

基于图卷积和多层特征融合的点云分类方法

田晟*, 龙安洋

华南理工大学土木与交通学院, 广东 广州 510641

摘要 为了解决现有的深度学习点云分类方法对局部特征挖掘不充分的问题并提升不同层级特征融合的质量,提出一种基于图卷积和多层特征融合的点云分类方法。首先,构造 K 邻域图,在此基础上利用改进的边缘函数提取更细粒度的边特征,并使用基于注意力机制的聚合方法获取更具代表性的局部特征。然后,通过多层特征融合模块调整中间特征的通道权值,引入残差连接融合不同层级的特征,加深网络层之间的信息传递。在标准公开数据集 ModelNet40 上的实验结果表明,相比其他点云分类方法,所提方法的分类性能更好,总体分类精度为 93.2%,并且具有较强的鲁棒性。

关键词 机器视觉; 深度学习; 点云分类; 图卷积; 多层特征融合

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP221938

Point Cloud Classification Method Based on Graph Convolution and Multilayer Feature Fusion

Tian Sheng*, Long Anyang

School of Civil and Transportation, South China University of Technology, Guangzhou 510641, Guangdong, China

Abstract A point cloud classification method based on graph convolution and multilayer feature fusion is proposed to solve the problem that the existing deep learning point cloud classification methods are insufficient for local feature mining and to improve the quality of feature fusion at different levels. First, the K -neighborhood graph is constructed, the improved edge function is used to extract more fine-grained edge features, and the aggregation method based on attention mechanism is used to obtain more representative local features. Next, the multilayer feature fusion module adjusts the channel weight of the intermediate features, introduces residual connection to fuse the features of different levels, and deepens the information transmission between the network layers. The experimental results using the standard public dataset ModelNet40 show that the proposed method exhibits better classification performance than other point cloud classification methods. The proposed method is robust and has an overall classification accuracy of 93.2%.

Key words machine vision; deep learning; point cloud classification; graph convolution; multilayer feature fusion

1 引言

随着三维扫描技术的快速发展和激光雷达、深度摄像机等采集设备的普及,点云数据的获取变得更加方便和快捷。点云较好地保留了物体的原始空间结构及表面特征,因而在自动驾驶^[1]、智能网联车^[2]、虚拟现实^[3]等领域得到了广泛应用。然而,三维点云具备无序性、密度不均匀性、场景复杂多变性等特点,因此对点云数据的分类任务一直是研究的热点且具有一定的挑战性。

早期的分类方法主要通过手工对点云的特定属性

进行特征提取,如法向量、曲率、质心距直方图等^[4-6]。然而,手工提取特征虽取得一定的效果,但该方法很大程度上依赖于先验知识,有较强的主观性,难以应用于复杂的点云场景。深度学习在图像领域的出色表现使研究者们尝试将其应用到点云分类中。Su等^[7]将三维点云向不同的视角投影,得到多幅二维(2D)图像后利用卷积神经网络(CNN)分类。Yang等^[8]提取了点云的高度、偏离角方差等特征,并将其转换为多个特征图像,使用CNN分类。Maturana等^[9]将点云转换为规范化的体素网格,提出一种结构简洁的三维卷积神经网络VoxNet,提升了点云分类精度。雷相达等^[10]通过设

收稿日期: 2022-06-28; 修回日期: 2022-07-30; 录用日期: 2022-08-29; 网络首发日期: 2022-09-09

基金项目: 广东省自然科学基金面上项目(2021A1515011587, 2020A1515010382)

通信作者: *shitian@scut.edu.cn

置不同的邻域大小和投影方向,生成多尺度和多投影特征图,在小样本的情况下实现了点云的高精度分类。然而,基于投影或体素化的方法在数据转化过程中损失了有价值的信息,这限制了最终的分类性能。

Charles 等^[11]率先提出直接处理原始点云的网络 PointNet,该网络通过多层感知机(MLP)和最大池化函数提取全局特征向量,解决了点云的置换不变性问题。但 PointNet 仅对每个点单独进行处理,并未考虑到点的邻域关系。为了解决该问题,Qi 等^[12]提出 PointNet++,该网络通过采样、分组的方式划分局部区域,但仍以独立点卷积的方式提取特征,未实际捕获邻域内的依赖关系。在 PointNet++ 的基础上,Li 等^[13]提出 SO-Net,利用自组织映射分层提取点云特征。赵中阳等^[14]在 PointNet 的基础上添加多尺度网络,提取点在不同尺度下的局部特征并进行融合。闫杰琼等^[15]将整体点云分割为特征数据与非特征数据,从多尺度局部表面片中提取形状结构和局部邻域信息,实现了高精度语义分割。释小松等^[16]基于多尺度网络提取邻域特征,融合点云与遥感影像数据用于训练,进一步提升了分类精度。杨建儒等^[17]挖掘和融合点云光谱反射信息及密度、法向量等空间几何特征,实现了植物茎叶的高效分离。上述研究改善了缺乏点云局部信息的问题,但并未对点与点之间的关系进行描述。Wang 等^[18]提出动态图卷积神经网络(DGCNN),通过动态构建局部邻域图来提取中心点与邻近点间的边缘特征,进一步聚合生成局部邻域特征,该网络较好地描述了点与其邻域的相关性,提升了局部特征的特征质量。Zhang 等^[19]在 DGCNN 的基础上连接不同层次的局部特征,有效提高了网络的分类精度。王江安等^[20]增加特征提取层数并引入残差连接,对局部特征进行更深层次的抽象。徐田野等^[21]提出一种融合图卷积的分类方法,分别基于空间域和谱域的图卷积提取点的局部特征,通过融合两种特征获取更丰富的局部

信息。基于图卷积的方法有效提取了点云的局部特征,然而直接融合不同层次的特征,可能在高层特征中引入干扰信息,影响分类性能。

针对上述方法存在的问题,本文结合图结构处理点云的优势,提出一种基于图卷积和多层特征融合的点云分类方法。首先,构造局部有向图,通过改进的边缘函数提取边特征,利用基于注意力机制的聚合方法获得局部特征,提升网络对局部信息的捕获能力;然后,对特征通道间的依赖关系进行建模,自适应地调整通道权值,并引入残差连接融合不同层次的特征,完成中间特征的优化;最后,使用高层次的全局特征向量实现点云的准确分类。

2 基于图卷积和多层特征融合的点云分类网络

2.1 网络结构设计

图 1 为所提点云分类网络结构图。网络的输入端为点集 $P = \{p_1, p_2, \dots, p_N\} \subseteq \mathbf{R}^3$,其中, p_i 表示第 i 点的 3 维坐标, N 表示点的数目。 $N \times 3$ 维的点云首先通过 1 个空间转换网络(STN)获取空间仿射矩阵,该矩阵将输入数据对齐到统一的规范空间中,可解决点云的旋转不变性问题。对齐后的数据依次经过 3 个图结构特征提取(GSFE)模块,在每个 GSFE 模块中应用 K 最近邻(KNN)算法构建对应的图结构,从而提取包含中心点与邻近点信息的 64 维、64 维、128 维局部特征。将提取到的不同层级局部特征分别作为多特征融合(MFF)模块的输入,在 MFF 模块内完成特征通道的权值重分配和多层级特征融合,从而获得优化后的 128 维、256 维中间特征。将 $N \times 256$ 维点云特征再通过 MLP(1024)映射到高维特征空间,利用全局最大池化层聚合得到 1×1024 维的全局特征向量,最后使用 3 个全连接层(FC, 512, 256, c)作为分类器,输出样本的分类得分,其中, c 为样本的类别数目。

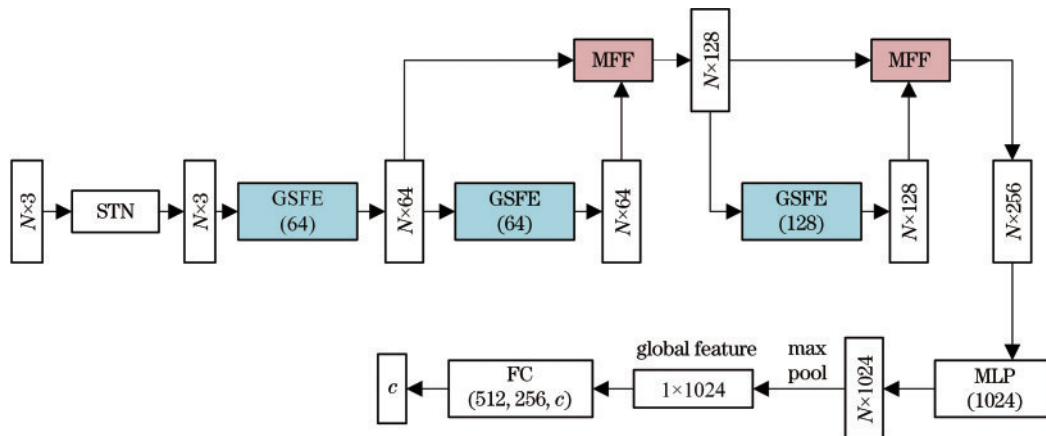


图 1 点云分类网络结构

Fig. 1 Point cloud classification network structure

2.2 图结构特征提取模块

由于点云是典型的非欧几里得数据,因此传统的二维卷积无法适用于其局部特征提取。而图结构的特性与非结构化的点云十分契合,这为描述点云的局部邻域关系提供了解决方案。图 2 为所设计的图结构特征提取模块,该模块的特征学习过程可分为以下步骤:1)利用 KNN 算法对输入点云构建局部有向图;2)通过边缘函数提取局部图结构中的边特征 e_{ij} ;3)通过基于注意力机制的聚合函数对邻域特征进行聚合,输出局部特征 l_i 。在图 2 中, N 为输入点的数目, D 为输入点的特征维度, K 为邻域点的数目, D' 为输入点经过特征提取后的特征维度。




图 2 图结构特征提取模块

Fig. 2 Graph structure feature extraction module

将点云转换为图结构表示,需要以逐点遍历的方式选择中心点并搜索其邻域点。KNN 算法是在非欧氏空间中搜索邻域点的常用方法,因此通过 KNN 算法来构造局部有向图 G ,如图 3 所示。




图 3 图结构构建过程

Fig. 3 Construction process of graph structure

对于一个给定的中心点 p_i ,使用 KNN 算法选取其 K 个邻域点 $p_{ij}, j=1, 2, \dots, K$,然后通过有向边将中心点 p_i 和所有的邻域点 p_{ij} 连接。构造的图结构 G 可描述为

$$G=(V, E), \quad (1)$$

$$V=\{p_i|i=1, 2, \dots, N\}, \quad (2)$$

$$E=\{e_i=(e_{i1}, e_{i2}, \dots, e_{ik})|i=1, 2, \dots, N\}, \quad (3)$$

式中: V 表示 N 个中心节点的集合; E 表示中心点及其邻域点构成的有向边集合; e_{ik} 表示中心点 p_i 与第 k 个邻域点 p_{ik} 之间的边特征。由于每个点的特征在不同的特征提取层是变化的,因此通过 KNN 算法在特征空间构建的 K 邻域图也是动态的,这使得点云的局部图结构能够随网络层的加深而不断更新,增强了网络对局部信息的捕获能力。

构建图结构完成后,对边特征进行提取。边特征的表达式为

$$e_{ij}=h_\theta(p_i, p_{ij}), \quad (4)$$

式中: $h_\theta(\cdot)$ 为边缘函数,是由一组可学习参数 θ 构成的非线性函数,用来实现 $\mathbf{R}^D \times \mathbf{R}^D \rightarrow \mathbf{R}^{D'}$ 的特征提取,选取多层感知机对参数 θ 进行学习。边缘函数和聚合函数的选择对局部特征的生成具有重要影响。PointNet^[11] 中的边缘函数如式(5)所示,该形式的边缘函数只考虑了独立点构成的全局信息,未顾及局部结构的特征。DGCNN^[18] 则定义了如式(6)所示的边缘函数,该结构既考虑了点自身的全局特征,也顾及中心点与邻域点之间的相对特征,因而有效提升了分类性能。

$$e_{ij}=h_\theta(p_i), \quad (5)$$

$$e_{ij}=h_\theta(p_i, p_{ij}-p_i). \quad (6)$$

所提算法同时考虑点的全局特征及其邻域点的相对位置特征,并通过增加中心点与邻域点之间的欧氏距离信息来设计新的边缘函数:

$$e_{ij}=h_\theta(p_i, p_{ij}-p_i, \|p_{ij}-p_i\|), \quad (7)$$

式中: $\|\cdot\|$ 为欧几里得范数。该边缘函数进一步丰富了中心点与邻域点之间的几何信息。边特征提取完成后,通过聚合函数输出中心点 p_i 的局部特征 l_i :

$$l_i=\sigma_{j:(i,j) \in E} \left\{ h_\theta(p_i, p_{ij}-p_i, \|p_{ij}-p_i\|) \right\}, \quad (8)$$

式中, $\sigma(\cdot)$ 表示聚合函数。现有研究通常选择最大池化函数对边特征进行聚合,然而最大池化策略简单地选取邻域特征中的最大特征值作为输出,损失了部分有价值的信息,是目前点云分类网络的一个局限。因此,基于注意力机制设计了针对点云局部邻域特征的聚合方法。该方法通过计算邻域内 K 个特征的注意力权重对其进行加权,并对加权后的特征进行求和运算,从而获得兼顾各个特征信息的局部特征。具体步骤如下:

1) 计算注意力权重。给定邻域内的一组边特征集合 $L_i=\{l_{i1}, l_{i2}, \dots, l_{iK}\} \in \mathbf{R}^{K \times D}$, L_i 经过一个共享权值的 MLP 处理后,输出一组注意力激活参数 $C=\{c_1, c_2, \dots, c_K\} \in \mathbf{R}^{K \times D}$,使用 Softmax 函数对其进行归一化,得到特征的注意力权重 $S=\{s_1, s_2, \dots, s_K\} \in \mathbf{R}^{K \times D}$,该过程可描述为

$$C=g(L_i, W), \quad (9)$$

$$s_k=\frac{\exp(c_k)}{\sum_{j=1}^K \exp(c_j)}, \quad (10)$$

式中: $g(\cdot)$ 为共享参数的 MLP; W 为 MLP 的可学习权值。

2) 加权求和。学习到的注意力权重可视作自动选择重要特征的掩码,将邻域内的特征与其对应的注意力权重相乘进行加权,对加权特征求和得到聚合后的

局部特征 $l_i \in \mathbf{R}^{1 \times D}$, 计算方法为

$$l_i = \sum_{k=1}^K (l_{ik} \cdot s_k). \quad (11)$$

3) 特征维度变换。 l_i 经过由 FC、批归一化层 (BN) 和 ReLU 激活函数层组成的 MLP 完成特征维度变换, 以满足后续特征提取模块的输入尺寸要求。

2.3 多层特征融合模块

叠加特征提取层的数量以获取更高层次的特征是提升点云分类网络性能的一种有效方式。通过叠加 3 个 GSFE 模块逐层提取到 3 个不同层级的高维特征, 而中间特征介于浅层特征和深层语义特征之间, 直接影响到下一层的特征提取效果, 对最终的分类型准确率具有重要影响。因此, 为进一步提高模型的分类型精度, 对增强中间特征表征质量的方法开展了研究。

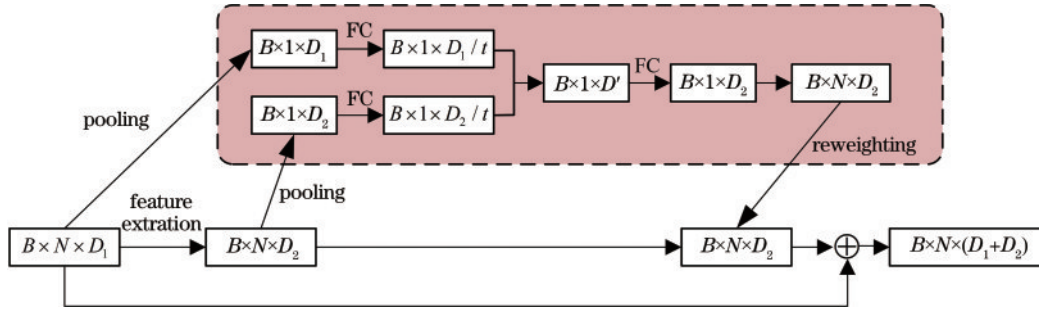


图4 MFf模块结构图

Fig. 4 Structure of MFf module

MFf模块的处理步骤如下:

1) 特征输入。输入前一层中间特征 $f_1 \in \mathbf{R}^{N \times D_1}$ 以及当前层的中间特征 $f_2 \in \mathbf{R}^{N \times D_2}$ 。

2) 通道特征压缩。使用池化函数对各通道上的特征进行聚合, 将空间上的点信息压缩为一系列具备全局感受野的通道描述符, 两组压缩的特征分别经过一个全连接层后降低通道数, 该过程可描述为

$$\varphi_i(f_i) = \frac{1}{t} \gamma_i[\sigma(f_i)], \quad i = 1, 2, \quad (12)$$

式中: $\gamma_i(\cdot)$ 表示后接 ReLU 激活函数的全连接层; $\sigma(\cdot)$ 为聚合函数, 此处选用全局平均池化来生成通道统计量; t 为压缩因子, 用于降低中间特征的通道数, 从而减少网络参数量, 设置为 4。

3) 权值生成。融合两组压缩后的特征, 得到包含残差流和恒等流信息的特征图。使用一个全连接层和 Sigmoid 激活函数来恢复特征通道数, 并学习通道之间的非线性交互关系, 当前层中间特征的通道分配权值的表达式为

$$F(f_1, f_2) = \varphi_1(f_1) \oplus \varphi_2(f_2), \quad (13)$$

$$W_c = \delta[F(f_1, f_2)], \quad (14)$$

式中: $F(\cdot)$ 为实现特征融合的函数; \oplus 表示特征的拼接融合, 融合后的特征维度 $D' = D_1/t + D_2/t$; $\delta(\cdot)$ 表示含有 Sigmoid 激活函数的全连接层; $W_c \in \mathbf{R}^{1 \times D_2}$ 为生

成的特征通道分配权值。
squeeze-excitation (SE) 模块^[22]在图像分类任务中展现出了优越的性能, SE 模块通过对特征通道之间的依赖关系进行建模, 自适应地调整特征通道的权重, 可有效增强特征的表达能力。competitive squeeze-excitation (CMPE-SE) 模块^[23]在 SE 模块的基础上进行了改进, 采用残差映射和恒等映射进行竞争建模, 更合理地完善了特征通道的权重调控机制。受 CMPE-SE 模块的启发, 设计了 MFf 模块来提升中间特征的表征质量。由于无序的点云和规则的图像之间存在本质区别, 因此 MFf 模块以 CMPE-SE 模块“压缩、激励、权值重分配”的特征优化思路为基础, 对各部分结构进行相应调整以适应三维点云的特点, 其网络结构如图 4 所示。其中, B 为批处理数据大小, N 为点的数量, D_i 为特征维度。

成的特征通道分配权值。

4) 多层特征融合。通道分配权值表征当前层中间特征 f_2 各个通道的重要程度, 权值越高的通道对训练结果的影响力越大。为方便将权值逐通道加权到原特征, 扩展 $W_c \in \mathbf{R}^{1 \times D_2}$ 的维度得到 $W_c \in \mathbf{R}^{N \times D_2}$ 。加权后的特征通过残差连接与 f_1 融合, 得到新的中间特征 $f_2^* \in \mathbf{R}^{N \times D_2}$ 可描述为

$$f_2^* = f_1 \oplus W_c f_2. \quad (15)$$

MFf 模块利用不同层级的中间特征进行竞争建模, 学习通道分配权值完成通道维度上的特征重标定, 从而选择性地激励重要通道特征, 抑制无用或低效通道特征。通过残差连接将前一层中间特征与调整后的当前层中间特征融合, 弥补了特征提取过程中的信息损失, 实现了中间特征优化。

3 实验及分析

3.1 实验数据集

为方便与其他点云分类算法比较, 使用公开数据集 ModelNet40 进行训练和测试。ModelNet40 数据集中包含 40 种物体类别, 共计 12311 个点云模型。其中, 用于训练的样本有 9842 个, 用于测试的样本有 2468 个, 以相同的比例划分训练集和测试集。对每个样本均匀采样 1024 个点, 并将其坐标归一化。

3.2 实验环境及参数设置

本实验的硬件环境为 Intel Core i5-9400 CPU、16 GB 内存、GeForce GTX 1050 Ti 显卡、8 GB 显存。软件环境为 Windows 10 (64 位) 操作系统、CUDA 10.1、CuDNN 7.6、TensorFlow 2.1、Python 3.7。

由于网络在训练过程中需要不断更新参数,而采用固定的学习率无法适用于所有参数的更新,因此选用 Adam 优化器来计算每个参数的自适应学习率,以提高训练的精度和效率。为保证模型对比的公平性,参照文献[14]、[20]、[21]等研究中的参数设置,使用 Adam 优化器的默认参数值,即初始学习率为 0.001,动量为 0.9。batch size 通常取 16 或 32^[16,20],在合适的范围内,batch size 的值越大,模型收敛速度越快,但对计算机的显存消耗越高,受实验硬件条件的限制,batch size 设置为 16。为防止网络出现过拟合,在每层卷积层后设置 BN 层,同时在全连接层中设 dropout 层,丢弃率取默认值 0.5。预实验结果表明,网络在迭代约 150 次时基本处于收敛状态,考虑到训练的精度和效率,设置训练轮数为 200。后文若无特殊说明,KNN 中的 K 值默认取 20。

3.3 点云分类结果分析

选取常用的总体分类精度(OA)和平均分类精度(mAcc)作为网络分类性能的评价指标。表 1 给出了所提方法和其他典型分类方法在 ModelNet40 数据集上的分类结果。其中,Multiview 表示多视图,Voxel 表示体素,Points 表示三维坐标,Normal 表示点云法线向量。实验结果表明,所提方法具有较好的性能,OA 和 mAcc 分别达到 93.2% 和 90.4%。在 OA 指标方面:所提方法比多视图方法 MVCNN 和体素方法 VoxNet 分别提高 3.1 个百分点和 7.3 个百分点,充分说明了基于点输入的方法能更有效地学习点云特征;与 PointNet、PointNet++、SO-Net 等相比,所提方法有 1.3 个百分点~4.0 个百分点的提升,表明通过图卷积提取点的边缘特征能有效补充点云的局部邻域信息,提高网络分类性能;与同样使用图卷积的 DGCNN 和 LDGCNN 相比,所提方法分别提升 2.0 个百分点、0.3 个

百分点,表明改进的图结构特征提取模块及新增的 MFf 模块能有效增强特征提取能力,减少中间信息损失,提高对细粒度模型的识别精度。

所提方法在部分点云模型上的分类结果可视化如图 5 所示。其中,飞机、汽车、吉他等模型具有明显的特征,网络的识别准确率较高。而椅子和课桌、花盆与植物等模型具有非常相似的特征,因而网络的误识别率较高,分类精度不足。




图 5 部分点云模型分类结果可视化

Fig. 5 Visualization of partial point cloud model classification results

K 值决定了构建局部有向图过程中的邻域点数量。为探究 K 值的选择对网络分类精度的影响,仅在 K 值不同的情况下进行了对比实验,实验结果如图 6 所示。由图 6 可知,当 K 值增大到 20 时网络的性能达到最优,此时继续增大 K 值,网络的分类精度反而逐渐下降。由此可以得出结论:在一定区间内,增加邻域点的个数可以丰富局部中心点的邻域信息,有助于提升分类精度;若邻域点的数量过多,会破坏每个局部邻域的几何结构,增加冗余点的干扰,导致网络分类性能下降。因此,选取合适的 K 值对模型的分类精度有重要影响。

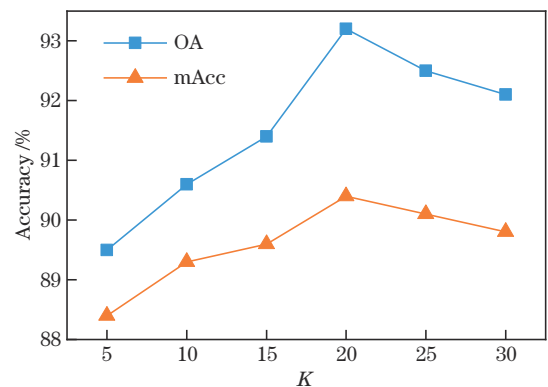


图 6 K 值对分类准确率的影响

Fig. 6 Influence of K value on classification accuracy

表 1 ModelNet40 数据集上的分类结果对比

Table 1 Comparison of classification results on ModelNet40 dataset

Method	Input	OA / %	mAcc / %
MVCNN ^[7]	Multiview	90.1	
VoxNet ^[9]	Voxel	85.9	
PointNet ^[11]	Points	89.2	86.2
PointNet++ ^[12]	Points+Normal	91.9	
SO-Net ^[13]	Points+Normal	90.9	87.3
DGCNN ^[18]	Points	91.2	88.8
LDGCNN ^[19]	Points	92.9	90.3
Proposed method	Points	93.2	90.4

此外,虽然基于KNN算法选取邻域点可以较好地突出局部代表性信息,但该方法仅保留了距离中心点基本相等的邻域点,为进一步探究邻域选择方法对网络分类精度的影响,设置了表2所示的对比实验。其中,基于半径的球形邻域查询(ball query)^[12,14]是常用的邻域选择方法,可以搜索中心点固定半径范围内的邻域点。参照文献[14]中的参数设置,球形邻域的半径 r 分别取0.1、0.2和0.3。为了保证实验的公正性,结合本实验最优邻域点取值($K=20$),随机选取中心点球形邻域内的20个点作为邻域点,若邻域内的点不足20个,则重采样至满足条件为止。由表2可知:在总体分类精度上,所提邻域选择方法取得了最高的分类精度;但在平均分类精度方面,使用球形查询方法($r=$

表2 邻域选择方法对分类精度的影响

Method	OA	mAcc
ball query($r=0.1$)	92.5	89.9
ball query($r=0.2$)	92.9	90.6
ball query($r=0.3$)	92.6	90.1
KNN($K=20$)	93.2	90.4

表3 消融实验结果对比

Table 3 Comparison of ablation experiment results unit: %

Model	OA	mAcc
A: original edge function + maxpooling	91.4	89.0
B: improved edge function + maxpooling	91.7	89.2
C: improved edge function + attentive pooling	92.3	89.7
D: improved edge function + attentive pooling + MFF	93.2	90.4

3.5 模型鲁棒性分析

在实际的点云数据采集过程中,受到复杂场景、传感器误差等因素影响,所采集的点云往往存在目标遮挡、噪声干扰等问题。为了检验所提模型的鲁棒性,分别模拟目标遮挡、噪声干扰等条件对模型分类精度的影响,实验参数与第3.2节保持一致。

模拟目标遮挡情况时,在对ModelNet40原始数据集均匀采样1024个点的基础上,随机丢弃25%、50%、62.5%、75%、87.5%的采样点,测试模型分类精度,并与DGCNN进行对比。实验中设置训练集与测试集的采样点数一致,结果如图7所示。可以看出,随着采样点数量的减少,所提模型的总体分类精度始终高于DGCNN,且曲线的下降趋势更平缓。当随机丢弃87.5%的采样点时,DGCNN的总体分类精度下降了7.1个百分点(从91.2%到84.1%),而所提模型下降了5.6个百分点(从93.2%到87.6%),这表明所提模型对目标遮挡问题具有较强的鲁棒性。

点云噪声一般包括扰动点和离群点。扰动点是指在采样平面上下一定范围内抖动的点,离群点则表示随机出现在空间任意位置的异常点。向采样点集中添

0.2时)的分类精度最高。这说明使用KNN算法选取邻域点能够更准确地识别具有明显特征的模型,因此总体分类精度较高。而球形邻域查询方法对特征不明显的模型的局部特征提取能力更强,能够提高对相似模型的识别能力,所以具有更高的平均分类精度。

3.4 消融实验

为了验证所提边缘函数、基于注意力机制的邻域特征聚合方法和MFF模块的有效性,构建4组消融对比实验。模型A为基准模型,采用与DGCNN相同的边缘函数,使用最大池化函数聚合局部邻域特征,且不加入MFF模块。模型B在模型A的基础上将边缘函数替换为所提形式。模型C在模型B的基础上将最大池化函数替换为基于注意力机制的邻域特征聚合方法。模型D在模型C的基础上加入MFF模块,对中间特征进行优化和融合。消融实验结果如表3所示。由表3可知:采用改进的边缘函数后,网络的总体分类精度提升了0.3个百分点;引入基于注意力机制的邻域特征聚合方法使网络分类精度由91.7%提升至92.3%;通过增加MFF模块,网络的分类精度有0.9个百分点的提升。实验结果表明,上述3个模块均有助于提升网络的特征提取能力,使网络的分类性能达到更优。

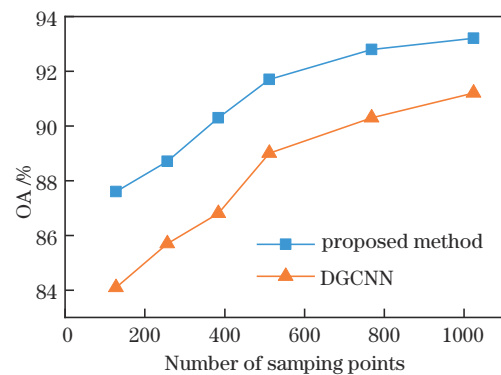


图7 采样点数对分类精度的影响

Fig. 7 Influence of sampling points on classification accuracy

加服从 $N(0, 0.02)$ 分布的高斯噪声模拟扰动点,加入 $x, y, z \in [-1, 1]$ 的随机噪声模拟离群点。噪声点的数量 n 设置为0、25、50、75、100,实验结果如图8所示。对比图8(a)、(b)可知,当高斯噪声数增加至100时,两种方法的总体分类精度仍在65%以上,而加入随机噪声数为100时,DGCNN的总体分类精度不足55%,这说明离群点对模型性能的影响比扰动点更为显著。另

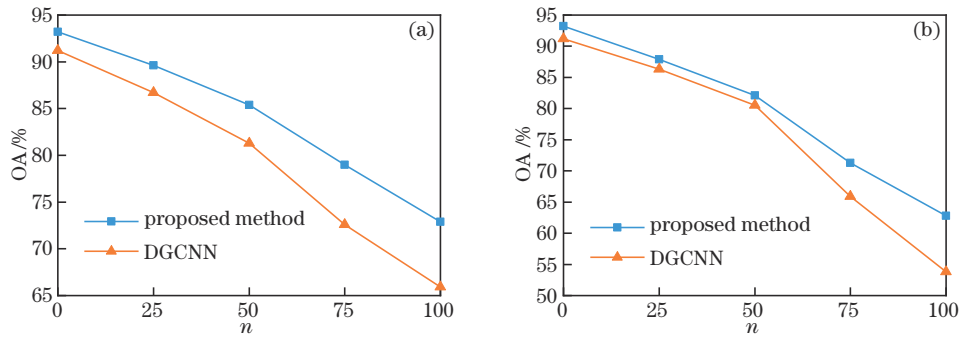


图 8 不同噪声类型下的分类性能。(a)高斯噪声;(b)随机噪声

Fig. 8 Classification performance under different noise types. (a) Gaussian noise; (b) random noise

外,在噪声数量增加的过程中,所提模型分类精度下降趋势比 DGCNN 更平缓,表明其对这两种噪声的抗干扰能力更强。

为进一步检验模型的鲁棒性,将原始采样点集中的一部分点随机替换为 $x, y, z \in [-1, 1]$ 的噪声点,模拟点丢失和噪声干扰同时存在时的模型性能,结果如图 9 所示。可以看出,当被替换的点数量由 0 增加到 100 时, DGCNN 的总体分类精度由 91.2% 下降到 36.6%, 降幅达到 54.6 个百分点。此时,所提模型由 93.2% 下降至 50.7%, 较 DGCNN 的降幅缩减了 12.1 个百分点。结果表明,即使处理点丢失和噪声并存的实际点云数据,所提模型仍能保持较高的分类精度,具有较强的鲁棒性。

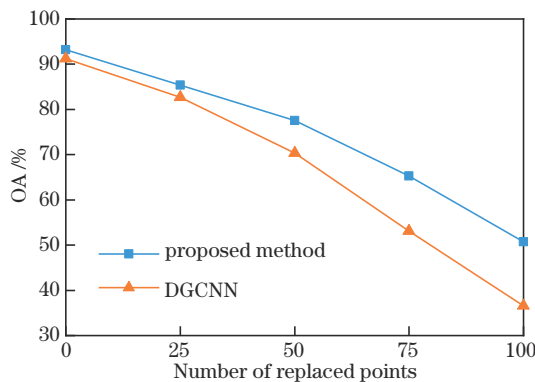


图 9 点丢失和噪声对分类精度的影响

Fig. 9 Influence of point loss and noise on classification accuracy

4 结 论

为进一步挖掘点云的局部邻域信息,提升特征融合的效果,提出一种基于图卷积和多层特征融合的点云分类方法。通过设计图结构特征提取模块,有效增强其对点云局部特征的提取能力;针对中间特征设计多层特征融合模块,该模块能自适应地调整特征通道的权值,并对不同层级的特征进行融合,显著地增强融合特征的表达能,提高模型分类性能。在 ModelNet40 数据集上通过一系列测试验证了所提方

法的有效性。实验结果表明,相较于其他分类方法,所提方法取得了较高的分类精度,并在面对不同的点云输入场景时具有较强的鲁棒性。然而,所提方法在处理复杂的点云输入时性能衰退较为显著,如何提高其在复杂点云场景下的分类性能有待进一步研究。

参 考 文 献

- [1] Li Y, Ibanez-Guzman J. Lidar for autonomous driving: the principles, challenges, and trends for automotive lidar and perception systems[J]. IEEE Signal Processing Magazine, 2020, 37(4): 50-61.
- [2] Kim K, Kim C, Jang C, et al. Deep learning-based dynamic object classification using LiDAR point cloud augmented by layer-based accumulation for intelligent vehicles[J]. Expert Systems with Applications, 2021, 167: 113861.
- [3] Yang B S, Huang R G, Li J P, et al. Automated reconstruction of building LoDs from airborne LiDAR point clouds using an improved morphological scale space [J]. Remote Sensing, 2016, 9(1): 14.
- [4] Bu S H, Liu Z B, Han J W, et al. Learning high-level feature by deep belief networks for 3-D model retrieval and recognition[J]. IEEE Transactions on Multimedia, 2014, 16(8): 2154-2167.
- [5] 佟国峰, 杜宪策, 李勇, 等. 基于切片采样和质心距直方图特征的室外大场景三维点云分类[J]. 中国激光, 2018, 45(10): 1004001.
- [6] Tong G F, Du X C, Li Y, et al. Three-dimensional point cloud classification of large outdoor scenes based on vertical slice sampling and centroid distance histogram[J]. Chinese Journal of Lasers, 2018, 45(10): 1004001.
- [7] Chen M L, Wan Y C, Wang M W, et al. Automatic stem detection in terrestrial laser scanning data with distance-adaptive search radius[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(5): 2968-2979.
- [8] Su H, Maji S, Kalogerakis E, et al. Multi-view convolutional neural networks for 3D shape recognition [C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 945-953.
- [9] Yang Z S, Tan B, Pei H K, et al. Segmentation and

- multi-scale convolutional neural network-based classification of airborne laser scanner data[J]. *Sensors*, 2018, 18(10): 3347.
- [9] 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), September 28-October 2, 2015, Hamburg, Germany. New York: IEEE Press, 2015: 922-928.
- [10] 雷相达, 王宏涛, 赵宗泽. 整合迁移学习与全卷积网络的小样本机载激光雷达点云分类[J]. *中国激光*, 2021, 48(16): 1610001.
Lei X D, Wang H T, Zhao Z Z. Small-sample airborne LiDAR point cloud classification based on transfer learning and fully convolutional network[J]. *Chinese Journal of Lasers*, 2021, 48(16): 1610001.
- [11] 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.
- [12] Qi C R, Yi L, Su H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [C]//NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems, December 4-9, 2017, Long Beach, CA, USA. New York: ACM Press, 2017: 5105-5114.
- [13] Li J X, Chen B M, Lee G H. SO-Net: self-organizing network for point cloud analysis[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: 9397-9406.
- [14] 赵中阳, 程英蕾, 释小松, 等. 基于多尺度特征和 PointNet 的 LiDAR 点云地物分类方法[J]. *激光与光电子学进展*, 2019, 56(5): 052804.
Zhao Z Y, Cheng Y L, Shi X S, et al. Terrain classification of LiDAR point cloud based on multi-scale features and PointNet[J]. *Laser & Optoelectronics Progress*, 2019, 56(5): 052804.
- [15] 闫杰琼, 周末水, 胡少乾, 等. 航空发动机外形点云的特征分割方法[J]. *光学学报*, 2022, 42(7): 0715001.
Yan J Q, Zhou L S, Hu S Q, et al. Feature segmentation method of aero-engine profile point cloud [J]. *Acta Optica Sinica*, 2022, 42(7): 0715001.
- [16] 释小松, 程英蕾, 薛豆豆, 等. 基于 Point-Net 的多源融合点云地物分类方法[J]. *激光与光电子学进展*, 2020, 57(8): 081019.
Shi X S, Cheng Y L, Xue D D, et al. Object classification method for multi-source fusion point clouds based on Point-Net[J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081019.
- [17] 杨建儒, 谭凯, 张卫国, 等. 地面激光雷达点云数据中滩涂湿地禾本科植物的茎叶分离方法[J]. *中国激光*, 2022, 49(13): 1310001.
Yang J R, Tan K, Zhang W G, et al. Stalk and leaf separation for Poaceae in mudflats and wetlands using TLS data[J]. *Chinese Journal of Lasers*, 2022, 49(13): 1310001.
- [18] 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): 146.
- [19] Zhang K G, Hao M, Wang J, et al. Linked dynamic graph CNN: learning on point cloud via linking hierarchical features[EB/OL]. (2019-04-22)[2022-06-15]. <https://arxiv.org/abs/1904.10014>.
- [20] 王江安, 何娇, 庞大为. 基于动态图卷积网络的点云分类和分割网络[J]. *激光与光电子学进展*, 2021, 58(12): 1215008.
Wang J A, He J, Pang D W. Point cloud classification and segmentation network based on dynamic graph convolutional network[J]. *Laser & Optoelectronics Progress*, 2021, 58(12): 1215008.
- [21] 徐田野, 丁海勇. 基于融合图卷积的深度学习点云分类方法[J]. *激光与光电子学进展*, 2022, 59(2): 0228005.
Xu T Y, Ding H Y. Deep learning point cloud classification method based on fusion graph convolution [J]. *Laser & Optoelectronics Progress*, 2022, 59(2): 0228005.
- [22] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [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: 7132-7141.
- [23] Hu Y, Wen G H, Luo M N, et al. Competitive inner-imaging squeeze and excitation for residual network[EB/OL]. (2018-12-23)[2022-06-15]. <https://arxiv.org/abs/1807.08920>.