

DOI:10.19651/j.cnki.emt.2312774

基于边缘卷积的交通锥筒点云数据分割方法^{*}

张政 孙鹏 王立勇 苏清华

(北京信息科技大学 现代测控技术教育部重点实验室 北京 100192)

摘要: 本研究以用于构建临时道路中的交通锥筒为研究目标,以多线激光雷达采集的临时道路三维点云数据为输入,提出一种基于图理论的图神经网络模型,该模型可实现点云数据分割,并提升模型对无序性点云数据学习效果。以无人驾驶方程式赛车为实验平台,针对交通锥筒进行网络训练与测试,实验结果表明,图神经网络模型对交通锥筒的分割准确率达到 88.6%,比 PointNet 模型提升了约 10%,此外,该模型在稀疏雷达点云数据下还具有一定泛化能力,有较好的适用性。

关键词: 图神经网络;点云;场景分割;交通锥筒

中图分类号: TP 391 **文献标识码:** A **国家标准学科分类代码:** 520.20

Segmentation method via point cloud of traffic cones based on edge convolution

Zhang Zheng Sun Peng Wang Liyong Su Qinghua

(MOE Key Laboratory of Modern Measurement and Control Technology, Beijing Information Science & Technology University, Beijing 100192, China)

Abstract: In this study, the traffic cone used to construct the temporary road is taken as the research objective, and the three-dimensional point cloud data of the temporary road collected by multi-line LiDAR is taken as the input. A graph neural network model based on graph theory is proposed, which can realize the segmentation of point cloud data and improve the learning effect of the model on the disordered point cloud data. Take the driverless formula car as the experimental platform, train and test for traffic cone, the experimental results show that the segmentation accuracy of the graph neural network model reaches 88.6%, which is about 10% higher than that of the PointNet model. In addition, the model also has a certain generalization ability under sparse LiDAR point cloud data, and has good applicability.

Keywords: graph neural network; point cloud; scene segmentation; traffic cone

0 引言

随着现代传感器技术的发展,以其为基础的自动驾驶技术也日趋完善^[1-2]。在自动驾驶领域中,较为常用的传感器例如图像传感器、激光雷达(light detecting and ranging, LiDAR)、毫米波雷达(radio detection and ranging, RADAR)等在针对于环境探测任务方面有着各自的优势^[3]。在临时道路、交通事故、道路施工环境下常常会使用到交通锥筒,对于 LiDAR 而言交通锥筒是较小的目标物,更具有挑战性^[4]。

多线束的 LiDAR 传感器可以获取到环境的三维信息,在障碍物监测任务中具有巨大的优势。为了提高系统对未

知环境的理解,可以使用语义分割的手段赋予环境中的障碍物语义信息。目前,激光 SLAM(simultaneous localization and mapping)中的点云语义分割主要分为两种方法:基于特征的方法和深度学习方法。

基于特征的点云处理手段如聚类的方式,将点云信息按照相似程度聚合为不同的点云簇。欧式聚类使用了点与点之间的欧氏距离作为约束进行聚类^[5],但其距离阈值需要手动设置,导致泛化效果较差;同样地,K-means 算法也以欧氏距离作为聚类指标^[6],但缺点是需要手动设置聚类中心个数,且这种算法对高维数据敏感性较差,聚类成功率低;DBSCAN(density based spatial clustering of application with noise)采用基于点云密度的策略进行聚

收稿日期:2023-02-09

^{*} 基金项目:国家“173”计划项目(2021JCQJ0022, MKF20210009)、国家自然科学基金(52175074)项目资助

类^[7],但由于 LiDAR 点云密度不均匀,聚类效果较差,实时性较差。谱聚类方法以图论作为基础,使用点云地图谱信息进行聚类^[8],该方法对于高维信息具有较高的敏感度,聚类效果较好,但由于在聚类过程中使用到 K-means 算法作为核心步骤,也需要手动设置聚类中心个数。传统的聚类算法具有计算速度快等优点,对于简单数据的分割具有较好的效果,但对于高维数据的泛化性较差。

由于深度学习^[9]技术的广泛应用,对于点云数据的处理也逐渐有了突破。这些方法具有从大量数据中提取特征的优点,避免了手工构造特征^[10]带来的不确定性和泛化能力差的缺点。Wan 等^[11]提出了基于投影的 SqueezeSeg 方法,该方法将激光点云沿圆柱面扩展为深度图,并将其转化为二维图像处理。利用 SqueezeNet 及 CNN 对输入图像进行特征提取和分割,优化结果。SqueezeSeg 降低了计算成本,具有较高的实时性,但通过投影点云^[12]不可避免地会出现离散化误差和遮挡造成的空间信息丢失的问题。斯坦福大学的 Qi 等^[13]直接基于点云提出了 PointNet 和 PointNet++^[14]方法。他们通过多层感知器学习单个点云的特征,通过使用旋转变换解决点云数据旋转问题,但只考虑了点云的全局特征。Point2Node 通过在高维图中整合节点与自身、局部和全局节点的关系来提取特征^[15]。SK-Net 联合执行空间关键点的推断和特征的学习,提取局部模式和不同区域之间的相关性^[16]。GS-Net 提取欧几里得空间和特征值空间中的特征,使其能够聚合局部和整体特征^[17]。PointWeb 通过使用点对差异设置局部边缘加权信息丰富点云特征,实现提高特征区分度的效果^[18]。PCCN 对连续卷积进行参数化处理,设计定义在点云上的参数化核函数,使卷积核适应点云的几何特征^[19]。PointConv 将动态过滤模块扩展为类卷积的操作,并构建深度卷积网络实现点云分析^[20]。A-CNN 为解决点云数据无序性,定义了环形区域中点的顺序,并使用环形卷积捕获单个信息点

的局部几何特征^[21]。Shape-OrientedCNN 同时学习底层的局部形状和它们之间的长期依赖关系^[22]。Point2SpatialCapsule 在学习几何特征同时学习局部邻域之间的关系^[23]。这些方法未关注到点云的拓扑结构,并从中提取特征信息。

LiDAR 数据的无序性为其最大特点,即点云矩阵顺序发生改变所表示的含义相同,由于传统的神经网络操作依赖于数据顺序,处理无序性的点云数据效果不佳。

为提升无序点云数据处理能力,本文使用图神经网络(graph neural net, GNN)模型,该模型可以通过神经网络来聚合每个节点及其周围节点的信息,从而更好地应用于对障碍物目标的识别。

第 2 节将对所提出的网络算法进行描述,首先描述整体的框架结构,由于框架中涉及到图论,将在 2.2 节中给出所使用到的定义,在 2.3 节中针对算法中使用的边缘卷积作详细论述。在 3.1 节中将介绍所使用到的实验环境,3.2 节中围绕开源数据集进行了两个网络的对比,3.3 节针对所采集到的实车交通锥筒数据进行训练与结果输出。

1 基于边缘卷积的网络框架介绍

本文网络将雷达原始数据导入后,根据原始点云数据点之间的欧氏距离关系,建立点云簇的邻接矩阵,并获取各子集的边缘及平面点信息,通过图神经网络对特征进行学习,获取特征矩阵,对环境中的交通锥筒进行分割。

1.1 整体框架

为克服点云数据的无序性,本文使用图理论构建神经网络,使用 3 个边缘卷积(edge convolution)层提取目标节点与邻近节点的特征信息,利用图的拓扑结构对点云数据进行学习,其整体框架图如图 1 所示,边缘卷积层的详细结构将在 2.3 节中进行描述,图中 n 为一帧数据包含点个数, p 为分割部分数。




图 1 网络整体框架

将原始三维点云数据作为输入,每个点的特征为其三维坐标信息,通过一层的边缘卷积可以学习到点所在邻域的局部特征信息,使用多层感知机(multilayer perceptron, MLP)将特征信息拓展至高维;之后使用多个边缘卷积层

可以将语义信息拓展至更远处,丰富特征信息;将边缘卷积层获取到的局部信息合并,即可获得点云的全局特征信息,因此使用 MLP 将高维的全局特征转换至低维,最终得到分割结果得分。

1.2 图论数据结构

在图论中,节点与边是两个较为常用的概念。一张图 G 是节点 V 和边 E 的集合,可表示为 $G=(V, E)$,其中节点为具有 F 维信息的点,若 n 为点个数,即可表示为 $V=\{v_1, v_2, v_3, \dots, v_n\} \in R^F$,针对 LiDAR 点云数据,将其中的每一帧点云数据看作是一张图,如图 2 所示,每一个点均为三维点,具有 x, y, z 三个轴的坐标信息,故可以将每一个独立的点看作图中的一个节点。在本文算法中,使用 KNN(K nearest neighbors)算法搜索 k 个邻近点,两个邻近节点之间定义为一条无向边 $E=\{E_1, E_2, E_3, \dots, E_m\}$,其中 m 为边的个数。




图 2 图结构示意图

KNN 算法是常用的机器学习算法之一,通过测量不同特征值之间的距离来进行分类。首先根据点云索引号取出图 G 中两点 $A(x_1, y_1, z_1), B(x_2, y_2, z_2)$,计算两点之间的欧氏距离 d ,同理计算点 A 与图 G 中其他点的距离并排序,找出 k 个距离最近的点作为 A 的邻近节点,建立无向边。

1.3 边缘卷积

边缘卷积是本文算法的核心方法,其作用是提取图 G 中节点的全局特征,包含两大步骤,首先根据 KNN 算法得到的图结构计算出该图的边特征,之后使用池化方法将边特征聚合,得到图中节点的全局特征,边缘卷积结构框图如图 3 所示。




图 3 边缘卷积结构图

图中, n 为输入点的个数, f 为输入点的特征数, k 为邻近节点个数, a 为经过多层感知机后特征个数。具体而言,定义 e_{ij} 为边特征,表达式如式(1)所示。

$$e_{ij} = h_{\theta, \mu}(v_i, v_j) = h_{\theta, \mu}(v_i, v_j - v_i) \quad (1)$$

式中: $h_{\theta, \mu}$ 为一个以 θ 和 μ 为可学习参数的非线性函数, v_i 和 v_j 为同一条边连接的两个节点, $v_j - v_i$ 表示两节点之间的相对特征,该操作将节点的局部信息和全局信息相融合,弥补了 PointNet 等算法缺乏局部信息的不足。得到节点每一条边的特征信息后,使用池化操作对其进行特征聚合,常用的池化操作为最大池化和平均池化,本文方法采用最大池化进行特征聚合,如式(2)所示。

$$v'_{im} = \max_{j: (i,j) \in \Omega} \text{ReLU}(h_{\theta, \mu}(v_i, v_i - v_j)) = \max_{j: (i,j) \in \Omega} \text{ReLU}(\theta_m \cdot (v_i - v_j) + \mu_m \cdot v_i) \quad (2)$$

其中, v'_{im} 表示索引号为 i 的节点 m 维特征, Ω 为节点 i 的临近节点集合, ReLU 为激活函数, θ_m 和 μ_m 为可学习参数。

2 实验及结果

2.1 实验环境介绍

为验证算法可行性,首先在 S3DIS (stanford large-scale 3D indoor spaces dataset)数据集进行训练测试,验证网络的可行性。S3DIS 是斯坦福大学提供的大场景室内 3D 点云数据集,包含 6 个教学和办公区域,总共有 695 878 620 个带有色彩信息以及语义标签的 3D 点,场景图如图 4 所示。

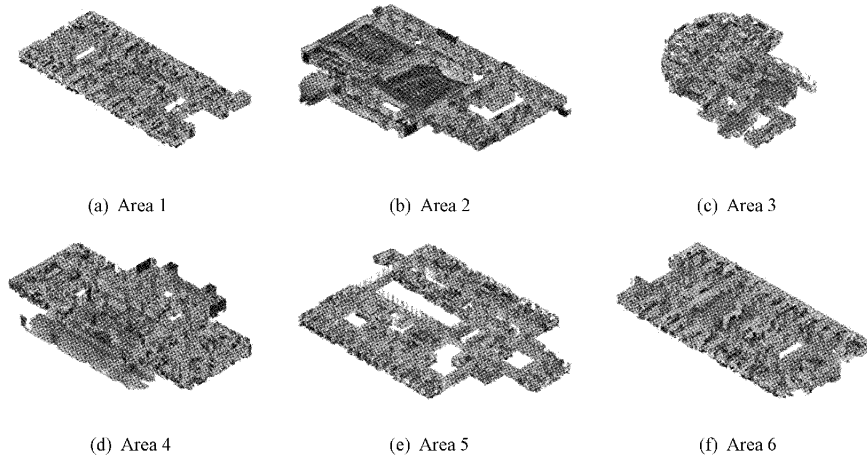


图 4 S3DIS 数据集

在此基础上,本文将网络应用于室外无人驾驶场景中,硬件平台为北京信息科技大学 MCT 无人方程式赛车,如图 5 所示。车上搭载速腾聚创公司的 Robosense-32 线激光

雷达。结合赛车机械结构以及方程式大赛中所使用的交通锥筒的高度特征,经过多次实际试验的调整最终确定 LiDAR 的安装高度为 0.15 m,可使 LiDAR 检测效果达到最

佳。软件系统使用 Ubuntu18.04 系统,采用机器人操作系统(robotic operating system, ROS)^[24]为基础实现功能节点通信,使用开源机器学习框架 Pytorch 对网络进行训练。




图5 无人方程式赛车平台

大赛中使用红、黄、蓝三色交通锥筒搭建赛道,交通锥筒长 20 cm,宽 20 cm,高 28 cm。为实现在比赛场景下的锥筒分割,使用上述赛车系统对场景数据进行训练,训练结果将在 3.3 节中进行讨论。

2.2 实验结果分析

使用 S3DIS 数据集对本文网络进行训练,使用随机下采样分别设置单帧采样点个数为 256 点,512 点和 1 024 点进行 50 个回合训练,其中 10% 的数据作为测试集,结果如图 6 所示,图中结果可知经过 50 回合训练准确率可高于 80%,且当采样点个数越多时,其分割准确率越高。






图6 不同采样点个数网络训练对比

使用相同数据集,设置单帧采样点个数为 256 和 1 024,分别对本文网络及 PointNet 进行训练,结果如图 7 所示,结果对比如表 1 所示。



(a) 1 024个采样点



(b) 256个采样点

图7 两种网络训练对比

表1 网络结果对比表

	点数	平均准确率/%
PointNet	1 024	72.2
	256	5.2
本文算法	1 024	88.6
	256	82.3

由表 1 可知,使用本文网络在相同条件下比 PointNet 准确率高约 10%,当降低采样点个数后,PointNet 失效,本文网络准确率高于 80%。

以 Area 1 中的会议室场景为例,使用两种网络分别对该数据集进行分割,可视化结果如图 8 所示,其中 PointNet 中圆圈内为分割错误点云。因此,本文提出的图神经网络模型可行。




图8 室内场景分割

本文使用均交并比(mean intersection over union, MIoU)和时间对比 PointNet 与本文算法的分割效果与算法耗时,MIoU 是语义分割的标准度量,计算所有类别交集和并集之比的平均值。结果如表 2 所示,分析可得在 MIoU 层面本文算法与 PointNet 相比提高了约 1 倍。

表2 网络分割效果及耗时对比

	MIoU/%	平均时间/ms
PointNet	20.3	7.2
本文算法	55.9	29.5

2.3 实车数据分析

实车数据集使用 LiDAR 采集到的不同场景下的交通锥筒数据集共 400 帧数据,其中 360 帧作为训练集,40 帧作为测试集,超参数 k 设置为 10。

由于实车状态下的感知场景较大,一帧数据中包含点云数量过多,导致算力资源需求冗余,故先使用距离阈值控制采样距离,减少过远处点云参与运算,再使用 PCL (point cloud library) 进行点云随机下采样,使采样点数为 n , n 为网络输入点个数,采样前后对比如图 9 所示。

之后,对点云中的数据点进行标记,分为交通锥筒和其它,并输入网络中进行训练,训练集和验证集的平均准确率和损失值如图 10 所示,蓝色曲线为训练集结果,红色曲线为测试集结果。

可视化的点云分割结果如图 11 所示,其中图 11(a)为分割前的点云结果,图 11(b)为分割后滤除其他点后的交

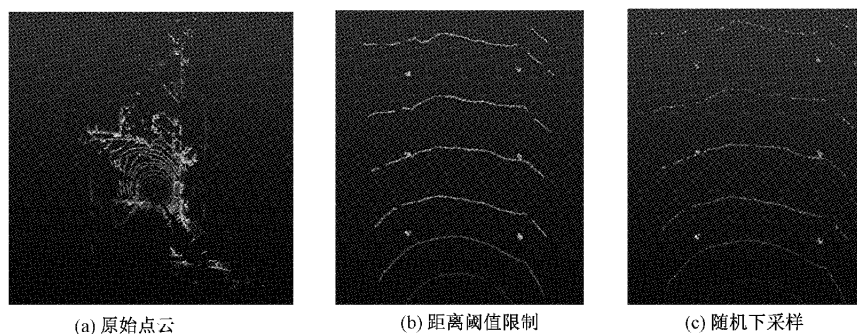


图 9 点云数据预处理




图 10 交通锥筒数据集结果




图 11 分割结果可视化

通锥筒数据点,不难看出本文方法可以成功将场景中包含的交通锥筒分割出来。

3 结 论

为克服 PointNet 中缺乏局部信息的不足,本文基于图神经网络,使用边缘卷积理论,在图论的基础上解决 LiDAR 三维点云无序性的问题,并使用开源数据集和交通锥筒数据集进行验证。实验证明,该方法相较于 PointNet 对于环境的分割有更高的准确性,准确率提升了 10%,并且在采样点个数较少的情况下仍具有鲁棒性。

参考文献

[1] 余联想,郑明魁,欧文君,等. 多传感器融合的移动机器人室外激光 SLAM 算法优化与系统实现[J/OL]. 电子测量与仪器学报: 1-9[2023-04-10]. <http://kns.cnki.net/kcms/detail/11.2488.tn.20230130.1232.002.html>.

[2] 陈昌川,全锐杨,张谦,等. 基于轻量化智能的多机协同 SLAM 系统[J]. 仪器仪表学报, 2022, 43(12): 188-198. DOI:10.19650/j.cnki.cjsi.J2209711.

[3] RAVINDRAN R, SANTORA M J, JAMALI M M. Multi-object detection and tracking, based on DNN, for autonomous vehicles: A review[J]. IEEE Sensors Journal, 2021, 21(5): 5668-5677.

[4] 杨颖,王立勇,孙鹏,等. 基于激光雷达与相机融合的交通锥筒检测[J]. 激光杂志, 2022, 43(6): 70-74.

[5] 张煌,王国权,孙鹏. 基于信息融合的目标检测系统研究[J]. 电子测量技术, 2021, 44(19): 28-35.

[6] CHOKNIWAL A, SINGH M. Faster Mahalanobis K-means clustering for Gaussian distributions [C]. International Conference on Advances In Computing, Communications and Informatics (Icacci). Jaipur, India; IEEE, 2016: 947-952.

[7] 陈广胜,程逸群,景维鹏. 基于 KD 树划分的云计算 DBSCAN 优化算法[J]. 计算机工程, 2017, 43(4): 21-27.

[8] 王伟伟,庞勇,杜黎明,等. 超体素约简和谱聚类结合的机载 LiDAR 点云单木分割[J]. 遥感学报, 2022, 26(8): 1650-1661.

[9] 王丽欢,任雨,刘建,等. 基于 B-PointNet++ 的地下电缆工井点云语义分割模型[J]. 国外电子测量技术, 2023, 42(2): 88-94.

[10] 王文曦,李乐林. 深度学习在点云分类中的研究综述[J]. 计算机工程与应用, 2022, 58(1): 26-40.

- [11] WAN A, YUE X, KEUTZER K, et al. SqueezeSeg: Convolutional neural nets with recurrent CRF for real-time road-object segmentation from 3d LiDAR point cloud[C]. International Conference on Robotics And Automation (ICRA). Prague, Czech Republic; IEEE, 2018: 1887-1893.
- [12] 王涛, 王文举, 蔡宇. 基于深度学习的三维点云语义分割方法研究[J]. 计算机工程与应用, 2021, 57(23): 18-26.
- [13] QI C R, SU H, KAICHUN M, et al. Pointnet: Deep learning on point sets for 3D classification and segmentation[C]. Conference on Computer Vision And Pattern Recognition (CVPR). Honolulu, USA; IEEE, 2017: 77-85.
- [14] QI C R, LI Y, HAO S, et al. Pointnet plus plus: Deep hierarchical feature learning on point sets in a metric space [C]. Annual Conference on Neural Information Processing Systems(NIPS). Long Beach, USA; NIPS, 2017: 5100-5109.
- [15] HAN W, WEN C, WANG C, et al. Point2node: Correlation learning of dynamic-node for point cloud feature modeling [C]. Proceedings of the AAAI Conference on Artificial Intelligence; volume 34, 2020; 10925-10932.
- [16] WU W, ZHANG Y, WANG D, et al. SK-Net: Deep learning on point cloud via end-to-end discovery of spatial keypoints [C]. Proceedings of the AAAI Conference on Artificial Intelligence; volume 34, 2020; 6422-6429.
- [17] XU M, ZHOU Z, QIAO Y. Geometry sharing network for 3d point cloud classification and segmentation [C]. Proceedings of the AAAI Conference on Artificial Intelligence; volume 34, 2020; 12500-12507.
- [18] ZHAO H, JIANG L, FU C W, et al. Pointweb: Enhancing local neighborhood features for point cloud processing [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 5565-5573.
- [19] WANG S, SUO S, MA W C, et al. Deep parametric continuous convolutional neural networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 2589-2597.
- [20] WU W, QI Z, FUXIN L. Pointconv: Deep convolutional networks on 3d point clouds [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9621-9630.
- [21] KOMARICHEV A, ZHONG Z, HUA J. A-cnn: Annularly convolutional neural networks on point clouds[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 7421-7430.
- [22] ZHANG C, SONG Y, YAO L, et al. Shape-oriented convolution neural network for point cloud analysis [C]. Proceedings of the AAAI Conference on Artificial Intelligence; volume 34, 2020; 12773-12780.
- [23] WEN X, HAN Z, LIU X, et al. Point2 Spatial Capsule: Aggregating features and spatial relationships of local regions on point clouds using spatial-aware capsules [J]. IEEE Transactions on Image Processing, 2020, 29: 8855-8869.
- [24] 贾鹏飞, 王容川, 徐林森, 等. 基于 ROS 和 CANOPEN 协议的控制器实时通信系统构建[J]. 中国科学技术大学学报, 2018, 48(9): 703-710.

作者简介

张政, 硕士研究生, 主要研究方向为激光雷达三维地图构建研究。

E-mail: jidazhangzheng@163.com

孙鹏(通信作者), 副研究员, 硕士生导师, 主要研究方向为视觉测量与无人车技术。

E-mail: sunpeng@bistu.edu.cn