

# 基于空间图卷积的三维点云语义分割

张坤<sup>1</sup>, 朱亚薇<sup>1</sup>, 王晓红<sup>1</sup>, 张丽婷<sup>1</sup>, 钟若飞<sup>2\*</sup>

<sup>1</sup>河北科技大学信息科学与工程学院, 河北 石家庄 050018;

<sup>2</sup>首都师范大学资源环境与旅游学院, 北京 100048

**摘要** 随着科技智能化建设需求的提高,语义分割技术受到图形、图像领域内学者的广泛关注,其为目标跟踪、视觉控制等技术提供有效的决策支持。然而三维点云语义分割模型的运行效率和分割准确率是限制其发展的瓶颈所在。基于此,提出一种基于空间图卷积的三维点云语义分割网络(PCGCN)。PCGCN采用边缘图卷积网络提取局部特征,并使用残差网增强特征的传递,对不同尺度的局部特征进行融合并参与三维点云语义分割。PCGCN解决了在深度学习过程中因局部特征丢失产生的语义分割效果不佳的问题,同时,点云深度学习网络中,残差网的引入提高语义分割的准确度。在ShapeNet和S3DIS数据集上进行实验,实验结果表明,PCGCN在ShapeNet数据集的准确率达到85.1%,在S3DIS数据集的准确率达到81.3%。

**关键词** 遥感; 三维图像处理; 点云; 语义分割; 图卷积网络

中图分类号 TN958.98/TN249

文献标志码 A

DOI: 10.3788/LOP212825

## Three-Dimensional Point Cloud Semantic Segmentation Network Based on Spatial Graph Convolution Network

Zhang Kun<sup>1</sup>, Zhu Yawei<sup>1</sup>, Wang Xiaohong<sup>1</sup>, Zhang Liting<sup>1</sup>, Zhong Ruofei<sup>2\*</sup>

<sup>1</sup>College of Information Science and Engineering, Hebei University of Science and Technology, Hebei 050018, Shijiazhuang, China;

<sup>2</sup>College of Resources Environment and Tourism, Capital Normal University, Beijing 100048, China

**Abstract** With the increasing demand for intelligent construction in science and technology, semantic segmentation technology has attracted extensive attention from scholars in the field of graphics and images. This technology provides effective decision support for target tracking, visual control, and other technologies. However, the operation efficiency and segmentation accuracy of the three-dimensional (3D) point cloud semantic segmentation model are bottlenecks to its development. A semantic segmentation network model of the 3D point cloud, called point cloud+graph convolution network (PCGCN) is proposed. PCGCN uses the EdgeConv network to extract local features and ResNet to enhance the transmission of features, fuse the local features of different scales, and participate in semantic segmentation of the 3D point cloud. In the process of deep learning, PCGCN solves the problem of the lack of local features and improves the segmentation effect. Furthermore, in the point cloud deep learning network, the introduction of ResNet improves the accuracy of semantic segmentation. Experiments are carried out using ShapeNet and S3DIS datasets. The experimental results show that the PCGCN accuracies are 85.1% on the ShapeNet dataset and 81.3% on the S3DIS dataset.

**Key words** remote sensing; three-dimensional image processing; point cloud; semantic segmentation; graph convolution network

## 1 引言

随着激光技术<sup>[1-2]</sup>的不断发展,三维点云数据的获取越来越便捷<sup>[3]</sup>。三维点云语义分割技术在自动驾

驶、文物保护、机器人学与环境感知等领域中有着重要的应用<sup>[4]</sup>,其发展愈发迫切。然而,三维点云数据的无序性和旋转性使语义分割的效果很难满足智能化应用需求。三维点云数据量大,在计算过程中占用大量的

收稿日期: 2021-10-28; 修回日期: 2021-11-24; 录用日期: 2021-11-29; 网络首发日期: 2021-12-10

基金项目: 国家自然科学基金(42071444)、河北省高等学校科学技术研究项目(ZD2020176)

通信作者: \*zrfsss@163.com

计算资源,使点云语义分割技术的推广受限。

传统的点云语义分割算法基于点云区域分割实现,而传统的区域分割技术应用于语义分割时,存在分割对象特征描述困难、算法适用性差的问题。2017年,Charles等<sup>[5]</sup>首次提出面向三维点云的深度学习网络PointNet,并将其应用于点云语义分割。随后,该团队又对PointNet进行改进,提出PointNet++<sup>[6]</sup>,提高算法的分割精度。PointNet与PointNet++的出现为对象分类、语义分割、场景理解的应用提供一个统一的体系结构,引起学者对点云深度学习网络的关注。之后,出现大量点云语义分割、分类网络<sup>[7-9]</sup>。然而,点云深度学习网络存在数据量大、无拓扑结构、上下文信息丢失等问题。

图卷积网络(GCN)的出现给图结构数据处理提供一种新的方法,与卷积神经网络(CNN)类似,GCN也通过卷积的方式提取特征,不同的是GCN是处理不规则数据的特征提取器<sup>[10]</sup>。利用图卷积进行点云数据语义分割可以使数据的拓扑结构参与到特征计算过程中,融合数据的局部和全局特征,提高语义分割的精度。目前,有关图卷积语义分割方法可以大致分为谱方法和空间方法。

谱方法是指在谱域层面进行研究的方法,即在谱空间输入信号上使用卷积核并实现图卷积。2017年,Kip等<sup>[11]</sup>最先采用GCN对谱方法中的卷积核进行参数化,将其变成可训练的数据,大大降低时空复杂度的同时也可以更好地反应局部结构,但是这个网络只能在一张已经学习过的图上进行操作,扩展性差。针对这个问题,Li等<sup>[12]</sup>在2018年提出自适应图卷积网络(AGCN),应用SGC-LL(谱图卷积器)对不同大小的图进行卷积,利用距离度量参数化拉普拉斯算法,但计算量大,为节省资源仍需降低复杂度<sup>[13]</sup>。2020年,侯向丹等<sup>[14]</sup>提出的GraphPNet使用谱法构建图卷积层,将GCN用于PointNet中来处理点云数据,用图卷积模块来学习局部特征来弥补PointNet忽略局部特征的缺陷。但谱方法需要大量的图傅里叶变换,计算复杂度高。

空间方法是指在空间层面研究的方法,与谱方法不同,空间方法直接从邻域节点等方向去研究整个网络。为了降低时间和空间复杂度,2019年,Chiang等<sup>[15]</sup>提出的Cluster-GCN将图随机分为较多个簇,随机合并为小批量数据来避免重复邻接点聚合信息造成的邻居指数增长问题。对于采样的改进,2019年,Wang等<sup>[16]</sup>提出的图注意力卷积网络(GAC)将注意力机制应用到采样上,使卷积核可以动态调整成适应目标结构的形状。因为GCN大多遵循邻域聚合过程,为了适应局部邻域属性和任务,2018年,Xu等<sup>[17]</sup>提出的跳跃知识(JK)网络可以灵活地利用节点不同邻域范围实现更好的结构感知表示。将JK框架与GCN、GAC等模型相结合,可以提高这些模型的性能。为了更好

地提取特征,2021年,Wang等<sup>[18]</sup>提出的Reeb图卷积将点云转化为Reeb图引导池和K近邻图,实现全局和本地上下文的融合。很多研究者从多尺度的方向进行研究,2019年,Xiu等<sup>[19]</sup>提出的dynamic-scale GCN通过聚合不同尺度的K近邻图,多尺度采样得到跨越多尺度图形特征,从而增强类内和类间的局部结构。2019年,Wang等<sup>[20]</sup>提出依赖于多尺度局部特征的dynamic graph CNN,其中的边缘图卷积(EdgeConv)在保持排列不变性的同时可更好地捕捉点云的局部几何特征。但是由于GCN随着层数的增加节点等信息呈指数增长,对计算机设备存储和计算性能的要求依然是很高的<sup>[21]</sup>。

因此,本文结合点云数据分簇的思想,生成多个数据局部图,提出一种基于空间图卷积的三维点云语义分割网络(PCGCN)。首先,利用边缘图卷积,通过节点之间的边进行邻域特征计算,构造多局部邻域特征提取;其次,通过跳跃连接结合GCN的方法,利用残差网增强网络的特征信息传递;最后,针对边缘图卷积存在局部特征之间节点信息提取不充分问题,改进K最近邻(KNN)算法,并聚合全局信息与局部信息实现数据的语义分割,提高分割的准确度。该网络相对于点云深度学习网络(例如PointNet++),具有训练时间短、准确率高的优势。

## 2 PCGCN模型设计

采用激光雷达采集的三维点云数据一般由空间坐标  $x$ 、 $y$ 、 $z$  和颜色信息  $\alpha$  组成,记为  $\mathbf{p}_i = \{p_i | x_i, y_i, z_i, \alpha_i\}$ ,数据之间没有任何结构和拓扑信息。每行的空间坐标为一个点数据,将点数据以张量的形式输入网络中,如图1所示,获得每个数据的类别标签  $\text{tag}_i$ ,最终的语义分割结果记为  $\{\mathbf{p}_i, \text{tag}_i\}$ 。




图1 PCGCN问题描述示意图

Fig. 1 PCGCN problem description diagram

PCGCN首先针对杂乱无序的数据  $\mathbf{P} = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n\}$ ,建立统一、规则化的空间表示形式  $\mathbf{p}_i', \mathbf{p}_i' = f_{sp}(\mathbf{p}_i)$ ,  $f_{sp}$  为规范化的过程。其次,随机选取  $n$  个数据作为中心点,构建其邻近区域局部网络结构图  $\mathbf{g}_i$ ,  $\mathbf{g}_i$  由顶点集  $V_i$  和弧集  $E_i$  组成,  $\mathbf{g}_i = (V_i, E_i)$ ,通过PCGCN提取  $\mathbf{g}_i$  的局部特征向量,对局部特征向量进行特征融合并取其最大值后得到全局网络结构图  $\mathbf{G}$ ,

$G = \{g_i | g_i = (V_i, E_i), 0 < i < n\}$ 。最后融合多局部特征及全局特征实现点云语义分割。

PCGCN 的整体网络结构如图 2 所示,由空间变换

子网络、边缘图卷积网络和残差子网络组成。图 2 中 I 框为空间变换网络,II 框为边缘图卷积网络,III 框为残差网,layer 2、layer 3 内部结构与 layer 1 相同。

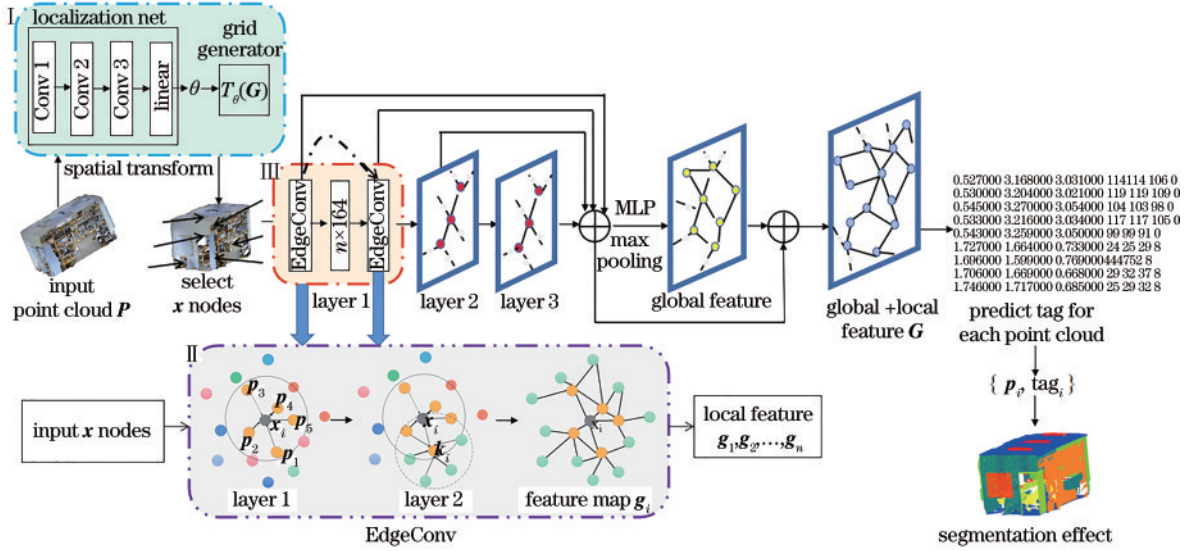


图 2 PCGCN 整体结构图

Fig. 2 Overall structure diagram of PCGCN

### 2.1 空间变换网络

空间变换网络由两部分组成,一部分是回归网络(localization net),另一部分是矩阵运算(grid generator),当采集设备所处的采集条件受限时,空间变换网络可以有效地提高语义分割的准确性。回归网络将三维点云数据传入网络,经过三层卷积操作后,通过全连接层回归得到空间变换系数  $\theta$ :

$$\theta \in \mathbf{R}^{3 \times 3}. \quad (1)$$

矩阵运算根据分割任务自适应地将数据进行空间变换和对齐。根据网络的训练参数,对整个点云数据  $p$  进行仿射变换:

$$p_i' = m_1 p_i + m_2, \quad (2)$$

式中: $p_i$  为三维点云数据的三维向量表示; $p_i'$  为仿射变换后的三维向量; $m_1$  表示缩放和旋转矩阵; $m_2$  表示平移矩阵。

### 2.2 边缘图卷积

对于邻域节点聚合方式,空间方法避免拉普拉斯矩阵的大量运算,转化时先取一个点序列,再对每一个

点进行近邻点提取,从而获取全部特征。设  $G=(V, E)$  是一个简单图,对于节点  $v \in V, x_v$  是它的节点特征。设  $\tilde{G}$  是每一个节点加上一个自循环得到的图。 $h_v^L$  是模型第  $L$  层学习到的节点  $v$  的隐藏特征,为了简单起见,PCGCN 认为跨层是相同的。 $N(v) = \{u \in V | (v, u) \in E\}$  代表节点  $v$  的邻域集, $\tilde{N}$  代表带自循环的邻域节点集, $u$  代表节点  $v$  的邻域节点。

计算每个输入节点的局部特征有向图  $G=(V, E)$ ,例如构造的  $G$  是输入节点序列的某个节点的 KNN 邻域图,该图每个节点也指向自身(即自循环)。输入序列中节点  $x_i$  的邻域节点聚合公式为

$$x_i' = \sum_{j:(i,j) \in E} h_{\theta}(x_i, x_j), \quad (3)$$

式中: $(x_i, x_j)$  是节点  $x_i$  与  $x_j$  间的边特征; $h_{\theta}$  是有本层的可学习参数的非线性函数; $x_i$  是每个顶点的边特征的集合。

图 3 为点云数据的边缘图卷积。这里假设图卷积为两层,随机选取的输入数据中,中心点  $x_i$  为其中一




图 3 EdgeConv 子网络。(a)第 2 层邻域聚合;(b)第 1 层邻域聚合;(c)局部特征图

Fig. 3 EdgeConv subnet. (a) 2nd layer neighborhood aggregation; (b) 1st layer neighborhood aggregation; (c) local features graph

点,图 3(a)对中心点进行 KNN 节点选取,圆圈代表 KNN 选取范围,图 3(b)代表中心点的上一层  $k_i$  节点的 KNN 选取范围,节点  $k_i$  先聚合邻域节点信息,  $x_i$  再进行特征聚合,最终所有信息都会聚合到中心点  $x_i$  上,最终形成图 3(c),  $x_i$  得到图中所有节点的信息从而实现边和节点信息的提取,形成一个局部特征图,网络通过多层边缘图卷积扩大感受野。在不断经过边缘图卷积时会给每个节点一个权重,权重是随着训练的不断进行更新的:

$$V_{\text{weight}} = 1/(d + c), \quad (4)$$

式中:  $V_{\text{weight}}$  是每个邻接节点的权重;  $d$  是邻接节点到中心点的距离;  $c$  是常量。

### 2.3 PCGCN 残差网

受跳跃连接网络的启发,加入残差网(ResNet)使其与图卷积网络相结合提取特征,增强网络的特征传递。图 4 是在边缘图卷积过程中引入残差网的示意图,将上一次边缘图卷积的结果加入下一次边缘图卷积的输入上,较好地利用邻域节点实现图结构感知,从而提高语义分割的效果。在网络的结尾连接一个池化层来防止过拟合,对输入输出的空间变换更具有鲁棒性,加强特征映射与类别的一致性。残差网保留深层




图 4 PCGCN 残差网络图  
Fig. 4 PCGCN residual network diagram

网络的深度,增添浅层网络的优势,增强局部特征提取,提高模型鲁棒性,解决深层网络退化的问题,从而提高模型的准确率。

PCGCN 残差网是由一系列残差块组成的:

$$h_{i+1} = h_i + \mathfrak{S}(h_i, W_i), \quad (5)$$

式中:  $h_i$  为第  $i$  层的特征;  $h_{i+1}$  为第  $i+1$  层的特征;  $W_i$  为第  $i$  层的卷积操作;  $\mathfrak{S}$  为残差函数。

对于任意  $m$  层模型中的  $n$  个输入节点,拥有  $k$  个最近邻节点,第  $l$  层 ( $0 < l < m$ ) 同时为每个输入序列内的节点  $v$  更新。首先聚合邻域,然后将得到的邻域表示与上一次迭代得到的节点表示相结合。第  $l$  层学到的节点  $v$  的隐藏特征为

$$h_{N(v)}^l = \sigma \{ W_l \cdot \text{AggNode} \{ h_u^{l-1}, \forall u \in \tilde{N}(v) \} \}, \quad (6)$$

$$h_v^l = \text{COMBINE}(h_u^{l-1}, h_{N(v)}^l), \quad (7)$$

式中: AggNode 是聚合函数; COMBINE 是连接函数;  $W_l$  是第  $l$  层上的所有节点共享的可训练权重矩阵;  $\sigma$  是非线性激活函数。

通过边缘图卷积子网得到点云数据的局部特征  $\{g_1, g_2, \dots, g_n\}$ , 将全部局部特征通过 PCGCN 特征聚合层聚合在一起,获取数据全局特征。全局特征的引入将有效提高语义分割准确度。每个中心点会聚合离中心点最近的节点信息,从而形成一个局部邻域特征提取器。为了提高网络的泛化能力,每次训练会更新最近邻数据。

### 2.4 PCGCN 模型简化

在 PCGCN 训练过程中,每个节点会聚合所有的邻居节点信息,随着聚合层数的增加,节点信息会呈指数增长。PCGCN 的特征学习部分会占用大量的内存空间,在时间消耗上也呈指数增长。因此,关于 PCGCN 的简化在提高模型训练效率方面是至关重要的。

图 5 中  $A$ 、 $B$ 、 $C$  为某一次训练选出的节点, hidden layer 为隐藏层, ReLU 为激活函数,对每个节点的邻居进行卷积操作聚合邻域信息,每层隐藏层信息不断叠




图 5 聚合不同层的特征  
Fig. 5 Aggregating characteristics of different layers

加,从而实现特征聚合。

PCGCN的简化模型将会减少不必要的边和节点,应用边缘卷积,每次随即输入一定的点,图5为输入节点A、B、C的邻域聚合网络图。但是它们在图中的位置是不固定的,每一层都会动态更新这些节点的邻域图,以达到更好的训练效果。

PCGCN简化模型删减中心点KNN中距离较近的一些点,在KNN聚合时,每一层都会聚合当前层所有节点的邻域,在以A为中心点的三维空间内,距离中心点最近的一些点的邻域重合较多,所以本研究随机删减 $m$ 个距离较近的邻节点( $m < k$ ),输入更少的节点以达到提升训练速度和节省内存的目的。图6(a),以 $X_1$ 为中心点的局部邻域中, $X_1$ 与 $X_2$ 、 $X_3$ 都有相同最近邻,在多次取最近邻之后, $X_6$ 的邻域最近邻只有一个不与其他节点的邻域节点重合,大量的重复导致大量的冗余信息,影响程序的运行速度。




图6 KNN示意图。(a)原始KNN;(b)随机删减节点;(c)原始采样;(d)改进后采样

Fig. 6 KNN diagrams. (a) Original KNN; (b) randomly delete nodes; (c) original sampling result; (d) sampling result after improvement

在训练模型时,为了减少训练时间控制KNN的邻域节点数,那么在多个局部邻域中间会有一些缝隙的节点特征提取不到,如图6(c)所示。本研究提出两种简化策略:1)随机删除KNN最近邻节点,确定删除个数 $m$ ,在增大KNN半径的同时减少KNN最近邻的节点数,每次选择删除点所消耗的时间大于或略小于不删减KNN点时的计算时间,这种方法没有达到减少训练时间的目的;2)在增大KNN半径的同时减少最初的采样点数,这样在损失一定准确率的同时又节省大量的时间,实验结果表明其可以有效缩短训练时间。

随机选择KNN最近邻中的少量的点删除不计入特征运算,减少重复节点,使得中心点向较远处找最近邻节点。图6(b)为删除KNN最近邻中 $X_7$ 节点

的情况,可以减少冗余信息。图6(d)中,KNN选取局部邻域的半径变大,减少了各个局部邻域的缝隙。

## 3 实验

### 3.1 实验数据与环境

所用数据集为ShapeNet和S3DIS。ShapeNet数据集包含16个类别的16881个对象,共有50个零件标签,每个类别包含2~6个标签,例如飞机有机翼、机身、尾翼等4个标签,其中训练集12137个,验证集1870个。S3DIS数据集包含6个室内区域的三维扫描点云,共271个点云房间,每个点都属于13个语义类别中的一个,例如木板、书架、椅子、天花板等杂物,其中训练集有19898个点云文件,测试集有每个区域的12个房间,共48个房间。

硬件环境如下: Intel CORE i7, 16 GB, NVIDIA GeForce GTX TITAN X;使用CUDA 10.1和CuDnn 10.1的GPU加速环境。软件环境如下: Windows 10操作系统;环境是Python 3.7+Pytorch 1.7。

### 3.2 实验参数

为了选择合适的训练参数,该实验分别对epoch和batch\_size进行相应的参数调试,在ShapeNet数据集上的分割实验最终设置epoch为300,batch\_size为16,参数敏感性实验设置epoch为50。在S3DIS数据集上的实验最终选择epoch为200,batch\_size为8。本研究在相同的实验环境下进行对比实验,并不代表是最优的效果。

在S3DIS数据集下对KNN的参数进行实验分析,在不同的简化参数下进行20轮次对比实验,结果如表1所示。其中,第3行是策略1的实验结果,第4行是策略2的实验结果, $k-m$ 代表删减后的最近邻点的个数, $m$ 代表删减点的个数,num\_points代表采样点数,every epoch为每一轮次的运行时间,mean IoU为

表1 参数对比实验

Table 1 Parameter comparison experiment

num_points	$k-m$	$m$	Every epoch /s	Mean IoU
2048	20	0	1442	41.79
2048	15	5	1679	42.34
2048	15	3	1757	42.87
2048	12	3	1370	42.23
1024	20	7	1234	42.13
1024	20	5	1200	42.03
1024	20	3	1123	41.78
1024	25	7	1547	<b>43.44</b>
1024	15	3	900	41.58
<b>1024</b>	<b>12</b>	<b>3</b>	<b>762</b>	<b>41.35</b>
1024	9	3	<b>670</b>	38.24

20轮次内训练最优准确率。这里选择20轮次是在实验环境和对比效果上综合考虑决定的。

实验结果表明:当 num\_points 为 1024,  $k$  为 25,  $m$  为 7 时,准确率达到最高,但是耗费的时间很长;当 num\_points 为 1024,  $k$  为 9,  $m$  为 3 时,耗费时间最短,但是准确率很低。因此最终取 num\_points 为 1024,  $k$  为 12,  $m$  为 3,此参数下,训练时间大大减少,准确率损失也较少。

### 3.3 S3DIS 数据集实验分析

表 2 为 S3DIS 数据集上的 3D 语义分割结果,分别与经典的点云 CNN 深度学习和图卷积网络进行对比。表 2 数据表明,除了更复杂的网络 DeepGCN, PCGCN 的准确度更高。

表 2 S3DIS 的语义分割结果

Table 2 Semantic segmentation results of S3DIS

Model	Mean IoU	Overall accuracy
PointNet	40.4	76.0
PointNet++	46.2	79.6
MS+CU	47.8	79.2
DeepGCN	52.2	<b>83.5</b>
GAC	47.8	79.8
DGCNN	49.1	80.8
Proposed model	<b>49.5</b>	<b>81.3</b>
Proposed simplified model	<b>49.3</b>	<b>81.0</b>

图 7 为不同模型在 S3DIS 数据集上的训练结果, PCGCN 较 DGCNN, 性能有一定的提升, 在 61 轮次时, 训练速度加快, 并且更快到达较好的训练水平。

表 3 为不同模型在 S3DIS 数据集上的训练时间。




图 7 S3DIS 数据集的训练结果对比。(a)平均准确率;(b)准确率;(c)交并比

Fig. 7 Comparison of training results of S3DIS. (a) Train average accuracy; (b) train accuracy; (c) train IoU

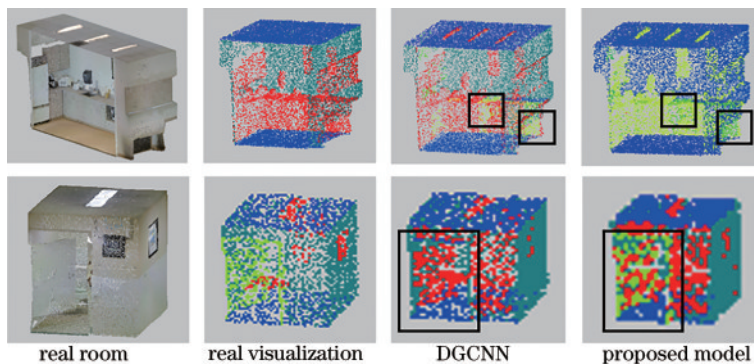


图 8 S3DIS 分割结果可视化

Fig. 8 Visualization of segmentation results in S3DIS

表 3 S3DIS 的语义分割时间

Table 3 Semantic Segmentation time of S3DIS

Model	Every epoch /s
PointNet	3840
PointNet++	25500
DeepGCN	5400
GAC	2939
DGCNN	812
Proposed model	1242
Proposed simplified model	<b>762</b>

从表 3 可以看出:相比 PointNet 与 PointNet++, PCGCN 的训练时间有着较大的优势;与较流行的 GAC 相比, PCGCN 的训练时间也有着一定的优势。简化后的模型在准确率上略低,但在运行时间上有一定的优势,运行时间已达到与当前众多成熟模型分割时间相近或更优的水平。

图 8 为所提模型的可视化结果,由于室内数据集是比较复杂的,对其进行语义分割还有待更深层次的研究。图 8 第 1 列为一些房间的原型,文件中包含模型的坐标信息和 RGB 参数信息,第 2 列的图片是点云文件和自带的正确的 label 标签的可视化生成,第 3 列是 DGCNN 的可视化结果,第 4 列是所提模型的分割结果。从图 8 可以看出,所提 PCGCN 的分割较为准确,与 DGCNN 的结果相比有一定的提升。

### 3.4 ShapeNet数据集实验分析

在ShapeNet数据集上对PCGCN模型性能进行评估。首先,针对简化后模型对于batch\_size的敏感性,在ShapeNet数据集上进行实验,分别选取batch\_size为2、8、16、32来进行对比实验,以50轮次内最佳测试准确率作为最终的结果,如表4所示,其中mAcc为平均准确率, mIoU为平均交并比。随着batch\_size的增大,训练与测试准确率有着一定的提升,模型能更快训练出较好的效果,batch\_size的大小对模型训练有着一定的影响,模型的稳定性有待提升。

表5是在ShapeNet数据集上的测试对比结果,PCGCN模型的准确率达到85.1%,达到当前众多

表4 参数敏感性实验

Table 4 Parameter sensitivity experiment unit: %

batch_size	train mAcc	test mAcc	train mIoU	test mIoU
2	91.6	89.2	79.2	77.3
8	92.8	91.0	82.2	81.4
16	94.1	93.0	83.5	82.8
32	94.8	92.8	84.9	82.9

模型的分割水平。简化模型的准确率达到84.7%,其牺牲一部分准确率,但节省训练时间和计算机资源,简化模型的训练每轮次用时为100 s,而DGCNN的训练每轮次需要用时330 s。

表5 ShapeNet数据集分割实验

Table 5 Semantic segmentation results of ShapeNet

Model	Kd-Net	SK-Net	SRI-Net	PointNet	PointNet++	DGCNN	Proposed model	Proposed simplified model
mIoU / %	82.3	85.0	73.5	83.7	85.1	85.0	85.1	84.7

PCGCN在ShapeNet数据集上进行训练,图9为训练时测试准确率的总体趋势。图9曲线表明,所提模型在50轮次得到较好的准确率,增长趋势较为平稳。

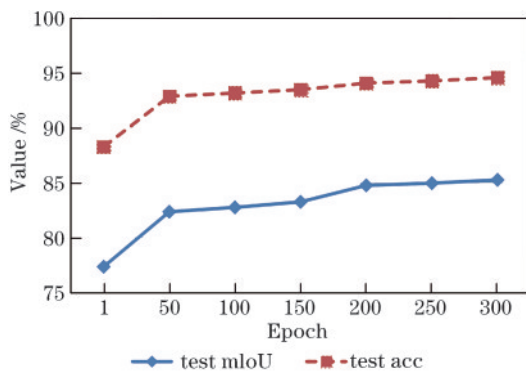


图9 ShapeNet测试集准确率

Fig. 9 Accuracy of ShapeNet test set

选择测试数据,将数据输入模型分别进行测试得到测试结果,通过可视化工具将结果进行可视化并观察分割效果,图10为简化模型的部分可视化结果,与DGCNN相比,在飞机的尾部、包的提手边缘处和汽车的顶部简化模型分割更为清晰,与带有原标签数据的可视化结果更相似,表现了较好的分割效果。

### 3.5 模型鲁棒性分析

在ShapeNet数据集上对简化模型进行鲁棒性分析实验,分别在不同采样点上进行测试,观察分割效果,结果如图11所示。num\_points分别为256、512、1024、2048,图11结果表明,即使点数很少也可以分割出飞机的每一部分。可见所提模型鲁棒性较好,受采样点数影响较小。

将原数据的颜色和标签信息删去变为只含有坐标信息的数据,并加入高斯噪声,然后将数据加工成测试




图10 ShapeNet分割结果可视化

Fig. 10 Visualization of segmentation results in ShapeNet




图11 ShapeNet鲁棒性分析

Fig. 11 Robustness analysis on ShapeNet

集进行测试,结果如图12所示,其中第1列为原图,第2列为简化模型测试结果可视化,第3列为加入高斯噪声的数据可视化,第4列为简化模型在加有高斯噪声的数据上的测试结果可视化。

加入高斯噪声后,两个房间的总分割效果受影响较小,较难分割的门分割效果变差。可见高斯噪声对分割结果的影响较小,模型的抗噪性较好。

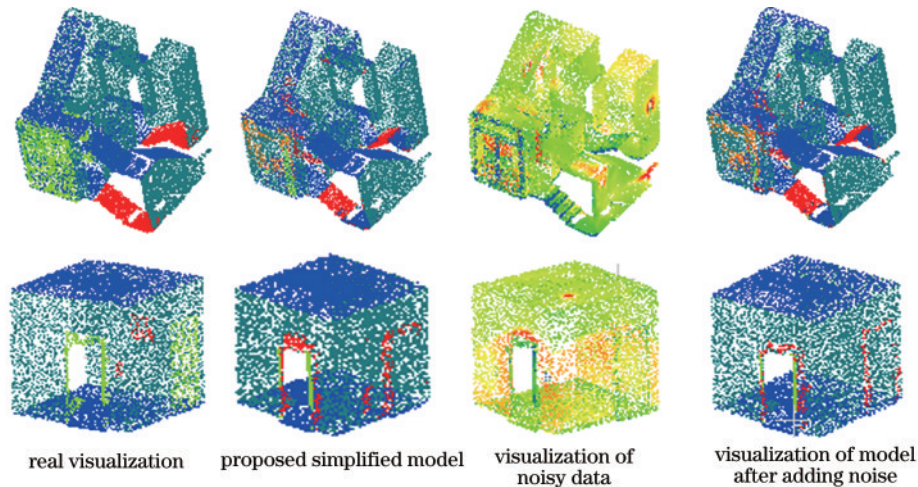


图 12 S3DIS 抗噪性分析

Fig. 12 Anti noise analysis on S3DIS

## 4 结 论

提出一种适用于三维点云分割任务的 PCGCN。首先采用改进 KNN, 将点云数据转换成图数据, 增强网络局部特征获取能力, 其次加入残差网增强特征的传递, 对点云数据进行局部划分后, 确定不同范围的局部特征区域, 并利用残差网得到的数据和 3 种不同深度的边卷积操作对局部特征进行提取和聚合, 然后将局部特征和全局特征拼接, 最后通过一个全局最大池化层提取全局语义信息用于数据语义分割。

将该模型在 S3DIS 和 ShapeNet 数据集上进行验证, 并与 DGCNN 进行对比。实验结果表明, 所提 PCGCN 在三维点云数据的分割准确度上达到良好的效果。在分割准确率方面, 所提模型已经达到与当前众多成熟模型分割性能一致的水平。简化 KNN, 且图卷积网络在点云语义分割中有着速度快、准确率高的优势, 图卷积网络可实现非结构性数据的处理, 其应用于目标跟踪、视觉控制、自动驾驶等领域有较好的前景。但图卷积网络存在计算量大、占用资源多的缺点, 今后将继续研究数据生成图的结构问题及图模型简化和优化的问题。

## 参 考 文 献

- [1] Yuan X C, Zayats A V. Laser: sixty years of advancement [J]. *Advanced Photonics*, 2020, 2(5): 050101.
- [2] Fu X Y, Chen Z D, Han D D, et al. Laser fabrication of graphene-based supercapacitors[J]. *Photonics Research*, 2020, 8(4): 577-588.
- [3] Qian Q S, Hu Y H, Zhao N X, et al. Object tracking method based on joint global and local feature descriptor of 3D LIDAR point cloud[J]. *Chinese Optics Letters*, 2020, 18(6): 061001.
- [4] Zhang J Z, Zhu C Y, Zheng L T, et al. Fusion-aware point convolution for online semantic 3D scene 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: 4533-4542.
- [5] 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, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 77-85.
- [6] Charles R Q, Li Y, Hao S, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [C]//Proceedings of NIPS 2017 Workshop on Machine Learning for the Developing World, December 3-9, 2017, Long beach, CA. Cambridge: NIPS, 2017.
- [7] 张爱武, 刘路路, 张希珍. 道路三维点云多特征卷积神经网络语义分割方法[J]. *中国激光*, 2020, 47(4): 0410001.  
Zhang A W, Liu L L, Zhang X Z. Multi-feature 3D road point cloud semantic segmentation method based on convolutional neural network[J]. *Chinese Journal of Lasers*, 2020, 47(4): 0410001.
- [8] 赵亮, 胡杰, 刘汉, 等. 基于语义分割的深度学习激光点云三维目标检测[J]. *中国激光*, 2021, 48(17): 1710004.  
Zhao L, Hu J, Liu H, et al. Deep learning based on semantic segmentation for three-dimensional object detection from point clouds[J]. *Chinese Journal of Lasers*, 2021, 48(17): 1710004.
- [9] 李琪琪, 花向红, 赵不钊, 等. 一种室内场景点云平面分割的新方法[J]. *中国激光*, 2021, 48(16): 1604002.  
Li Q Q, Hua X H, Zhao B F, et al. New method for plane segmentation of indoor scene point cloud[J]. *Chinese Journal of Lasers*, 2021, 48(16): 1604002.
- [10] Li G H, Mueller M, Qian G C, et al. DeepGCNs: making GCNs go as deep as CNNs[EB/OL]. (2019-10-15)[2021-02-05]. <https://arxiv.org/abs/1910.06849>.
- [11] Kip F T N, Welling M. Semi-supervised classification with graph convolutional networks[C]//International Conference on Learning Representations(ICLR 2017),



- April 24-26, 2017, Toulon, France. Cambridge: ICLR, 2017.
- [12] Li R, Sheng W, Zhu F, et al. Adaptive graph convolutional neural networks[C]//AAAI Conference on Artificial Intelligence, February 2-7, 2018, New Orleans, Louisiana. New York: AAAI Press, 2018.
- [13] Wu F, Zhang T, Souza A, et al. Simplifying graph convolutional networks[C]//International Conference on Machine Learning, June 9-15, 2019, Long Beach, CA, USA. Cambridge: ICML, 2019.
- [14] 侯向丹, 于习欣, 刘洪普. 基于图卷积网络的三维点云分类分割模型[J]. 激光与光电子学进展, 2020, 57(18): 181019.  
Hou X D, Yu X X, Liu H P. 3D point cloud classification and segmentation model based on graph convolutional network[J]. Laser & Optoelectronics Progress, 2020, 57(18): 181019.
- [15] Chiang W L, Liu X Q, Si S, et al. Cluster-GCN: an efficient algorithm for training deep and large graph convolutional networks[C]//KDD '19: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, October 21-25, 2019, Nice, France. New York: ACM Press, 2019: 257-266.
- [16] Wang L, Huang Y C, Hou Y L, et al. Graph attention convolution for point cloud semantic segmentation[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: 10288-10297.
- [17] Xu K, Li C T, Tian Y L, et al. Representation learning on graphs with jumping knowledge networks[EB/OL]. (2018-06-09)[2021-04-05]. <https://arxiv.org/abs/1806.03536>.
- [18] Wang W M, You Y, Liu W H, et al. Point cloud classification with deep normalized Reeb graph convolution [J]. Image and Vision Computing, 2021, 106: 104092.
- [19] Xiu H Y, Shinohara T, Matsuoka M. Dynamic-scale graph convolutional network for semantic segmentation of 3D point cloud[C]//2019 IEEE International Symposium on Multimedia, December 9-11, 2019, San Diego, CA, USA. New York: IEEE Press, 2019: 271-2717.
- [20] 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.
- [21] Xu Q G, Sun X D, Wu C Y, et al. Grid-GCN for fast and scalable point cloud learning[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 5660-5669.