

基于图卷积神经网络的点云语义分割综述

黄海新, 蔡明启, 王钰瑶

引用本文

黄海新, 蔡明启, 王钰瑶. [基于图卷积神经网络的点云语义分割综述](#)[J]. 计算机科学, 2024, 51(6A): 230400196-7.

HUANG Haixin, CAI Mingqi, WANG Yuyao. [Review of Point Cloud Semantic Segmentation Based on Graph Convolutional Neural Networks](#) [J]. Computer Science, 2024, 51(6A): 230400196-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向产线AI质检的少样本评测方法研究和验证](#)

Study and Verification on Few-shot Evaluation Methods for AI-based Quality Inspection in Production Lines

计算机科学, 2024, 51(6A): 230700086-8. <https://doi.org/10.11896/jsjcx.230700086>

[基于BERT和CNN的药物不良反应个例报道文献分类方法](#)

Literature Classification of Individual Reports of Adverse Drug Reactions Based on BERT and CNN

计算机科学, 2024, 51(6A): 230400049-6. <https://doi.org/10.11896/jsjcx.230400049>

[结合图卷积神经网络和集成方法的推荐系统恶意攻击检测](#)

Malicious Attack Detection in Recommendation Systems Combining Graph Convolutional Neural Networks and Ensemble Methods

计算机科学, 2024, 51(6A): 230700003-9. <https://doi.org/10.11896/jsjcx.230700003>

[DUWe:动态未知词嵌入方法在Web异常检测中的应用](#)

DUWe:Dynamic Unknown Word Embedding Approach for Web Anomaly Detection

计算机科学, 2024, 51(6A): 230300191-5. <https://doi.org/10.11896/jsjcx.230300191>

[一种基于谱图SIFT的同源频谱监测数据判定方法](#)

Method for Homologous Spectrum Monitoring Data Identification Based on Spectrum SIFT

计算机科学, 2024, 51(6A): 230300177-7. <https://doi.org/10.11896/jsjcx.230300177>

基于图卷积神经网络的点云语义分割综述

黄海新 蔡明启 王钰瑶

沈阳理工大学自动化与电气工程学院 沈阳 110159

摘要 随着点云在自动驾驶、地图测绘和矿山测量等领域的广泛应用,人们愈发关注这种蕴含丰富信息的数据表示形式。点云语义分割作为点云数据处理的重要手段,因具有极高的研究价值和应用前景而受到广泛关注。由于点云所具有的置换不变性和旋转不变性等特点,传统的卷积神经网络无法直接处理不规则的点云数据,而图卷积神经网络却可以使用图卷积算子直接提取点云特征,逐步成为当前点云分割领域的研究热点。虽已有综述性文章对点云分割方法做出总结,但这些文章对图卷积的介绍较为粗略。因而对近几年基于图卷积的点云分割方法进行了分析和归类,总结每类方法的研究思路和特点;然后,介绍了一些在点云语义分割领域中主流的点云数据集和评价指标,并对提及的分割方法的实验结果进行对比;最后,对各类方法的发展方向进行了展望。

关键词: 语义分割;点云;图卷积神经网络;深度学习;计算机视觉

中图分类号 TP391

Review of Point Cloud Semantic Segmentation Based on Graph Convolutional Neural Networks

HUANG Haixin, CAI Mingqi and WANG Yuyao

School of Automation and Electrical Engineering, Shenyang Ligong University, Shenyang 110159, China

Abstract As point clouds are widely utilized in various fields such as autonomous driving, map making, and mining measurement, there is a growing interest in this data representation that contains rich information. Point cloud semantic segmentation, as an important means of point cloud data processing, has attracted wide attention due to its high research value and application prospects. Due to the characteristics of permutation invariance and rotation invariance in point clouds, traditional convolutional neural networks cannot directly process irregular point cloud data, but graph convolutional neural networks can use graph convolution operators to directly extract point cloud features. Therefore, this paper provides a detailed review of recent point cloud segmentation methods based on graph convolution. The methods are further divided according to the type of graph convolution, and representative algorithms in each category are introduced and analyzed, summarizing the research ideas and advantages and disadvantages of each method. Then, some mainstream point cloud datasets and evaluation metrics in the field of point cloud semantic segmentation are introduced, and the experimental results of the mentioned segmentation methods are compared. Finally, the development direction of various methods is discussed.

Keywords Semantic segmentation, Point clouds, Graph convolution neural network, Deep learning, Computer vision

1 引言

近年来,随着深度学习的不断发展,点云被广泛应用于汽车自动驾驶、人工智能、生物遥感等领域。点云作为三维空间信息的主要描述方式,比二维数据包含更加丰富的几何、形状和比例信息。

针对点云数据的不规则性,处理方法分为间接分割方法和直接分割方法。其中,间接法采用将点云数据转换为体素化或多视图形式的方式,以易于处理的规则形式来提取特征。然而,这种方法无法避免信息丢失的问题。而直接法则直接对点云数据进行操作,保留原始点的内在信息,有效降低了信息损失。直接法包括基于点^[1-2]、基于循环神经网络^[3]、基于图卷积、基于无监督、基于优化 CNN 等方法。图卷积神经网络(Graph Convolution Neural Network, GCN)^[4]直接对点

进行处理,将每个点视为图的顶点,与邻域点生成图的有向边,在空间域或频谱域中学习点云特征,适合处理非欧几里得数据。本文总结了各种点云语义分割的图卷积方法,将其划分为频谱域图卷积、空间域图卷积、图注意力卷积、深度图卷积、扩展图卷积以及其他常见的方法。

本文旨在对近年来基于图卷积方法的点云分割技术进行总结,对新提出的分割方法进行归类与归纳;同时介绍常见的公开数据集和评估指标,探讨点云语义分割中存在的问题,并提出相应的建议。

2 基于图卷积神经网络的点云分割法

2.1 频谱域图卷积方法

基于频谱域的图卷积神经网络模型在频谱域中定义图卷积^[5],从而实现了对图信号的滤波。卷积层在该类网络中扮演

基金项目:国家自然科学基金(61672359)

This work was supported by the National Natural Science Foundation of China(61672359).

通信作者:黄海新(huanghaixin@sylu.edu.cn)

了滤波器的角色,通过对图卷积层的过滤,降低噪声对信号分类结果的影响。该方法的关键在于对图拉普拉斯矩阵进行特征分解,以描述图的连通性。

Wang 等^[6]在 PointNet++^[2]的基础上提出了 LSGCN (Local Spectral Graph Convolution Network),用递归聚类谱坐标的方式代替池化操作,在局部图上结合谱图卷积,聚合图节点处的特征,克服了前者忽略相邻点的相对布局及其特征的限制。这种新结构为无序点云特征提取任务提供了一种解决方案。




图1 RGCNN网络结构图

Fig. 1 Diagram of RGCNN network structure

Lu 等^[8]提出了一种新型的点云处理网络 PointNGCNN,其灵感源于二维图像分析中使用图卷积提取特征的方法。该网络使用 K 最近邻(KNN)方法在每个点的邻域内构建邻域图,该图反映了领域点之间的关系。为了提取更多的邻域特征,PointNGCNN 使用 Chebyshev 多项式作为邻域图滤波器,而不是传统的多层感知机(MLP)。Li 等^[9]提出了一种名为双滤波器图卷积网络(Double Filter Graph Convolutional Network,DFGCN)的点云分割方法,其中第一个滤波器被应用于原始点云,旨在消除噪声并优化图结构以减少计算量。第二个滤波器则使用切比雪夫多项式逼近卷积操作,采用低通滤波思想进行计算优化。该网络可以解决利用体素进行点云分割会导致信息丢失从而影响分割精度的问题,具有较强的鲁棒性和广泛性。需要注意的是,当图结构发生变化时,需要重新构建拉普拉斯矩阵。

2.2 空间域图卷积方法

基于空间域的图卷积方法通过在点云中构建图结构,直

固定的图拉普拉斯矩阵无法代表学习过程中动态图的结构。为了解决该问题,Te 等^[7]提出了一种正则化图卷积神经网络(RGCNN),如图 1 所示。该网络使用点云的基础几何信息(点的坐标和法线)作为特征,采用了基于切比雪夫多项式近似的 GCNN 框架,结合数据驱动和模型驱动的方法,设计了三层具有高阶切比雪夫多项式的 GCNN。在每一层,通过更新相应特征的拉普拉斯矩阵,并自适应地动态更新图结构,实现了计算复杂度明显降低,性能极具竞争力的效果。

接从节点之间提取丰富的特征信息,有效减少了空间信息损失。

DGCNN^[10]采用了基于图卷积网络的思想,构建了局部邻域图,并在相邻点之间的连接上应用了边缘卷积(EdgeConv)以提取局部几何特征。在每个特征层中,通过重新应用近邻算法来计算采样点的邻域并更新图模型,这样可以更好地让信息在相似的结构之间传播,从而加快局部语义信息的学习并有效地提高网络性能。

Zhang 等^[11]采用 DenseNet 的思想,在 DGCNN 网络的基础上,通过级联不同层次的特征,获得了更丰富的边缘向量,并将转换网络删除以缩小网络规模;不同于 PointNet^[1],为了捕获局部特征,使用 KNN 进行邻域搜索,并利用 MLP 对邻域内的点特征进行聚合提取,以此提出了链接动态图卷积网络(Linked Dynamic Graph CNN,LDGCNN),如图 2 所示。相比于 DGCNN 网络,LDGCNN 减小了模型尺寸,提高了网络的性能。

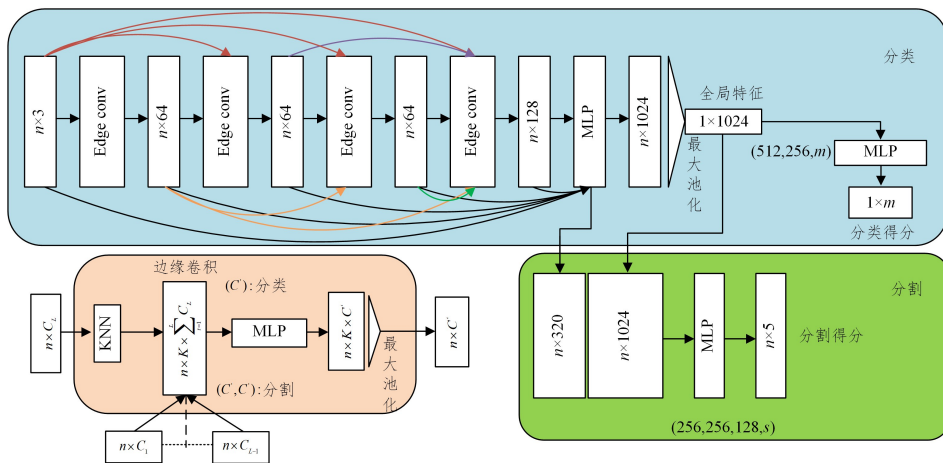


图2 LDGCNN网络结构图

Fig. 2 Diagram of LDGCNN network structure

Chen 等^[12]提出一种新的融合距离和方向的图卷积神经网络(DDGCN),该网络基于点云的相似度矩阵构造动态邻域图,使用多个多层感知器来提取局部特征,并提出一种新的结合中心损失的损失函数,使点云数据中的类内数据更紧凑,类间的间距大于类内间距。Wang 等^[13]为解决特征的各向同性,提出了亲和点图卷积网络(Affinity-Point GCN, AP-GCN)。该方法利用每对点之间的特征来定义点之间的亲和性,建立带有亲和信息的图,并在图的顶点和边之间进行边缘条件卷积,以获得更强的邻域信息。实验证明,AP-GCN 学习到了更合理的特征,显著提高了点云语义分割的性能。

2.3 图注意力卷积方法

Chen 等^[14]提出了 GAPNet(Graph Attention Based Point Neural Network),其中利用注意力感知空间变换网络保持点云在某些变换下不变;提出了自注意和相邻关注机制,允许 GAPLayer 层通过考虑自几何信息和与相邻点的局部相关性来计算关注系数,允许并行处理来自不同表示空间的特征,并在邻点上构建注意力池化层以进一步聚合特征提取能力;此外,他们在多图特征的相邻信道上定义了注意力池化层以提取局部特征,从而增强了网络的鲁棒性和性能。

Wang 等^[15]借鉴注意力机制的思想,提出了图注意力卷积(Graph Attention Convolution, GAC)方法,该方法在分配注意力权重时考虑了邻点和特征通道之间的关系。相比于 GAT, GAC 结合了邻点之间的局部空间关系,这在三维分析中具有重要意义。同时,注意力权重的分配不仅取决于邻点的空间位置,还取决于动态学习特征的生成。此外, GAC 基于点的空间邻域设计,保留了标准卷积的权重共享和局部性。GACNet 网络结构简单,能够捕获点云的结构化特征以进行细粒度分割,并避免特征污染,在点云目标的边缘分割任务中表现出良好的效果。

之前的方法通常使用最大池化策略来实现对称函数,但这种方法只能聚合最重要的特征,而丢弃大量包含丰富几何信息的特征。为解决这个问题, Jing 等^[16]提出了一种名为注意力图神经网络(Attention-based Graph Network, AGNet)的方法,如图 3 所示,并设计了一种基于注意力池化策略的特征提取模块(AGM)。在局部区域中, AGNet 使用该模块构建拓扑结构,提取不同距离的空间信息,并利用注意力池化操作聚合重要特征,从而增加接受野,丰富点云局部信息。因此,该模型可以聚合更多信息,更好地表示不同的点云特征。

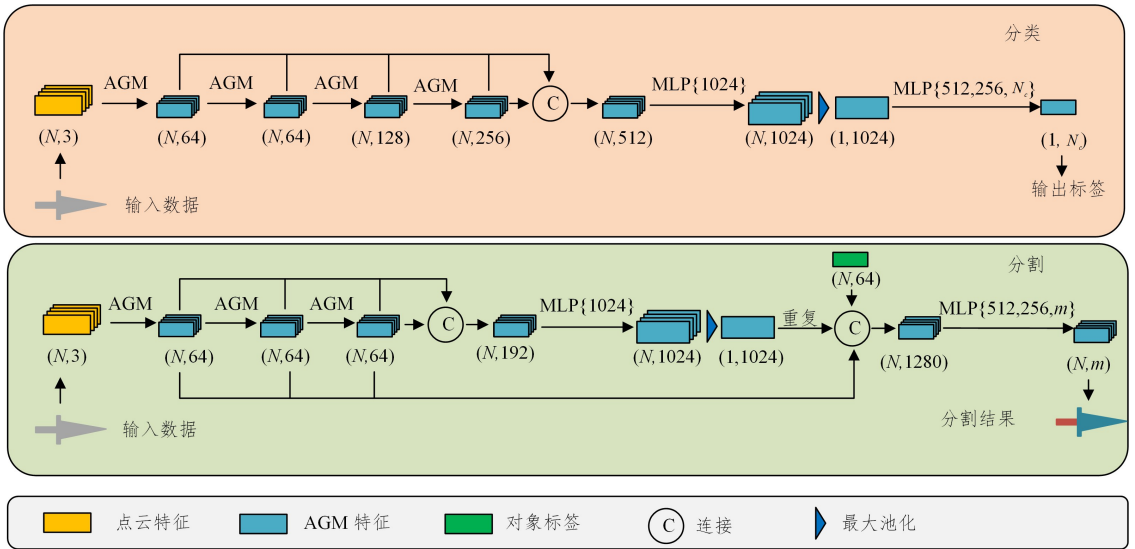


图 3 AGNet 网络结构图

Fig. 3 Diagram of AGNet network structure

Zhai 等^[17]提出了一种交互式注意力图卷积网络(Interactive Attention Graph Convolution Network, IAGC),专注于通过交互式注意机制捕获局部特征。该方法由区域简化双重注意力网络和全局图卷积网络组成。通过构造超点图,该方法最大程度地保留了每个超点内的物体特征,同时有效降低了计算复杂度,并且可以显著扩展感受野,获得更丰富的信息。同时,该方法提出了一种双重注意模块(IAG-MLP),结合了跨位置和跨通道的注意机制,用于学习超点中的高级特征。此外, IAGC 网络采用一种称为 GRU 的 RNN 架构,在整个超级节点集上执行,以提取全局上下文信息,更新局部嵌入并促进最终的语义分割推理。

为充分提取采样中心点与其相邻点之间的深层特征关系, Deng 等^[18]根据模型的损失值调整采样权值,设计了一种基于 FPS 的加权采样方法,平衡了网络对各种采样数据的提取能力。在特征编码过程中引入了采样中心点邻域空间的关系学习,使用注意力模型来区分特征的重要

性,并使用混合池化方法对全局特征与局部特征进行聚合和传输。

2.4 深度图卷积方法

当网络层数增加时,会出现梯度消失和过度平滑的问题,这与 CNN 深度增加时出现的问题相似。将 CNN 领域中残差连接、密集连接和扩张卷积等经典神经网络模块应用于图卷积网络中,是一种有效的解决深层网络梯度问题的方法。DeepGCNs^[19]是这方面的代表性工作,通过引入这些模块,增加了 GCNs 的感受野,在点云分割任务中表现出色,即使在只有少量邻近点的情况下也能获得优异的性能。为了进一步增强聚合函数的效果, Li 等提出了广义聚合网络(GEN)作为 DeeperGCN^[20]的核心组成部分。该方法定义了一种通用特征聚合函数,可将 mean 和 max 等特征聚合操作覆盖到广义空间中,可以不断学习优化。同时,该方法还改进了图跳跃连接并提出了一种新的图归一化层,增强了 GCNs 的能力。DeepGCNs 的网络结构如图 4 所示。

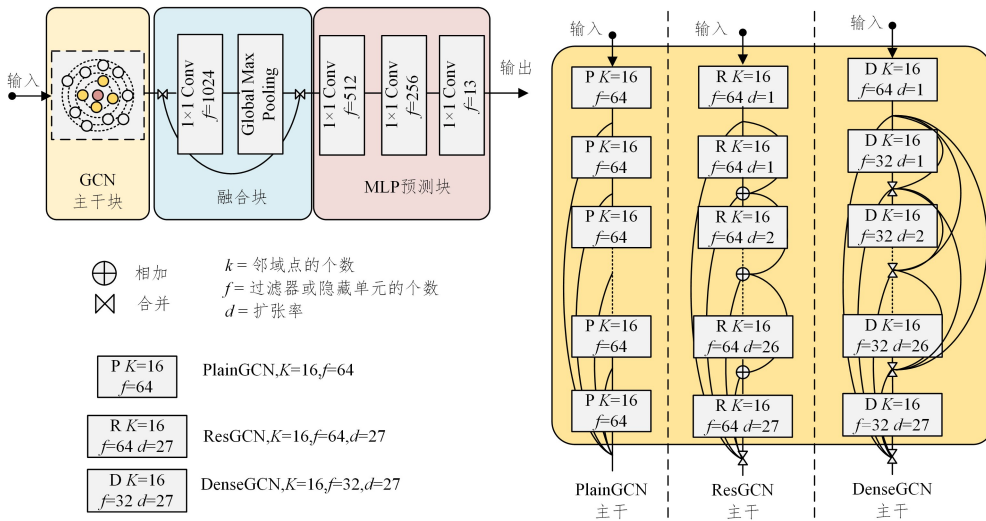


图 4 DeepGCNs 网络结构图
Fig. 4 Diagram of DeepGCNs network structure

Wang 等^[21]提出了 DeepGCNs-Att 模型,使用 ResGCN 作为图卷积网络的主干块,通过 MLP 进行特征融合,并利用空间注意力模块和通道注意力模块在点云中主动学习全局特征,以取代最大化池化层。在相同层数下,DeepGCNs-Att 在空间复杂性和计算复杂性等方面表现出优异的结果,并具有良好的采样密度变化鲁棒性。另外,为了降低 DeepGCNs 结构的计算成本和运行延迟,He 等^[22]提出了一种新的框架 AgileGCN,使用结构化剪枝压缩和加速具有残差连接的深层 GCN 模型。该网络针对深度 GCN 的每个残差结构,分别对卷积层的输入和输出通道进行通道采样和填充,以显著减少浮点运算(FLOPs)和参数数量。

2.5 扩张图卷积方法

在点云语义分割任务中,局部特征的提取对于提高分割准确性至关重要。为此,Engelmann 等^[23]提出了一种基于扩张卷积的点云分割网络,称为扩张点卷积(DPC)网络。DPC 网络使用扩张卷积操作来增加感受野范围,以充分提取局部特征。

为了更好地利用点云的局部细粒度特征,DGNet^[24]引入了局部扩张图来为每个输入点构建一种远程空间相关性,并能够访问具有远程依赖关系的局部点的几何信息。DGNet 还设计了扩张图注意力模块(DGAM),它嵌入了一种新的偏移-注意力机制,能够动态地学习局部注意力特征,并利用注意力池化机制捕获最重要的局部几何信息。这种策略扩大了感受野,丰富了局部特征信息,从而使最终聚合的特征更能代表点云的局部区域。

在点云分割任务中,局部特征提取是提高分割精度的关键因素之一。为此,Wang 等^[25]提出了一种局部特征聚合模块(DNE)用于扩张邻近图的分割网络(DNNG),如图 5 所示。DNE 模块使用局部特征编码、注意力池化和扩张残差块,提取随机采样点的特征,并利用共享的多层感知器进行上采样和编码,最终得到语义分割结果。该网络通过相同数量的神经网络参数来扩大邻域范围,以增加接受域,提取更多的几何信息。Wang 等将该模块应用于 RandLA-Net 和 Point Transformer 中进行评估,实验证明该方法具有稳定的优势。

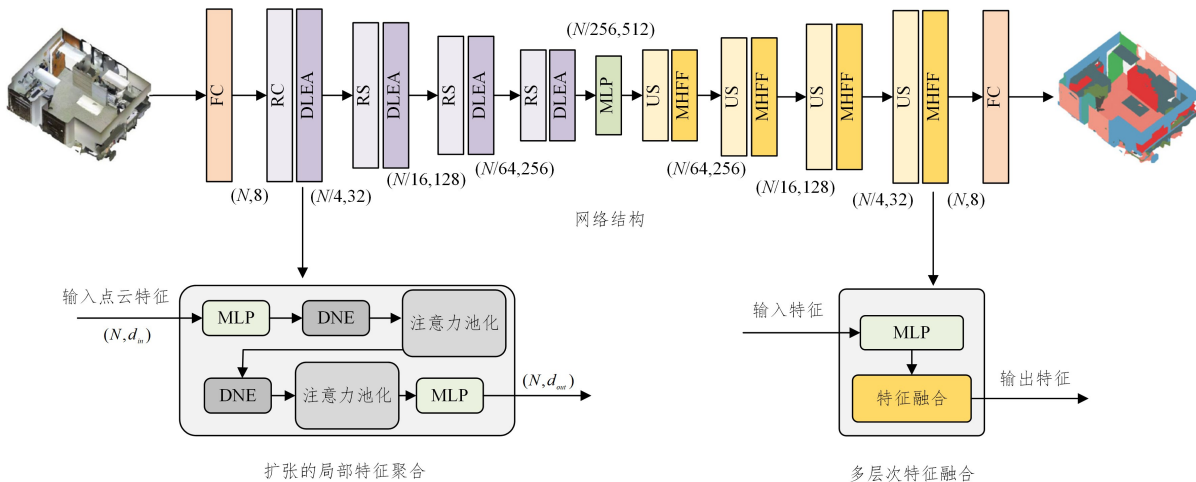


图 5 DNNG 网络结构图
Fig. 5 Diagram of DNNG network structure

通用点云分割网络中,使用固定 KNN 搜索邻近点的方式计算接受场,限制了接受场范围只能覆盖单一区域,无法捕捉多尺度局部关系,因此无法学习空间结构相似的点间关

系。此外,多感受野特征的表达受到感受野大小唯一性和计算依据唯一性的限制。为解决这些问题,Mao 等^[26]提出了 DGFA-Net 网络,该网络使用 DGConv 获取不同尺度的感受

野,并根据预设的膨胀率捕获不同感受区域的膨胀图。此外,DGFA-Net提出了基于DGConv的膨胀图特征聚合模块(DGFA),以解决相似区域的错误分类问题,并提出了多基聚合损失(MALoss)驱动的金字塔解码器,以不同分辨率的点集作为计算基础,从而实现了利用多层次接受场信息的效果。实验证明,DGFA-Net显著提高了具有相似空间结构类别的分割性能,并为捕获多尺度特征提供了新的思路。

2.6 其他方法

Landrieu等^[27]在SPG网络中引入了超点(Super Point, SP)图的概念。SPG采用无监督的方式将点云划分为几何上均匀的元素,使用超点表示大规模点云,从而极大地减小了处理大规模点云的计算压力。针对海量数据,Geng等^[28]提出了一种局部嵌入超点图(LE-SPG)的结构表示算法,将点云表示为简洁的图,同时通过局部空间嵌入保留数据固有的拓扑结构,并在上下文分割过程中使用门控积分图卷积网络(GIGCN)对图分割。在GIGCN中,为防止梯度消失或爆炸,每一层的门控循环单元的隐藏状态使用一种称为门控隐藏状态集成(GHSD)的新层进行集成,通过让损失函数直接访问每一层来增强反向传播,并全面吸收不同层的特征,使网络产生更平滑的决策边界,防止过拟合问题。

Li等^[29]提出了一种泰勒-高斯混合模型(TGNet),旨在提取输入点云与其相邻坐标或特征之间的高级几何相关性,并应用于点云语义分割。TGNet使用TGConv进行局部卷积操作,通过一系列滤波器对局部邻点特征和几何特征进行参数化。其中,几何特征是从由高斯加权泰勒核函数族表示的局部坐标中提取的,可用于提取邻点之间的几何相关性,以提高语义分割性能。

为了解决标准卷积在点云分割任务中无法区分三维点之间的特征对应关系,特征学习能力具有局限性的问题,Wei等^[30]提出了自适应图卷积(AdaptConv)。该方法根据点特征动态生成自适应核,以更灵活的方式塑造几何特征,而不再使用固定的内核来捕捉点之间难以区分的对应关系。实验证明该网络具有更高的分割精度,并可与现有的图CNN集成,通过用自适应内核替换现有内核来提高性能。

Yang等^[31]将特征空间中的条件随机场(CRF)引入点云分割任务,以捕捉特征结构,提高特征的表示能力。他们使用二次能量模型对点云特征进行建模,并将求解过程描述为一个消息传递图卷积。他们基于所提出的连续CRF图卷积(CRFConv)构建了一个端到端网络,并将CRFConv嵌入在解码器中,以恢复编码阶段丢失的高级特征细节,从而增强网络的定位能力,有利于点云分割任务的实现。

3 数据集与评价指标

设计合理的数据集和评价指标对于训练复杂的分割网络是不可或缺的,能够对网络的分割性能进行比较评估,推动网络架构改进,提出新方法。

3.1 数据集

KITTI数据集由德国卡尔斯鲁厄理工学院和丰田美国技术研究院联合创办,每张图像最多包含15辆车和30个人,整个数据集由389对立体图像和光流图,39.2 km视觉测

距序列以及超过200 000三维标注物体的图像组成。

S3DIS数据集在2016年由斯坦福大学开发,是一个大型的3D室内数据集,包含6个区域272个房间,共13种类别,扫描面积超过6 000 m²,数据量超过7亿,并包含深度和xyz坐标等信息。

ScanNet数据集在2017年由斯坦福大学、普林斯顿大学以及德国慕尼黑工业大学共同研发,是由RGB-D视频组成的室内场景数据集,包含1513个采集场景数据,应用于点云分类分割和CAD模型检索等任务。

Semantic3D数据集是在2017年由瑞士苏黎世联邦理工大学开发的室外数据集,包含8个类别15个大型点云,所扫描的场景包括教堂、街道、广场等,超过40亿个点,为当前最大点云户外场景分割数据集。

SemanticKITTI数据集在2019年由德国波恩大学开发,是一个自动驾驶场景中语义分割的数据集。为KITTI Vision Benchmark的LiDAR数据提供逐点label。它基于里程计任务数据,并提供28类的标注信息。

Nuscence数据集由1 000个场景组成,每个场景长度为20 s,包含了各种各样的情景。关键帧经过手工的标注,每一帧中都有了若干个注释,标注的形式为bounding box,不仅标注了大小、范围,还有类别、可见程度等。

Toronto-3D数据集为加拿大多伦多MLS系统获取的用于语义分割的大型城市户外点云数据集。该数据集覆盖了大约1 km的点云,由大约7 830万个点和8个标记的对象类组成。

3.2 评价指标

评价指标用于比较点云语义分割效果,包含总体精度(Overall Accuracy, OA)、平均分类精度(Mean Accuracy, mAcc)、均交并比(mean Intersection over Union, mIoU)和平均精率(mean Accuracy Precision, mAP)等。具体公式如表1所列。

表1 常用的评价指标

Table 1 Common evaluation indicators

Indicators	Formula
Accuracy	$Acc = \frac{TP + TN}{TP + TN + FP + FN}$
mAcc	$mAcc = \frac{1}{C+1} \sum_{i=0}^C Acc$
IoU	$IoU = \frac{TP}{TP + FP + FN}$
mIoU	$mIoU = \frac{1}{C+1} \sum_{i=0}^C IoU$
OA	$OA = \frac{1}{N} \sum_C TP_i$
AP	$AP = \frac{1}{C} \sum_C \left(\frac{1}{ thresholds } \sum_i \frac{TP(i)}{TP(i) + FP(i)} \right)$
mAP	$mAP = \frac{1}{C} \sum_{i=1}^C AP_C$

其中, N 表示总样本数; C 表示分割类别数; TP, TN, FP 和 FN 分别表示真阳性真阴性、假阳性和假阴性。

4 点云语义分割方法精度对比

本文将模型在3个公开数据集上的分割结果进行比较,如表2所列,“—”表示网络模型未提供该数据集的相应结果。从表中可以看出,S3DIS数据集使用最为广泛,在此数据集上

使用自适应图卷积的 AGConv 精度最好;该网络在 ShapeNetPart 数据集上也有不俗表现。

表 2 不同方法的分割模型在公开数据集上的分割结果

Table 2 Segmentation results of different methods' segmentation model on public datasets (%)

Method	Model	S3DIS		ShapeNetPart		Semantic3D	
		<i>mIoU</i>	<i>OA</i>	<i>mIoU</i>	<i>OA</i>	<i>mIoU</i>	<i>OA</i>
Spectral Domain	LSGCN ^[6]	—	—	85.40	—	—	—
	RGCNN ^[7]	—	—	84.30	—	—	—
	PointNGCNN ^[8]	—	87.30	85.60	—	—	—
	DFGCN ^[9]	—	—	80.38	—	—	—
Spatial Domain	DGCNN ^[10]	56.10	84.10	85.20	—	—	—
	LDGCNN ^[11]	—	—	85.10	—	—	—
	DDGCN ^[12]	62.80	85.90	86.20	—	—	—
	AP-GCN ^[13]	—	—	85.40	—	—	—
Graph Attention Convolution	GAPNet ^[14]	—	—	84.70	—	—	—
	GACNet ^[15]	62.85	87.79	—	—	73.20	94.00
	AGNet ^[16]	59.60	85.90	—	—	—	—
	IAGC ^[17]	64.70	85.60	—	—	—	—
DeepGraph Convolution	DeepGCNs ^[19]	60.0	85.90	—	—	—	—
	DeeperGCN ^[20]	—	—	—	—	—	—
	DeepGCNs-Att ^[21]	57.7	—	—	—	—	—
	AgileGCN ^[22]	—	—	—	—	—	—
DilatedGraph Convolution	DGANet ^[24]	—	—	85.20	94.30	—	—
	DNNG ^[25]	62.5	—	—	—	—	—
	DGFA-Net ^[26]	65.8	88.2	83.8	—	—	—
Other Method	SPG ^[27]	62.10	85.50	—	—	—	—
	3DGraphSeg ^[28]	—	—	—	—	76.8	94.7
	TGNet ^[29]	57.80	88.50	—	—	—	—
	AGConv ^[30]	67.90	90.00	86.40	—	—	—
	CRFConv ^[31]	66.20	89.20	83.50	—	74.90	94.20

5 面临的挑战与展望

针对不同方法,本文分析了存在的问题并对未来发展方向进行展望。

基于频谱域的图卷积网络依赖于对拉普拉斯矩阵的特征分解,而图结构的微小扰动可能导致不同的特征基。同时,特征分解需要较大的计算代价,学习到的滤波器针对特定问题,泛化能力较差。因此,未来的研究方向应该是对网络模型进行优化,以降低计算代价并提高泛化能力,从而解决当前存在的问题。

基于空间域的图卷积方法则基于节点的空间关系定义图卷积算子,可以共享权值以提高效率和泛化能力。未来需要解决特征各向同性导致忽略物体结构的问题,该问题会导致物体边界分割效果不佳,需要通过优化网络架构和调整参数来解决。

将注意力机制与图卷积方法结合可以有效解决基于空间域方法中忽略物体结构的问题,但其存在类不平衡问题和稀疏区域处理效果不佳等问题,因此提高稀疏区域的分割精度是未来的研究方向之一。此外,由于处理大型点云数据的计算压力较大,计算速度较慢,因此优化结构,提高核心模块嵌入能力也是一个重要的发展方向。

深度图卷积是将 CNN 领域内用于解决梯度下降问题的方法迁移到图卷积中,通过改进抽样算法可以进一步提高分割精度。然而,其网络结构较深,训练时间增大和内存资源占用增多是不可避免的,需要在结构设计、算法应用和优化模型等方面做出改进。

扩张图卷积在保持参数个数不变的情况下拓宽感受野,处理大规模点云任务具有更高的运行速度和精确度,但其局

部特征提取能力不足,使用多模态表示点云可能会有更好的分割精度,将二维特征和三维特征结合用于提取局部特征也是未来的发展方向之一。

当前使用图卷积的方式处理点云任务是一个热点话题。虽然本文列举的方法通过全面逐点特征和局部几何信息完成分割任务,但其中使用的 KNN 和 ball query 等搜索机制容易忽略局部低级特征,增加了特征提取难度。因此,未来需要在算法设计上做出改进。

结束语 使用图卷积处理点云的主要目的是在点云中构建图结构,获取局部特征与全局特征,克服信息丢失问题,提高数据处理的精度及速度。当前点云语义分割的研究发展趋势是:1)增强点云有效特征的提取能力;2)改进现有的语义分割网络结构来提高精度;3)结合 2D 特征和 3D 特征获取更多相关信息。随着 3D 信息获取技术的成熟,数据集的质量也在不断提升,改进模型和提高数据集质量都可以提升语义分割任务中模型的性能。综上所述,将图卷积应用于点云虽已取得一定成果,但许多问题仍待解决。

参 考 文 献

- [1] QI C R, SU H, MOK, et al. Pointnet: Deep learning on point sets for 3d classification and segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017:652-660.
- [2] QI C R, YI L, SUH P N, et al. Deep hierarchical feature learning on point sets in a metric space. arXiv 2017 [J]. arXiv: 1706.02413, 2017.
- [3] HUANG Q, WANG W, NEUMANN U. Recurrent slice networks for 3d segmentation of point clouds[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recogni-

- tion. 2018;2626-2635.
- [4] ZHANG S, TONG H, XU J, et al. Graph convolutional networks: a comprehensive review[J]. *Computational Social Networks*, 2019, 6(1): 1-23.
- [5] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs[J]. arXiv:1312.6203, 2013.
- [6] WANG C, SAMARI B, SIDDIQI K. Local spectral graph convolution for point set feature learning[C]// *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018; 52-66.
- [7] TE G, HU W, ZHENG A, et al. Rgcnn: Regularized graph cnn for point cloud segmentation[C]// *Proceedings of the 26th ACM international conference on Multimedia*. 2018; 746-754.
- [8] LU Q, CHEN C, XIE W, et al. PointNGCNN: Deep convolutional networks on 3D point clouds with neighborhood graph filters[J]. *Computers & Graphics*, 2020, 86: 42-51.
- [9] LI W, MA Q, TIAN W, et al. Graph Convolution Network with Double Filter for Point Cloud Segmentation[C]// *2020 5th International Conference on Intelligent Informatics and Biomedical Sciences (ICIBMS)*. IEEE, 2020; 168-173.
- [10] WANG Y, SUN Y, LIU Z, et al. Dynamic graph cnn for learning on point clouds[J]. *ACM Transactions On Graphics (tog)*, 2019, 38(5): 1-12.
- [11] ZHANG K, HAO M, WANG J, et al. Linked dynamic graph cnn: Learning on point cloud via linking hierarchical features[J]. arXiv:1904.10014, 2019.
- [12] CHEN L, ZHANG Q. Ddgcnn: graph convolution network based on direction and distance for point cloud learning[J]. *The Visual Computer*, 2023, 39(3): 863-873.
- [13] WANG Y, XIAO S. Affinity-Point Graph Convolutional Network for 3D Point Cloud Analysis[J]. *Applied Sciences*, 2022, 12(11): 5328.
- [14] CHEN C, FRAGONARA L Z, TSOURDOS A. GAPointNet: Graph attention based point neural network for exploiting local feature of point cloud[J]. *Neurocomputing*, 2021, 438: 122-132.
- [15] WANG L, HUANG Y, HOU Y, et al. Graph attention convolution for point cloud semantic segmentation[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019; 10296-10305.
- [16] JING W, ZHANG W, LI L, et al. AGNet: An attention-based graph network for point cloud classification and segmentation[J]. *Remote Sensing*, 2022, 14(4): 1036.
- [17] ZHAI R, ZOU J, HE Y, et al. IAGC: interactive attention graph convolution network for semantic segmentation of point clouds in building indoor environment[J]. *ISPRS International Journal of Geo-Information*, 2022, 11(3): 181.
- [18] DENG C, PENG Z, CHEN Z, et al. Point Cloud Deep Learning Network Based on Balanced Sampling and Hybrid Pooling[J]. *Sensors*, 2023, 23(2): 981.
- [19] LI G, MULLER M, THABET A, et al. Deepgcns: Can gcns go as deep as cnns? [C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2019; 9267-9276.
- [20] LI G, XIONG C, THABET A, et al. Deepergen: All you need to train deeper gcns[J]. arXiv:2006.07739, 2020.
- [21] WANG X, JIANG B, ZHANG Z, et al. DeepGCNs-Att for Point Cloud Semantic Segmentation[C]// *Journal of Physics: Conference Series*. IOP Publishing, 2021; 012059.
- [22] HE Q, BANERJEE S, SCHWIEBERT L, et al. AgileGCN: Accelerating Deep GCN with Residual Connections using Structured Pruning[C]// *2022 IEEE 5th International Conference on Multimedia Information Processing and Retrieval (MIPR)*. IEEE, 2022; 20-26.
- [23] ENGELMANN F, KONTOGIANNI T, LEIBE B. Dilated point convolutions: On the receptive field size of point convolutions on 3d point clouds[C]// *2020 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2020; 9463-9469.
- [24] WAN J, XIE Z, XU Y, et al. DGANet: A dilated graph attention-based network for local feature extraction on 3D point clouds[J]. *Remote Sensing*, 2021, 13(17): 3484.
- [25] WANG L, WU J, LIU X, et al. Semantic segmentation of large-scale point clouds based on dilated nearest neighbors graph[J]. *Complex & Intelligent Systems*, 2022, 8(5): 3833-3845.
- [26] MAO Y, SUN X, DIAO W, et al. Semantic segmentation for point cloud scenes via dilated graph feature aggregation and pyramid decoders[J]. arXiv:2204.04944, 2022.
- [27] LANDRIEU L, SIMONOVSKY M. Large-scale point cloud semantic segmentation with superpoint graphs[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2018; 4558-4567.
- [28] GENG Y, WANG Z, JIA L, et al. 3DGraphSeg: A unified graph representation-based point cloud segmentation framework for full-range highspeed railway environments[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(2): 11430-11443.
- [29] LI Y, MA L, ZHONG Z, et al. TGNet: Geometric graph CNN on 3-D point cloud segmentation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 58(5): 3588-3600.
- [30] WEI M, WEI Z, ZHOU H, et al. AGConv: Adaptive Graph Convolution on 3D Point Clouds[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(8): 9374-9392.
- [31] YANG F, DAVOINE F, WANG H, et al. Continuous conditional random field convolution for point cloud segmentation[J]. *Pattern Recognition*, 2022, 122: 108357.



HUANG Haixin, born in 1973, Ph.D, associate professor. Her main research interests include machine learning, artificial intelligence and intelligent grid.