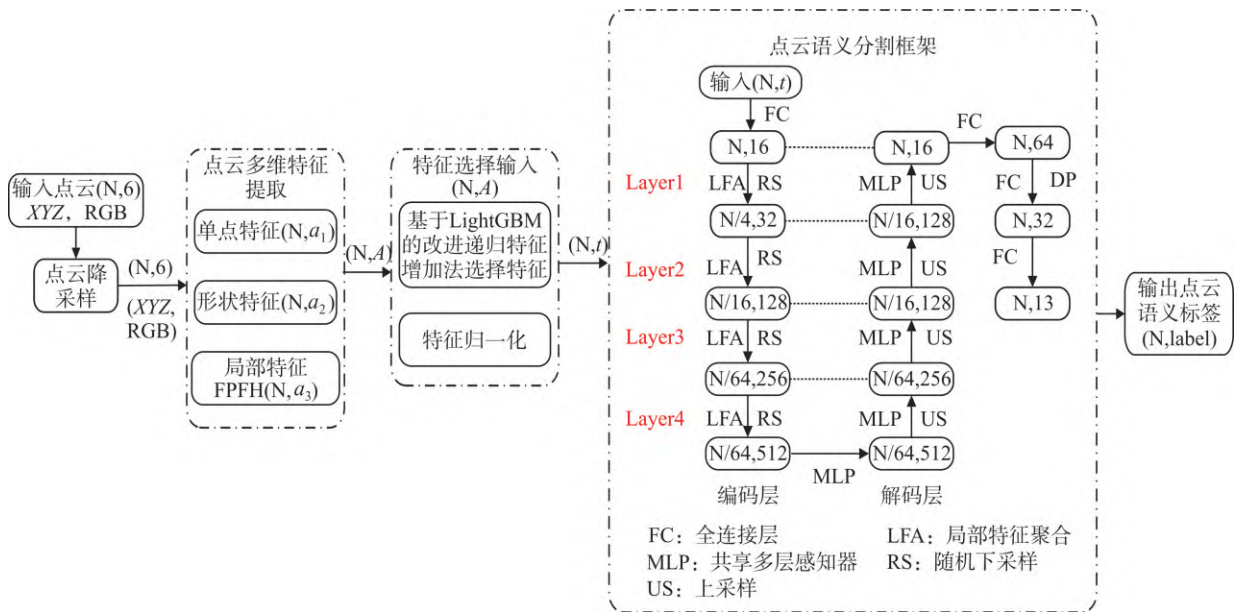


图 1 融合点云特征选择的点云语义分割方法流程

Fig. 1 Our Algorithmic Pipeline

1) 单点特征: 包括点云的三维坐标(X, Y, Z), 点云的颜色(R, G, B), 点云的回波强度(intensity), 点云的法向量(N_x, N_y, N_z), 点云曲率等。法向量是点云重要的特征之一, 一般采用PCA算法求得: 对任一点法线问题近似于估计表面相切面法线问题, 也就是最小二乘问题, 计算公式如下:

$$C = \frac{1}{k} \sum_{i=1}^k (p_i - \bar{p}) \times (p_i - \bar{p})^T \quad (1)$$

$$C \times n_i = \lambda_i \times n_i, i = 0, 1, 2 \quad (2)$$

式中, \bar{p} 表示任一点 p_i 的 k 个近邻点的质心; C 为协方差矩阵; λ_i 是协方差矩阵的特征值, 当 λ_i 为最小值

时, 对应的法向量 n_i 即为点 p_i 的法向量。

2) 形状特征: 包括人造物体存在基本的点线面等形状。考虑到点云数据也存在散乱点、线状点和面状点等类型, 可以通过分析单点 p_i 与其 k 个邻域点之间的局部关系, 可以得出点 p_i 的线状特征 L_λ 、面状特征 P_λ 、球形特征 S_λ 、各向异性 A_λ 等低维的几何特征。对式(2)中的协方差矩阵 C 进行正交分解可得到 $\lambda_1^i, \lambda_2^i, \lambda_3^i, \lambda_1^i \geq \lambda_2^i \geq \lambda_3^i, e_i = \frac{\lambda_i}{\sum \lambda_i}, i \in \{1, 2, 3\}$, 则点云的各种低维几何特征计算公式见表1。

表 1 几何特征计算公式

Tab. 1 Formulas for Calculating Geometric Features

形状特征	线性特征	平面性	球形	各向异性	全方差	特征熵	迹	曲率变化
计算公式	$L_\lambda = \frac{\lambda_1^i - \lambda_2^i}{\lambda_1^i}$	$P_\lambda = \frac{\lambda_2^i - \lambda_3^i}{\lambda_1^i}$	$S_\lambda = \frac{\lambda_3^i}{\lambda_1^i}$	$A_\lambda = \frac{\lambda_1^i - \lambda_3^i}{\lambda_1^i}$	$O_\lambda = 3 \sqrt[3]{e_1 e_2 e_3}$	$E_\lambda = -\sum_{i=1}^3 e_i \ln(e_i)$	$T_\lambda = \frac{2}{\pi} \arctan(\lambda_1 + \lambda_2 + \lambda_3)$	$C_\lambda = 3e_3$

3) 局部特征: 为了提供更多点云的局部特征信息, 引入FPFH(fast point feature histograms)特征描述符来表示点云的局部特征^[16], FPFH是PFH特征描述子的简化形式, PFH(point feature histogram)描述子通过特征点与其邻域点之间的空间差异参数化形成一个多维直方图描述该点在其邻域内的几何属性。PFH特征描述子基于特征点和其 k 个邻域点之间的关系, 来描述样本的几何特征, 如图2所示。图2中, 红色点 P_q 为查询点, 在指定半径内有 k 个邻域点, 对特征点 P_q 及其 k 个邻域点进行两两配对, 可以得到 $k(k+1)/2$ 个点对, 对每一对点对建立局部坐标系, 如式(3), 其中 \times 代表外积。




图 2 PFH 特征点及其邻域点

Fig. 2 PFH Feature Points and Their Domain Points

$$\begin{aligned} u &= n_s \\ v &= u \times \frac{(p_t - p_s)}{\|p_t - p_s\|^2} \\ w &= u \times v \end{aligned} \quad (3)$$

根据局部坐标系图3可得, PFH特征计算见式(4):

$$\begin{aligned} \alpha &= v \times n_t \\ \phi &= u \times \frac{(p_t - p_s)}{d} \\ \theta &= \arctan(w \times n_t, u \times n_t) \\ d &= \|p_t - p_s\|^2 \end{aligned} \quad (4)$$




图3 局部坐标系示意图

Fig. 3 Schematic Diagram of the Local Coordinate System

通过计算 k 领域内所有点对 p_s 和 p_t 的 $(\alpha, \phi, \theta, d)$ 四元组, 将所有点对的 $(\alpha, \phi, \theta, d)$ 放入直方图中, 进行投票统计, 即可得到 PFH 特征描述子。PFH 的计算时间复杂度为 $O(nk^2)$, 对于大型点云计算效率很低。SPFH 特征描述子首先计算查询点 p_s 与其 k 领域点的 (α, ϕ, θ) , 得到简化点特征直方图, 然后通过加权求和得到 FPFH, 其时间复杂度为 $O(nk)$, 其计算见式(5), 其中, w_k 代表权重, 由查询点到领域点距离决定:

$$\text{FPFH}(p_s) = \text{SPFH}(p_s) + \frac{1}{k} \sum_{i=1}^k \frac{1}{w_k} \text{SPFH}(p_k) \quad (5)$$

1.2 点云特征选择

冗余的特征会导致网络模型复杂, 学习难度大, 导致模型过拟合, 因此本文对提取出的特征进行筛选, 选择与点类标签关系最密切的特征作为深度学习网络的输入特征。特征选择的方法一般包括过滤法、包装法和嵌入法^[17-18], 本文使用 LightGBM 分类器^[19-20]作为递归特征增加法的基本分类器, 采用 F1 得分作为衡量特征重要性的指标, 改进的递归特征增加法(modified recursive feature addition, MRFA)算法流程如下:

1) 计算所有特征与点云类别标签之间的相关系数 COR_1 , 若 COR_1 小于所设阈值 t_1 , 将该特征舍去;

2) 计算特征之间的相关系数 COR_2 , 若 COR_2 大于所设阈值 t_2 , 将后加入特征舍去, 否则保留;

3) 将筛选后的特征集合加入 LightGBM 分类器中进行训练, 然后利用 LightGBM 重要性方法对筛选特征进行排序;

4) 构建只包含最重要特征的 LightGBM 模型, 并计算其 F1 得分 f_1 ;

5) 在剩余特征中选取一个最重要的特征, 并利用选取的特征和之前保留的特征构建 LightGBM 模型, 并计算其 F1 得分 f_2 ;

6) 如果 $\Delta f = f_2 - f_1$ 大于所设阈值 Tol, 则将所选取特征保留, 否则将其舍去;

7) 重复步骤 3)~步骤 6), 直到所有特征选择完毕。

为加快后续深度学习训练的速度, 由于不同的特征的数值范围不一致, 这里对筛选出的特征进行归一化处理, 将特征映射到 $[-1, 1]$ 之间。

1.3 点云语义分割网络

本文点云语义分割网络主干网络选择与 RandLA-Net 相似的结构, 主要包括 4 层编解码层和 3 个全连接层。每一层编码层包括局部特征聚合模块和随机下采样。通过对点云进行降采样, 点云数量降低为 $N/256$, 每层的特征维度设置为 $[32, 128, 256, 512]$ 。通过局部特征聚合模块(local feature aggregation, LFA)得到最终的聚合特征。其过程如下:

1) 对输入点云每一点及 K 邻近点的位置信息进行局部空间编码(local spatial encoding, LocSE), 使网络能够从点云的相对位置关系和距离信息中更好地学习到空间几何结构, 具体编码过程如下: 对点云中任一点使用 K 邻近算法搜索其 k 个邻近点, 将 p_i 及其 K 个邻近点按照式(6)进行编码。

$$r_i^k = \text{MLP}(p_i \oplus p_i^k \oplus (p_i - p_i^k) \oplus \|p_i - p_i^k\|) \quad (6)$$

式中, $(p_i - p_i^k)$ 代表中心点 p_i 与 p_i^k 的相对坐标; $\|p_i - p_i^k\|$ 代表中心点 p_i 与 p_i^k 的欧氏距离。将 r_i^k 与领域点 p_i^k 对应的点特征 f_i^k 连接在一起, 得到新的点特征 \hat{f}_i^k 。

2) 利用注意力池化模块来进行自动学习和聚合重要的局部特征, 而对于给定的局部特征集合 $\hat{F}_i = \{\hat{f}_i^1, \dots, \hat{f}_i^k, \dots, \hat{f}_i^K\}$, 通过共享函数 $g(\cdot)$ 计算得到每个特征的注意力分数, 计算见式(7), 其中 W 为可学习的参数:

$$s_i^k = g(\hat{f}_i^k, W) \quad (7)$$

将注意力分数作为掩膜自动选择最重要的特征, 去除不重要的特征, 然后将局部特征和注意力分数进行加权求和得到局部聚合特征 \tilde{f}_i , 计算公式为:

$$\tilde{f}_i = \sum_{i=1}^k (\hat{f}_i^k \cdot s_i^k) \quad (8)$$

点云 P 中的任一点 p_i 经过局部特征编码和注意力池化模块,得到的聚合特征 \tilde{f}_i 既包括了 p_i 的单个特征信息,又包括了点 p_i 与其 K 近邻点的几何结构信息和 K 个近邻点的特征信息。

3) 考虑到随机采样算法有可能造成关键点 p_i 信息丢失,因此,将局部空间编码、注意力池化和多层感知机进行堆叠组成扩张残差块,在只有一个扩张残差块时, p_i 能够接收到其 K 个近邻点的信息,在叠加 n 个扩张残差块后, p_i 最多能够接收 K^n 个近邻点信息,通过残差块叠加来扩大每个点对其近邻点的感受范围,降低关键点丢失对网络的影响。并在每个扩张残差块中的局部空间编码模块前输入点的位置信息,同时在输入前与输出后馈入多层感知机,得到必要的特征数,并将堆叠后的输出特征与输入点云经过多层感知机处理后的特征相加,得到最终的聚合特征。

4) 经过四层编码层后,点云数量降低,而每个点包含的特征维度提高,经过一层全连接层进入解码层。在四层解码层中,每一层利用最近邻插值算法进行上采样,将点云恢复到原始数量,将更新的采样点特征与编码层生成的中间特征进行跳层连接,将新的特征输入多层感知机中,通过 3 个全连接层 (fully connected layers, FC) 和随机失活层 (Drop-out) 输出点云的语义标签 (N, label)。

2 实验与结果分析

为了验证本文算法的有效性,选择斯坦福开源室内点云数据集 S3DIS (stanford large-scale 3D indoor spaces dataset, S3DIS) 进行分析, S3DIS 是斯坦福大学提供的大场景室内 3D 点云数据集,由 6 个大型室内区域的 272 个房间组成,每个场景点数在 50 万到 250 万之间,总点数约 6.9 亿,点云中每一个点都有手动标注的标签,共有 13 类语义标签,包括天花板、地板、门、窗等 (见图 4), 每个点都提供了三维坐标 XYZ、RGB 颜色信息和归一化的空间坐标信息。本文实验环境为 ubuntu18.04, 内存 48GB,



图 4 S3DIS 点云类别示意图

Fig. 4 S3DIS Point Class

CPU:i7-8700K, GPU:NVIDIA GTX1080Ti*2, 深度学习框架为 pytorch1.13.1, CUDA 版本为 10.2。

2.1 点云语义分割评价指标

本文选择常用的点云语义分割的精确度评价指标:全局准确度 (overall accuracy, OA), 平均交并比 (mean intersection over union, mIoU), 平均准确度 (mean accuracy, mAcc) 等。OA 是数据集中分割正确的样本数与总样本数之比; 交并比 (IoU) 是模型对某一类别预测结果和真实值的交集与并集的比值, 其用于测量真实值和预测值之间的相关度, 相关度越高, 该值越高; mIoU 则是所有类别 IoU 的平均值; mAcc 是数据集中每个类别的分割准确率求和再平均的结果。OA、IoU、mIoU、mAcc 的计算公式如下:

$$OA = \frac{n}{N} \quad (9)$$

$$IoU = \frac{\sum_{i=1}^k p_{ii}}{\sum_{j=1}^k p_{ij} + \sum_{j=1}^k p_{ji} - p_{ii}} \quad (10)$$

$$mIoU = \frac{1}{k} \frac{\sum_{i=1}^k p_{ii}}{\sum_{j=1}^k p_{ij} + \sum_{j=1}^k p_{ji} - p_{ii}} \quad (11)$$

$$mAcc = \frac{1}{k} \frac{\sum_{i=1}^k p_{ii}}{\sum_{j=1}^k p_{ij}} \quad (12)$$

式中, k 表示场景的点云类别数; p_{ij} 表示类别为第 i 类, 被标注为第 j 类的点; p_{ii} 表示标注为第 i 类的正确标注点; p_{ji} 表示标注为第 j 类, 被分为第 i 类的点。mIoU 和 OA 越大, 分割效果越好, $mIoU \leq OA$ 。

2.2 实验分析

2.2.1 实验结果初步分析

针对 S3DIS 数据集, 本文设置 batch_size=4, 模型初始输入点数为 20 480, 实验中采用 Adam 优化器, 初始学习率为 0.01, 每一个 epoch 学习率衰减率设置为 0.95, 设置最大迭代次数为 100。参考其他文献中测试集选择, 本文选择场景较复杂且与其他场景的不同的 Area5 场景共 68 个点云数据作为测试集, Area1、Area2、Area3、Area4 和 Area6 共 5 个场景 204 个点云数据作为训练集, 表 2 为不同的算法在

表 2 不同算法在 S3DIS 上的结果

Tab. 2 Results of Different Algorithms on S3DIS

模型	OA/%	mAcc/%	mIoU/%
PointNet	79.3	49.0	41.1
PointNet++	84.0	63.6	55.2
RandLA-Net	87.2	71.5	62.4
本文算法	87.8	82.0	62.95

S3DIS上的运行结果。

由表2可以看出,本文算法的OA和mAcc均高于另外3种算法,相比于RandLA-Net模型OA提高了0.6%,mAcc提高了11.5%,mIoU与RandLA-Net算法接近,高于PointNet和PointNet++算法。

表3列出了PointNet,PointNet++,RandLA-

Net和本文算法在Area5上测试得到的13个类别点云的IoU结果。

由表3可以看出,本文算法在墙壁,窗户,桌子,椅子、书桌、黑板和杂物取得了比较好的分割精度。但是对于梁的分割精度很低,原因是存在类别不平衡,梁的点数远小于其他类别。

表3 S3DIS数据集中Area5语义分割结果IoU/%

Tab. 3 Area5 Semantic Segmentation Result in S3DIS Dataset IoU/%

算法	ceiling	floor	wall	beam	column	window	door	table	chair	sofa	bookcase	board	clutter
PointNet	87.40	97.80	71.20	0	9.20	52.10	16.40	58.20	48.50	3.20	48.30	39.00	36.20
PointNet++	90.50	98.10	75.80	0	6.80	57.60	21.50	69.60	79.30	50.70	62.50	58.80	45.70
RandLA-Net	88.90	93.90	75.50	0.1	20.60	53.00	43.70	68.10	72.80	65.40	63.40	55.90	45.80
Ours	92.36	97.38	81.48	0	24.59	60.43	43.35	78.01	85.23	65.16	70.39	67.63	52.36

2.2.2 特征选择对分割结果的影响

为了评估本文特征选择算法对点云语义分割结果的影响,本文测试了输入特征维度为6,9,12,14,15,16,20,25等的语义分割结果,结果见表4及图5。

由表4及图5可以看出,在四层网络结构下,随着输入特征个数的增加,OA、mAcc、mIoU会出现先升高后降低的趋势,当特征输入为15维时,分割结果最好。当输入特征增加到20维后,训练速度明显变慢,一个epoch需要21min,而在16维以下时每个epoch只需要7min,时间成本增加了三倍,分割结果却变差。

表4 网络输入特征个数对点云分割结果影响

Tab. 4 Different Features on the Point Cloud Segmentation Result

特征个数	OA/%	mAcc/%	mIoU/%
6	68.44	67.32	44.41
9	70.07	69.07	46.95
12	72.17	71.57	47.20
14	75.26	72.49	55.14
15	87.8	82.00	62.95
16	68.97	69.67	45.52
20	69.48	68.63	45.67
25	68.44	67.32	44.41

2.2.3 单个点云分析

为了更直观地展示本文算法的分割效果,选择Area5中点数最多office8的点云进行可视化分析,如图6所示。并统计不同算法下Office8中不同类别点




图5 不同特征维度对结果的影响

Fig. 5 Effect of Different Feature Dimensions on the Results

云的Accuracy结果见表5。

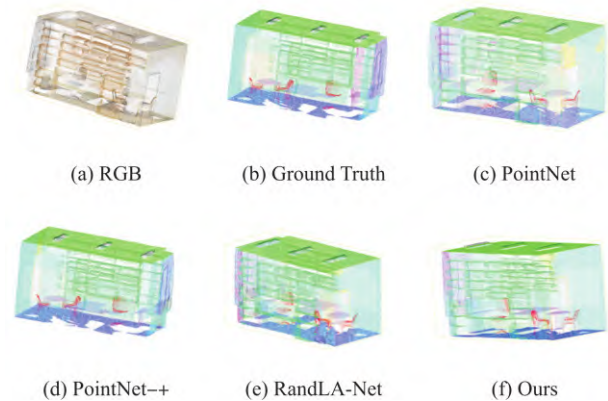


图6 Area_5_office_8不同算法运行结果

Fig. 6 Area_5_office_8 Results of Different Algorithms

从图6与表5中可以看出,本文算法对Area_5_office_8的柱子、窗户、黑板和其他杂类点云具有较好的分割精度,几种算法的sofa和beam的精度均为0,故未在表5中标出,其中PointNet在书橱的边

表5 Area_5_office_8各类别精度/%

Tab. 5 Area_5_office_8 Class Accuracy/%

算法	mAcc	ceiling	floor	wall	column	window	door	table	chair	bookcase	board	clutter
PointNet	64.22	99.28	98.12	81.55	35.16	90.26	57.91	82.90	95.99	91.53	72.66	29.45
PointNet++	72.75	99.32	94.74	76.99	62.96	99.41	91.64	89.19	99.95	96.21	87.26	48.11
RandLA-Net	72.94	98.86	98.52	89.09	69.59	95.12	93.76	95.18	97.92	95.23	73.90	41.08
Ours	77.11	99.47	97.64	86.57	76.09	99.22	92.47	98.35	99.44	93.58	86.45	73.17

缘存在错分,对柱子的分割精度只有 35.16%,远低于其他三种算法,而 RandLA-Net 将柱子错分为墙面,对黑板的分割精度也较低。进一步分析可知,PointNet 由于没有建立近邻邻域,未提取点云的局部特征;而 PointNet++ 和 RandLA-Net 在一些物体的边缘和细节上分割效果不太理想,容易出现多类杂糅边界模糊不清,本文算法在提取局部特征时,考虑了近邻域中点自身特征向量的相关性,将多种特征融入网络中,得到了更好的分割结果。

3 结束语

本文提出的融合点云多维特征选择的点云语义分割方法保留了 RandLA-Net 网络处理大规模点云的能力,并将原始网络由 5 层编解码层缩减为 4 层,将经过特征排序的特征融入网络的局部特征聚合模块,增强网络学习高级特征的能力,利用 4 层解码层和 3 层全连接层实现室内点云的语义分割,输出点云语义标签。实验结果表明,本文算法在 S3DIS 数据上取得了较好的语义分割结果。然而本文算法的几何特征是在固定领域下求得,容易受点云密度影响,因此,下一步的工作重点是如何根据点云数据的密度自动选择最佳邻域,进而提高点云分割的精度。

参考文献

- [1] 杨必胜,董震.点云智能研究进展与趋势[J].测绘学报,2019,48(12):1575-1585
- [2] 邹禄杰,花向红,赵不钊,等.点云场景语义标注的排序批处理模式主动学习法[J].测绘学报,2023,52(2):260-271
- [3] 黄宇航,宋友,王宝会.改进的森林优化特征选择算法在信用评估中的应用[J].计算机科学,2023,50(S1):531-536
- [4] 李海亭,肖建华,李艳红,等.机器学习在车载激光点云分类中的应用研究[J].华中师范大学学报(自然科学版),2015,49(3):460-464
- [5] Li Y, Bu R, Sun M, et al. PointCNN: Convolution on X-Transformed Points[C]. Neural Information Processing Systems, Montreal, Canada, 2018
- [6] Boulch A, Guerry Y, le Saux B, et al. SnapNet: 3D Point Cloud Semantic Labeling with 2D Deep Segmentation Networks[J]. Computers & Graphics, 2017, 71 (APR.):189-198
- [7] 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), IEEE, Hamburg, Germany, 2015
- [8] Riegler G, Ulusoy A O, Geiger A. OctNet: Learning Deep 3D Representations at High Resolutions [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, Honolulu, HI, USA, 2017
- [9] Qi C R, Su H, Mo K, et al. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation [J]. 2016, doi:10.48550/arXiv.1612.00593
- [10] Qi C R, Yi L, Su H, et al. PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space[J]. 2017, doi:10.48550/arXiv.1706.02413
- [11] Hu Q, Yang B, Xie L, et al. RandLA-Net: Efficient Semantic Segmentation of Large-Scale Point Clouds [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, Seattle, WA, USA, 2020
- [12] 吴军,崔玥,赵雪梅,等. SSA-PointNet++:空间自注意力机制下的 3D 点云语义分割网络[J]. 计算机辅助设计与图形学学报, 2022, 34(3): 437-448
- [13] Su H, Maji S, Kalogerakis E, et al. Multi-view Convolutional Neural Networks for 3D Shape Recognition [J]. IEEE, 2015, doi:10.1109/ICCV.2015.114
- [14] 张春娇,徐胜华,刘正军,等.顾及法向量的点云语义分割方法[J].测绘科学,2022,47(7):126-134
- [15] 孟琮棠.基于 RandLA-Net 的机载 LiDAR 点云城市典型地物变化检测[D].徐州:中国矿业大学,2023
- [16] Rusu R B, Blodow N, Beetz M. Fast Point Feature Histograms (FPFH) for 3D Registration[C]. IEEE International Conference on Robotics & Automation, IEEE, Kobe, Japan, 2009
- [17] 李郅琴,杜建强,聂斌,等.特征选择方法综述[J].计算机工程与应用,2019,55(24):10-19
- [18] Meng Q. LightGBM: A Highly Efficient Gradient Boosting Decision Tree [C]. Neural Information Processing Systems, Long Beach, CA, 2017
- [19] 李占山,姚鑫,刘兆庚,等.基于 LightGBM 的特征选择算法[J].东北大学学报(自然科学版),2021,42(12):1688-1695
- [20] 尚志刚,董永慧,李蒙蒙,等.基于偏最小二乘回归的鲁棒性特征选择与分类算法[J].计算机应用,2017,37(3):871-875

修回日期:2024-11-08

第一作者:杨森,硕士,主要研究内容为点云数据处理与应用。
E-mail:864022611@qq.com

通信作者:花向红,教授,主要从事点云数据处理与质量评价及应用、工程测量与工程变形监测预报、专题 GIS、多传感器信息融合室内外导航定位技术。E-mail: xhhua@sgg.whu.edu.cn