

基于 KNN-PointNet 的点云语义分割

杨晓文*, 王爱兵, 韩燮, 赵融, 靳瑜昕

中北大学大数据学院, 山西 太原 030051

摘要 针对深度神经网络 PointNet 未引入局部特征以及分割精度有待提高的问题,在 PointNet 的基础上提出一种结合改进 K 近邻(KNN)算法的局部特征提取方法,将引入局部特征提取方法的神经网络命名为 KNN-PointNet。首先将局部区域划分为 k 个圆形邻域,根据局部区域中样本数据分布密度的差异来确定权值以计算待测点的分类情况;其次将局部邻域特征结合单点全局特征作为输入进行特征提取,通过调节网络深度来提取局部特征以增强局部邻域中点与点的相互关联;最后将改进的 KNN 算法应用于 KNN-PointNet 点云分割网络进行实验对比。实验结果表明,相比于当前一些先进的分割网络,采用改进 KNN 算法的分割网络 KNN-PointNet 具有更高的分割精度。

关键词 图像处理; KNN 算法; 局部特征; PointNet; 密度差异; 点云分割

中图分类号 TP183

文献标志码 A

doi: 10.3788/LOP202158.2410013

Point Cloud Semantic Segmentation Based on KNN-PointNet

Yang Xiaowen*, Wang Aibing, Han Xie, Zhao Rong, Jin Yuxin

School of Data Science and Technology, North University of China, Taiyuan, Shanxi 030051, China

Abstract To overcome the lack of local features of the deep neural network PointNet and the need for the improvement of segmentation accuracy, the present research introduces a local feature extraction method combined with an improved K-nearest neighbor (KNN) algorithm based on PointNet and a neural network known as KNN-PointNet. First, the local area is divided into k circular neighborhoods, and weights are determined according to the difference in the distribution density of sample data in the local area to calculate the classification of the points to be measured. Second, the local neighborhood features combined with single point global features are used as input for feature extraction by adjusting the network depth to extract local features for enhancing the correlation between points in the local neighborhood. Finally, the improved KNN algorithm is applied to the KNN-PointNet point cloud segmentation network for experimental comparison. Results show that compared with some current advanced segmentation networks, the segmentation network KNN-PointNet with local features extracted by the improved KNN algorithm has higher segmentation accuracy.

Key words image processing; KNN algorithm; local features; PointNet; density difference; point cloud segmentation

OCIS codes 100.4996; 200.4260; 150.1135

1 引言

随着 3D 传感技术的发展,物体的颜色、三维坐标和深度信息等 3D 数据的采集越来越便捷。3D

数据具有丰富的表示形式,如深度图像、点云和体素网格,在自动驾驶^[1]、机器人技术^[2]、无线遥感^[3]、医疗^[4]和建筑^[5]等领域具有广泛的应用前景。点云数据是一种常用的 3D 数据格式,其可以将原始的几

收稿日期: 2021-05-26; 修回日期: 2021-06-20; 录用日期: 2021-07-20

基金项目: 山西省回国留学人员科研资助项目(2020-113)、山西省重点研发计划(201903D121147)、山西省自然科学基金(201901D111150)

通信作者: *wenyang1314@nuc.edu.cn

何信息保留在 3D 空间中。在保留数据点信息方面,相比于体素网格,点云数据显得更为出色,因此将其作为一种 3D 数据表示形式是许多场景理解相关应用(自动驾驶和机器人技术)的首选表示。近年来,随着深度学习的发展以及硬件设备的更新,大规模三维场景的识别与理解逐渐引起了众多学者的关注,但在技术创新方面面临新的挑战。语义分割作为三维场景理解的关键技术,已成为导航定位^[6]、计算机视觉^[7]、智能机器人^[8]和测绘地理信息^[9]等科学领域中重要的研究热点。

近年来,随着 3D 数据在深度学习中的广泛应用,2017 年 Charles 团队^[10]提出了点云分类和分割网络 PointNet,其是一种直接以点云数据作为输入对象的深度学习神经网络,分割网络利用多层感知机(MLP)来提取全局特征向量,利用对称函数来解决无序的问题,最终取得了不错的目标识别效果和较高的分割精度。然而,PointNet 只能学习点云的全局特征,忽略了局部特征,因此该网络在分割场景细节方面精度欠佳。针对这一问题,Charles 团队^[11]对 PointNet 进行了改进,提出了 PointNet++,该网络在局部特征方面考虑到了空间中点与点之间的距离,通过对局部邻域特征的提取并有效利用局部区域中的特征信息,可以使网络的目标识别和分割精度都获得一定程度的提高。2018 年,Li 等^[12]在 PointNet 的基础上进行改进,提出了 PointCNN(Point Convolutional Neural Network)结构模型,首先使用该模型来分析点云特性,接着从点云中学习得到线性变换矩阵,然后将其与点关联输入特征(坐标和颜色等)进行卷积处理,可以将这些特征信息重新排列成隐含的规范顺序。虽然线性变换矩阵在点云卷积处理方面的性能有所提高,但在点云排序方面的表现并不理想,为此其还有较大的改进空间。2020 年,Jiang 等^[13]提出了一种新的端到端自底向上的体系结构,其通过探索对象之间的空隙以更好地对点进行分组。在聚类分量的基础上,首先根据原始坐标点集和偏移坐标点集的互补性来建立记分网以评估候选实例,接着采用非最大抑制法来消除重复点,这在点云场景的分割方面取得了较好的效果。上述网络结构的出现为后续基于深度学习的点云分割方法的提出指引了方向,而且具有重要的理论研究价值。

本文在 PointNet 的基础上,将点的 K 邻域特征与单点全局特征的结合作为输入并对高维特征进行提取,可以增强点与点之间的相互关联;在卷积层改

变卷积核的大小和调节网络深度提取局部特征的同时,通过特征融合来提高点云数据的分割精度,最后应用于室内场景的分割。

2 改进 K 近邻算法

2.1 K 近邻算法

K 近邻(KNN)算法^[14]是一种出现较早的经典机器学习算法,该算法的核心思想是在给定的样本特征空间中,如果待预测样本点附近 k' 个样本点中的多数属于某一个样本点的类别,那么该样本点也属于该类别。KNN 算法不需要初始训练,仅仅在待预测样本分类的过程中进行预测,可以减少模型训练的时间开销,说明其是一种惰性学习算法,其中 k' 值的选择、距离度量和分类决策规则是 KNN 算法的三要素,详细介绍如下。

1) k' 值的选择对算法的准确性具有较大的影响,因此成为 KNN 算法的研究热点之一。

2) 距离度量对于 KNN 算法而言是一个关键问题。在给定的样本数据中计算待预测样本点与附近样本点之间的欧氏距离,根据距离可以直接决定哪些样本点会进入前 k' 个样本点。假设现有的特征空间 H 是 f 维实数向量, $\mathbf{m}_{i^*} \in \mathbf{R}^f, \mathbf{m}_j \in \mathbf{R}^f$, 其中 $\mathbf{m}_{i^*} = [\mathbf{m}_{i^*}^{(1)} \mathbf{m}_{i^*}^{(2)} \cdots \mathbf{m}_{i^*}^{(f)}]^\top, \mathbf{m}_j = [\mathbf{m}_j^{(1)} \mathbf{m}_j^{(2)} \cdots \mathbf{m}_j^{(f)}]^\top$, i^* 和 j 分别为空间中的第 i^* 个点和第 j 个点, \mathbf{m}_{i^*} 与 \mathbf{m}_j 之间的距离可表示为

$$L_l(\mathbf{m}_{i^*}, \mathbf{m}_j) = \left(\sum_{c=1}^f \|\mathbf{m}_{i^*}^{(c)} - \mathbf{m}_j^{(c)}\|_l \right)^{1/l}, \quad (1)$$

式中: l 为不同取值可表示不同距离。当 $l=2$ 时, \mathbf{m}_{i^*} 与 \mathbf{m}_j 之间的距离即为欧氏距离,表达式为

$$L_2(\mathbf{m}_{i^*}, \mathbf{m}_j) = \left(\sum_{c=1}^f \|\mathbf{m}_{i^*}^{(c)} - \mathbf{m}_j^{(c)}\|_2 \right)^{1/2}. \quad (2)$$

另外,当 $l=1$ 时距离为曼哈顿距离,当 $l=\infty$ 时距离为切比雪夫距离。

3) 分类决策规则是决定待测样本最终所属类别的一个重要因素。通常情况下,分类决策规则的投票决定策略是少数服从多数,即挑选距离待测样本点最近的 k' 个样本点, k' 个样本点中所属类别最多的那个类别作为待测样本点的所属类别。

给定数据集 $P = \{(a_1, b_1), (a_2, b_2), \dots, (a_{n'}, b_{n'})\}$, 其中 $a_{n'}$ 为样本点 a 邻域的第 n' 个特征点, $b_{n'}$ 为样本点 a 邻域的第 n' 个样本点所属分类, $b = \{\partial'_1, \partial'_2, \dots, \partial'_{M'}\}$, M' 为类别的总数,现有的样本数据量为 N 。由(2)式可知,根据距离结果来排序选

取距离待测样本点最近的 k' 个点, 可以确定待测样本点所属的类别 b 。具体来说, 通过计算待测样本点的 k' 个近邻点的类别统计结果, 将待测点归属于统计值最高的类别, 表达式为

$$b = \operatorname{argmax}_{\partial_{z'}} \sum_{a_{i'} \in N_{k'}(a)} I(b_{i'} = \partial_{z'}), i' = 1, 2, \dots, n', \dots, N, z' = 1, 2, \dots, M', \quad (3)$$

式中: $N_{k'}(a)$ 为包含 k' 个样本点的 a 邻域; I 为指示函数, 可表示为

$$I_{b_{i'}} = \begin{cases} 1, & b_{i'} = \partial_{z'} \\ 0, & b_{i'} \neq \partial_{z'} \end{cases} \quad (4)$$

对于大型点云数据而言, 将 KNN 算法直接应用于点云局部特征的提取会造成时间的复杂度相对较高, 采用增大 k' 值的方法会造成分类的准确度降低, 因此需要改进传统 KNN 算法再应用于点云数据中局部特征的提取。

2.2 改进的 KNN 算法

对于大型且密度不均匀数据集中局部特征的提取, 基于二维圆形结构来详细阐述改进 KNN 算法的具体过程。在三维空间中, 以球体代替二维圆形结构, 改进 KNN 算法的执行步骤如下。

1) 在样本空间中, 以待测样本点 x 为圆心 and r 为半径来划定圆形邻域 $R = \{\|x - x_i\|_2 \leq r\}$ 。

2) 定义一组位置 $\{x_k | k < q\} \in R$, 其中 q 为局部邻域中的样本点数。

局部邻域中待测点的归类效果如图 1 所示。从图 1 可以看到, 将局部邻域划分为 k 个圆形邻域, 半径均为 g' , 中间实心部分为待测样本点 x , 五角星、三角形和小圆形为样本点类别。给定数据集 $Q = \{(x_1, y_1), (x_2, y_2), \dots, (x_w, y_w)\}$, 其中 x_w 为第 w 个样本点, $y = \{\partial_1, \partial_2, \dots, \partial_M\}$ 为样本点的




图 1 局部邻域中待测点的归类效果

Fig. 1 Classification effect of points to be measured in local neighborhood

类别。

3) 从图 1 可以看到, 在划定的局部邻域内选取 k 个圆形邻域, 每个圆形邻域中样本点的数量根据所处位置处密度的不同而存在差异。计算待测样本点在 k 个圆形邻域的分类结果 β_t (t 为待测样本点的第 t 个圆形邻域, $t = 1, 2, \dots, k$), 表达式为

$$\beta_t = \operatorname{argmax}_{\partial_z} \sum_{x_i \in k_n(x)} I(y_i = \partial_z), i = 1, 2, \dots, k_n, z = 1, 2, \dots, M, \quad (5)$$

式中: k_n 为 k 个圆形邻域中某一个圆形邻域内的样本点集。为分类结果 β_t 赋予权重 λ_t , 其中 λ_t 为圆形邻域内样本点数与局部邻域内样本点数 q 的比值。

4) 计算 k 个圆形邻域的加权分类结果, 判断待测样本点的所属类别。考虑 k 个圆形邻域的加权分类结果, 将 (3) 式改写为

$$y = \operatorname{argmax}_{\partial_z} \sum_{g \in k} \beta_g \lambda_g I, g = 1, 2, \dots, k, z = 1, 2, \dots, M, \quad (6)$$

式中: g 为 k 个圆形邻域中第 g 个圆形邻域; $\beta_g \lambda_g$ 为 k 个圆形邻域中某一个圆形邻域所代表的目标类别加权积; y 为待测样本点的最终归类。

5) 将改进后的 KNN 算法应用于深度学习点云分割网络 KNN-PointNet, 以其中一个圆形邻域为例, 使用 MLP 来提取圆形邻域中每一个点的特征, 然后执行最大池化操作以提取局部特征, 表达式为

$$p_i = M_{\text{MAX}}\{h(x_1), h(x_2), h(x_3), \dots, h(x_n)\}, \quad (7)$$

式中: p_i 为在某一个圆形邻域中提取的局部特征; h 为多层感知机。

局部邻域中特征的提取过程如图 2 所示, 其中 d 为维度, n 为圆形邻域中特征点的个数。对 k 个圆形邻域中每个圆形邻域上的所有点进行特征提取再升高维度以扩大感受野, 提取高层次的点云特征并采用 MLP 来降低维度, 然后执行最大池化操作以提取全局特征并将其作为该圆形邻域中的局部特征, 最后拼接 k 个圆形邻域中的局部特征。对于 k 个子区域未覆盖的样本区域, 将整个局部区域中的全局特征复制 $q - k$ 次并与 k 个圆形邻域中的局部特征拼接。采用改进的 KNN 算法来提取局部特征, 在极少特征损失的情况下提高了网络模型的分割精度。

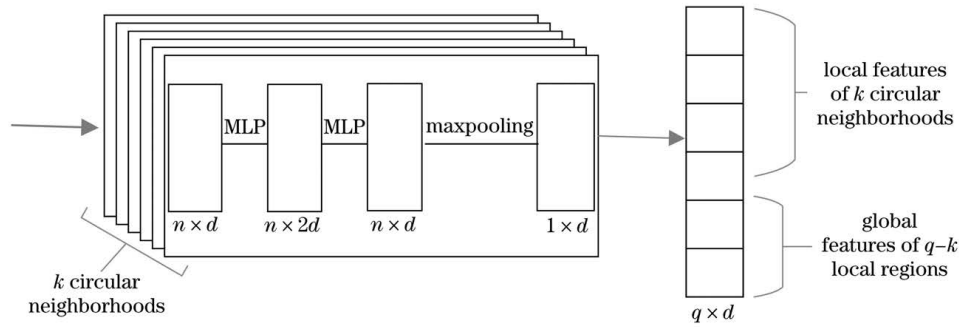


图 2 局部特征的提取过程

Fig. 2 local feature extraction process

3 改进的点云分割网络结构

PointNet 是较为先进的基于深度学习的三维语义分割网络模型,但其只能提取单点特征后执行最大池化操作,未提取局部特征,因此该网络模型对局部邻域中点云特征的描述能力较弱,使得训练和测试的过程中学习到的点云局部特征不足,导致点云的分割精度较低。为了获取更高的分割精度,选取改进的 KNN 算法来提取局部特征,将局部特征提取方法引入 PointNet 网络,并命名为 KNN-

PointNet。

KNN-PointNet 的框架如图 3 所示,其中 m 为维度。首先利用改进的 KNN 算法来搜索局部邻域,对局部邻域中的点云数据使用 MLP 来升高维度以扩大感受野,从而方便提取不同层次的点云特征;然后将点特征和局部特征结合起来,对获取的高维特征通过最大池化操作来实现全局特征的提取;将全局特征拼接在 128 维的局部特征上并通过 MLP 来输出逐点的分类概率,从而实现分割目标。

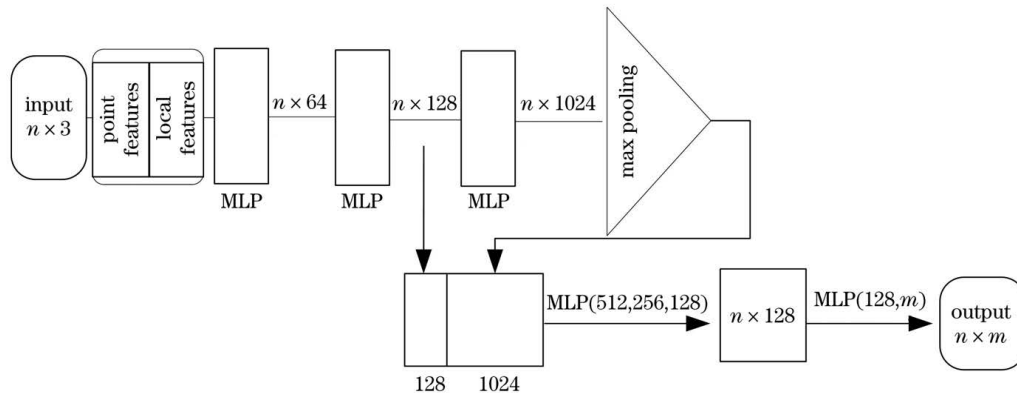


图 3 KNN-PointNet 的框架

Fig. 3 KNN-PointNet framework

以 S3DIS 数据集为研究对象,该数据集是由斯坦福大学开发且带有像素级标注的语义数据集。S3DIS 数据集中有 6 个大型室内区域,共包括 544 个房间,特征点超过了 2.15 亿,区域中包括办公区域、教育和展览空间、会议室、个人办公室、卫生间、开放空间、大堂、楼梯和走廊。每个点包含坐标信息(XYZ)、归一化坐标和颜色信息(RGB),同时还附加了所属的 13 个语义标签类别信息(桌子、椅子、沙发、书架和木板等)。

PointNet 能够直接应用于三维点云数据,但是无法获得局部特征,所以复杂场景的分割精度仍有

待提高。针对 PointNet 无法提取局部特征的问题,引入改进的 KNN 算法来加强局部特征的提取,从而提高复杂场景的分割精度。为了验证改进 KNN 算法的有效性和可行性,将其与 KNN 算法进行对比。实验是在处理器为 Intel(R) Core(TM) i7-9700 CPU @3.00 GHz、内存为 64 GB 和显卡为 TITAN RTX 的工作站上完成。采用改进 KNN 算法与 KNN 算法对点云数据进行三次分割,结果如图 4 所示,将日志文件的分割结果通过 Python 软件中的 matplotlib 绘图工具来直观展示,可以看出改进 KNN 算法的点云分割精度高于 KNN 算法,其中

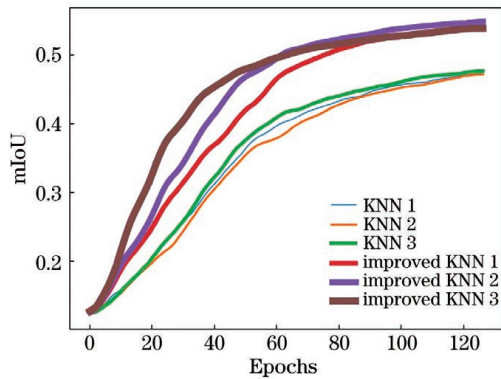


图 4 改进 KNN 算法与 KNN 算法的分割结果

Fig. 4 Segmentation results of improved KNN algorithm and KNN algorithm




图 5 不同算法下场景分割的可视化结果。(a)原始点云;(b)真实分割;(c)PointNet;(d)PointNet++

Fig. 5 Visualization results of scene segmentation under different algorithms. (a) Original point cloud; (b) true segmentation; (c) PointNet; (d) PointNet++

采用改进后的 KNN 算法来加强局部特征的提取,这在分割方面有了进一步的提升。所提算法的可视化结果如图 6 所示。从图 6 可以看到,改进后的 KNN 算法在墙壁和白板的边界处分割更加清晰,图画轮廓更加接近真实图像,在桌面和地板相接处特征点的识别准确率更高。




图 6 所提算法的可视化结果

Fig. 6 Visualization results of proposed algorithm

实验中,以 S3DIS 数据集中的 Area_1、Area_2、Area_3、Area_4 和 Area_6 为训练集,以 Area_5 为测试集。对于 S3DIS 数据集中的每一个场景,将输

mIoU 为平均类别交并比。

选取 S3DIS 数据集中的 Area6_conferenceRoom_1 作为可视化分割场景样本,将所提算法的可视化分割结果与 PointNet 和 PointNet++ 进行对比。图 5 为 Area6_conferenceRoom_1 的原始点云、真实分割结果、PointNet 分割结果和 PointNet++ 分割结果。

从图 5 可以看到,由于 PointNet 未能提取局部特征,所以在白板、图画和墙壁等特征较为相似的类别上容易出现边界模糊的现象,在桌面和地板相接处出现特征点识别错误的现象;PointNet++ 是在 PointNet 的基础上进行改进,能够清晰分割墙壁和白板边界,在桌面和地板相接处特征点的识别准确率也有所提高。

入的点云数据分为 9 个通道,具体可表示为 $\{X, Y, Z, R, G, B, X^0, Y^0, Z^0\}$ 。其中 X, Y 和 Z 为目标物体表面点云的空间坐标信息,它们是描述点云信息必不可少的特征; R, G 和 B 为目标物体影像在点云上的颜色纹理映射; X^0, Y^0 和 Z^0 为输入点云的归一化坐标。设置每个 Batch 有 4096 个点并设置训练次数为 128,将每个 Batch 的 4096 个点作为一个局部邻域样本数 q ,将日志文件中的分割结果通过 Python 软件中的 matplotlib 绘图工具来绘制 128 次训练的分割结果,结果如图 7 所示。从图 7 可以看到,当 k 为 1024 和 r 为 0.1 时,所提算法的分割结果较好。

将改进 KNN 算法的局部特征提取模块应用在 KNN-PointNet 分割网络中并在 S3DIS 数据集中的 Area_5 上进行测试,将实验结果与 G+RCU (Grid Recurrent Consolidation Units)^[15]、PointNet++、3P-RNN (Pointwise Pyramid Pooling Recurrent Neural Networks)^[16]、Engelmann^[17]、TangentConv (Tangent Convolutions)^[18] 和 ASIS (Associatively

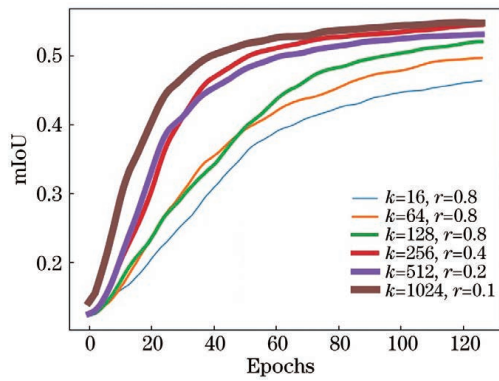
图 7 不同 k 值和 r 值下的分割结果

Fig. 7 Segmentation results under different k and r values

Segmenting Instances and Semantics)^[19] 等进行对比,对比结果如表 1 所示。评价指标为平均类别准确度 (mAcc)、mIoU 和总体准确度 (oAcc),其中 mAcc 为所有形状类分割的平均准确率,mIoU 为对每一类预测的结果和真实值的交集与并集的比值求和平均的结果,oAcc 为在测试集上分割正确的数量与总体数量之间的比值。

表 1 改进 KNN 算法与其他算法的性能对比

Table 1 Performance comparison between improved KNN algorithm and other algorithms unit: %

| Algorithm | mAcc | mIoU | oAcc |
|--------------------|------|------|------|
| PointNet | 57.8 | 41.1 | 82.3 |
| PointNet++ | - | 52.4 | - |
| G+RCU | - | 45.1 | - |
| 3P-RNN | - | 53.4 | 85.7 |
| Engelmann | - | 52.2 | 84.2 |
| TangentConv | - | 52.8 | 82.5 |
| ASIS | - | 51.1 | - |
| Proposed algorithm | 81.5 | 56.3 | 85.8 |

从表 1 可以看到,将改进 KNN 算法应用在分割网络中,通过加强局部信息的提取可以使分割结果在 mAcc、mIoU 和 oAcc 上都有不同程度的提升。采用所提网络对 S3DIS 数据集上的 13 种语义类别的交并比 (IoU) 进行测试,并将测试结果与 PointNet 和 PointNet++ 等当前较为流行的点云处理网络进行对比,结果如表 2 所示。

从表 2 可以看到,所提网络在整个 S3DIS 数据集上有 13 种类别的 IoU 超过 PointNet,12 种类别的 IoU 超过 PointNet++;除此之外,所提网络在天花板、地板、墙壁、横梁和椅子上的 mIoU 达到 70% 以上,这 5 个类别在整个数据集中占据的数量

表 2 不同网络在 S3DIS 数据集上 13 种语义类别的 IoU 结果

Table 2 IoU results of 13 semantic categories on S3DIS dataset for different networks unit: %

| Type | PointNet | PointNet++ | Proposed network |
|----------|----------|------------|------------------|
| Ceiling | 84.0 | 90.5 | 90.2 |
| Floor | 80.7 | 90.0 | 91.2 |
| Wall | 55.3 | 65.2 | 74.3 |
| Beam | 42.4 | 63.3 | 70.1 |
| Pillar | 26.3 | 40.2 | 45.2 |
| Window | 40.5 | 50.3 | 56.5 |
| Door | 38.6 | 42.3 | 43.2 |
| Chair | 55.0 | 68.4 | 70.5 |
| Table | 30.1 | 36.9 | 48.3 |
| Sofa | 9.6 | 32.2 | 26.4 |
| Bookcase | 27.2 | 36.5 | 46.3 |
| Board | 19.4 | 34.2 | 38.1 |
| Clutter | 25.2 | 31.2 | 31.6 |

比较大,因此在训练过程中学习到的特征比较强,得到的分割精度比较高。

所提网络 PointNet++ 在 PointNet 的基础上引入多尺度分组和多分辨率分组,将 PointNet 从局部区域中提取的全局特征作为局部特征,其中多尺度分组和多分辨率分组都采用 Ball Query 算法作为点集重叠划分的方法。Ball Query 算法中,球邻域局部特征点的选取依赖于索引下标的排序,提取前 v 个点作为局部特征提取点。当球邻域中的特征点不足 v 个时,将索引下标排序最大的点复制多次以凑足 v 个局部特征提取点;当球邻域中的点超过 v 个时,根据索引下标对其进行切片,选取前 v 个点作为局部特征提取点。Ball Query 算法对 v 个特征点的选取依赖于点云数据输入网络中的顺序,但这具有随机性。当球邻域中的特征点不足 v 个时,多次复制一个点来提取特征容易产生特征过拟合的现象,当特征点超过 v 个时,对其进行切片会损失部分点的特征。所提算法未设定局部特征提取点的固定数量,直接采用欧氏距离来判定特征点是否位于球形邻域,然后提取球形邻域中所有点的特征。相比于 Ball Query 算法,所提算法减少了特征损失和特征拟合现象的发生。

4 结 论

为了进一步加强点云数据中局部特征之间的关

联以及提高点云数据的分割精度,本文提出一个分割网络 KNN-PointNet,该网络引入了改进的 KNN 算法,其可以划分局部邻域并提取局部特征。对于大型且密度不均匀的数据集,采用改进的 KNN 算法来搜索局部邻域,在保证极少特征损失的情况下提高了网络模型的分割精度。本文将改进的 KNN 算法应用于室内点云模型的分割网络,加强了点与点之间的相互联系,从而获得了更好的分割结果。

参 考 文 献

- [1] Luo Y T, Qin H. 3D object detection method for autonomous vehicle based on sparse color point cloud [J]. *Automotive Engineering*, 2021, 43(4): 492-500.
罗玉涛, 秦瀚. 基于稀疏彩色点云的自动驾驶汽车 3D 目标检测方法[J]. *汽车工程*, 2021, 43(4): 492-500.
- [2] Lu R S, Shi Y Q, Hu H B. Review of three-dimensional imaging techniques for robotic vision[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 040001.
卢荣胜, 史艳琼, 胡海兵. 机器人视觉三维成像技术综述[J]. *激光与光电子学进展*, 2020, 57(4): 040001.
- [3] Zhang W, Zhao L. Vectorization of building contour information with laser scanning intensity and remote sensing information [J]. *Laser Journal*, 2020, 41(11): 100-104.
张维, 赵亮. 激光技术和遥感信息相融合的建筑轮廓识别研究[J]. *激光杂志*, 2020, 41(11): 100-104.
- [4] Liu B C, Sun C, Hou G J, et al. Clinical application of 3D printing technology: bone defect reconstruction of limbs based on "precision orthopedics" [J]. *Chinese Journal of Minimally Invasive Surgery*, 2021, 21(4): 303-308.
刘冰川, 孙川, 侯国进, 等. 3D 打印技术的临床应用: 基于“精准骨科”的四肢骨缺损重建[J]. *中国微创外科杂志*, 2021, 21(4): 303-308.
- [5] Zhao M N, Hua X H, Feng S Q, et al. Information extraction of buildings, doors, and windows based on point cloud slices [J]. *Chinese Journal of Lasers*, 2020, 47(6): 0604002.
赵梦娜, 花向红, 冯绍权, 等. 基于点云切片的建筑物门窗信息提取[J]. *中国激光*, 2020, 47(6): 0604002.
- [6] Zhang F F, Chen L, Yang S Y, et al. Robot-assisted three-dimensional positioning and navigation in spinal surgery[J]. *Journal of Harbin Engineering University*, 2020, 41(12): 1735-1741.
张峰峰, 陈龙, 杨诗怡, 等. 机器人辅助脊柱手术三维定位导航[J]. *哈尔滨工程大学学报*, 2020, 41(12): 1735-1741.
- [7] Gao J Y, Xu H L, Shao K L, et al. An adaptive edge detection method based on local edge feature descriptor[J]. *Chinese Journal of Lasers*, 2020, 47(6): 0604003.
高佳月, 许宏丽, 邵凯亮, 等. 基于局部边缘特征描述子的自适应边缘检测算法[J]. *中国激光*, 2020, 47(6): 0604003.
- [8] Zeng Y, Liu C L, Tan T N. Retrospect and outlook of brain-inspired intelligence research [J]. *Chinese Journal of Computers*, 2016, 39(1): 212-222.
曾毅, 刘成林, 谭铁牛. 类脑智能研究的回顾与展望[J]. *计算机学报*, 2016, 39(1): 212-222.
- [9] Du W, Li Q. Simulation of non calibration 3D reconstruction algorithm for urban virtual geographic scene[J]. *Computer Simulation*, 2021, 38(3): 327-330, 424.
杜炜, 李倩. 城市虚拟地理场景非定标三维重建算法仿真[J]. *计算机仿真*, 2021, 38(3): 327-330, 424.
- [10] 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.
- [11] Charles R Q, Li Y, Hao S, et al. Pointnet++: deep hierarchical feature learning on point sets in a metric space [C]//Advances in Neural Information Processing Systems 30: Annual Conference on Neural Information Processing Systems 2017, December 4-9, 2017, Long Beach, CA, USA. [S. l.: s. n.], 2007: 5099-5108.
- [12] Li Y Y, Bu R, Sun M C, et al. PointCNN: convolution on X-transformed points[EB/OL]. (2018-01-23)[2021-05-20]. <https://arxiv.org/abs/1801.07791v5>.
- [13] Jiang L, Zhao H S, Shi S S, et al. PointGroup: dual-set point grouping for 3D instance segmentation[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 4866-4875.
- [14] Wang Y Q, Xu C F, Yu G, et al. Visible k nearest neighbor queries over uncertain data [J]. *Chinese Journal of Computers*, 2010, 33(10): 1943-1952.
王艳秋, 徐传飞, 于戈, 等. 一种面向不确定对象的可见 k 近邻查询算法[J]. *计算机学报*, 2010, 33(10): 1943-1952.
- [15] Engelmann F, Kontogianni T, Hermans A, et al.

- Exploring spatial context for 3D semantic segmentation of point clouds[C]//2017 IEEE International Conference on Computer Vision Workshops (ICCVW), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 716-724.
- [16] Ye X Q, Li J M, Huang H X, et al. 3D recurrent neural networks with context fusion for point cloud semantic segmentation[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 415-430.
- [17] Engelmann F, Kontogianni T, Schult J, et al. Know what your neighbors do: 3D semantic segmentation of point clouds[M]//Computer vision-ECCV 2018 workshops. Lecture notes in computer science. Cham: Springer, 2019, 11131: 395-409.
- [18] Tatarchenko M, Park J, Koltun V, et al. Tangent convolutions for dense prediction in 3D [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: 3887-3896.
- [19] Wang X L, Liu S, Shen X Y, et al. Associatively segmenting instances and semantics in point clouds [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 4091-4100.