



3D点云数据处理方法研究进展

郭张翔, 闫天红, 周国强

引用本文

郭张翔, 闫天红, 周国强. 3D点云数据处理方法研究进展[J]. 计算机科学, 2024, 51(11A): 240100132-13.

GUO Zhangxiang, YAN Tianhong, ZHOU Guoqiang. [Research Progress of 3D Point Cloud Data Processing Methods](#) [J]. Computer Science, 2024, 51(11A): 240100132-13.

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)

[基于多模态融合的动态恶意软件检测方法](#)

Multimodal Fusion Based Dynamic Malware Detection

计算机科学, 2024, 51(11A): 240200098-7. <https://doi.org/10.11896/jsjcx.240200098>

[基于开放集的入侵检测方法研究](#)

Study on Open Set Based Intrusion Detection Method

计算机科学, 2024, 51(11A): 231000033-6. <https://doi.org/10.11896/jsjcx.231000033>

[基于CNN结合BiGRU的恶意流量分类算法研究](#)

Study on Malicious Traffic Classification Algorithm Based on CNN Combined with BiGRU

计算机科学, 2024, 51(11A): 231100106-9. <https://doi.org/10.11896/jsjcx.231100106>

[基于深度学习智能反射面辅助通信系统的联合波束成形](#)

Deep Learning Based Joint Beamforming in Intelligent Reflecting Surface Enhanced Wireless Communication Systems

计算机科学, 2024, 51(11A): 231200125-5. <https://doi.org/10.11896/jsjcx.231200125>

[基于因果关系的领域泛化长尾学习](#)

Domain Generalization and Long-tailed Learning Based on Causal Relationships

计算机科学, 2024, 51(11A): 240300041-8. <https://doi.org/10.11896/jsjcx.240300041>

3D 点云数据处理方法研究进展

郭张翔 闫天红 周国强

东北石油大学三亚海洋油气研究院 海南 三亚 572000

东北石油大学机械科学与工程学院 黑龙江 大庆 163000

(guozhangxiang0329@163.com)

摘要 点云是理解三维场景的重要形式之一,3D点云在海洋平台逆向建模、海底地形测绘、深水浮式结构系泊系统损伤测量及海底管线可视化等方面都有着重要应用。基于此,文中梳理了点云数据处理方法,将其分为传统处理算法和基于深度学习方法两大类;传统处理算法从滤波、对象识别与分类和配准3方面进行了介绍总结;基于深度学习方法从点云、体素化和多视图3方面进行了介绍总结。对各种算法的优缺点进行了归纳对比,并展望了3D点云处理技术未来的发展趋势与方向。

关键词:3D点云;数据处理;传统方法;深度学习

中图分类号 TP751.1

Research Progress of 3D Point Cloud Data Processing Methods

GUO Zhangxiang, YAN Tianhong and ZHOU Guoqiang

Sanya Institute of Offshore Oil and Gas, Northeast Petroleum University, Sanya, Hainan 572000, China

College of Mechanical Science and Engineering, Northeast Petroleum University, Daqing, Heilongjiang 163000, China

Abstract Point cloud is one of the important forms to understand 3D scenes, and 3D point cloud has important applications in reverse modeling of offshore platforms, seabed topography mapping, damage measurement of mooring systems of deep-water floating structures, and visualization of submarine pipelines. Based on this, this paper sorts out the point cloud data processing methods and divides them into two categories: traditional processing algorithms and deep learning-based methods. The traditional processing algorithms are introduced and summarized from three aspects: filtering, object recognition, classification and registration. Based on the deep learning method, it is introduced and summarized from three aspects: point cloud, voxelization and multi-view. The advantages and disadvantages of various algorithms are summarized and compared, and the future development trend and direction of 3D point cloud processing technology are prospected.

Keywords 3D point clouds, Data processing, Traditional methods, Deep learning

目前,随着各种3D设备(RGB-D相机和LiDAR传感器)的广泛使用,研究人员可以轻松地获得需要的3D点云数据,因此对于点云数据的处理方法也随之不断更新迭代,随着方法的进步,我们对点云的理解也有着显著的进步。近年来,3D点云在海洋平台逆向建模^[1]、海底地形测绘^[2]、海洋石油导管架平台损伤测量^[3]和油井、管线可视化^[4]等领域有着诸多应用。相比2D数据,3D数据有不可比拟的优势,3D数据可以提供目标物丰富的几何形状和尺度信息,同时在获取信息时不易受到环境物体的遮挡以及光照强度变化等影响。点云是3D数据的重要表征格式之一,由于3D点云数据本身复杂性高、点稀疏度变化大、噪声繁多、标注过程中3D视图变化频繁等原因,处理3D点云耗时费力。一方面,如何从无序和不均匀的点云中提取需要的信息是处理点云的一个难题,另一方面,如何将3D数据应用到现实工程中更是理解点云

的另一个重大难题。

点云处理一般包含点云滤波、点云分割、特征提取、对象识别和分类以及点云配准等,传统的点云处理方法过于依赖人工,人力成本高,计算量大,效率也低。随着机器学习和深度学习的发展,点云处理进入快速度、低成本和高效率的阶段,尽管深度学习在点云处理方面取得了巨大的进步,但现有处理点云数据的学习方法对注释良好的数据集有着很强的依赖性。本文对传统的点云处理方法以及深度学习在点云处理方面的最新进展做了详细的整理。

本文第1章介绍了当前公开的点云数据集、相关定量评估指标和重要应用;第2、3章分别介绍了3D点云经典传统处理方法以及基于深度学习处理方法;最后从归纳的各种方法出发,分析了点云处理算法存在的不足,同时给出了可能的解决办法以及算法未来发展方向。

基金项目:海南省院士创新平台科研项目(YSPTZX202301);2022年三亚市科技创新专项(2022KJCX52)

This work was supported by the Specific Research Fund of the Innovation Platform for Academicians of Hainan Province(YSPTZX202301) and 2022 Sanya Science and Technology Innovation Project(2022KJCX52).

通信作者:闫天红(yantianhong82@126.com)

1 数据集及评价指标

随着获取的数据多样性的增加及复杂化程度的加深,建立相应数据集显得尤为重要:1)一个综合性好的数据集可以同时用于不同数据处理方法的验证和评估;2)多样稳定的数据集可以用来比较相同数据处理方法对不同数据处理的鲁棒性;3)多样数据集的建立可以推动3D点云在相关领域的发展,促进数据处理方法的不断创新。

1.1 数据集

为了促进对获取的3D点云处理方法的研究,部分机构公开了一些通过手动标记分类好的基准数据集,用于验证点云处理算法的准确性以及算法训练。公开的不同类型数据集如表1所列。

表1 已公开的不同类型数据集

Table 1 Publicly available datasets of different types

数据集	年份	应用场景	类别
ObjectNN	2017	室内场景	20
ModelNet	2015	物体部件	660
Paris-Lille-3D	2018	城市街道	50
Semantic3D	2017	城市街道	8
SemanticKITTI	2019	户外场景	25
S3DIS	2017	室内场景	13
Campus3D	2020	户外场景	24
Paris-CARLA-3D	2021	户外场景	23
Building3D	2023	城市街道	—

ObjectNN^[5]是用于基准测试RGB-D对象到CAD模型检索的研究数据集,该数据集在SceneNN^[6]数据集基础上收集了CAD模型,SceneNN是计算机视觉的RGB-D数据集,该数据集由100个真实的场景组成,提供了网格和颜色纹理数据,对所有场景的2D和3D图像都进行了逐顶点和逐像素的分割与注释,同时标注了场景中的所有对象,丰富了数据细粒度信息,如轴对齐边界框、方向边界框以及对对象姿态等。数据集获取地址为<https://hkust-vgd.github.io/scenenn/>。

ModelNet^[7]是一个三维计算机图形CAD模型的大规模对象数据集。该数据集通过搜索261个CAD模型网站下载了660个类别,每个类别不少于20个对象的常见模型,手动对这些模型进行注释,得到15万个带注释的CAD模型。该数据集可以用于通过输入三维物体的几何形状来识别物体所属的类别,一般用于同一场景识别不同目标物体的形状及类别。数据集获取地址为<https://3dshapenets.cs.princeton.edu/>。

Paris-Lille-3D^[8]是一个对城市三维点云自动分割和分类的数据集,该数据集对1.4亿个点进行手动分割,对其中50个类做出标记,该数据集包含了树木、建筑物等对象的标签数据,不同区域树木点云的特征相似,数据可重用,一般

可以用来训练对象的检测和分割。数据集获取地址为<https://npm3d.fr/paris-lille-3d>。

Semantic3D^[9]数据集是迄今为止,最大的地面激光扫描3D点云户外场景分割数据集,该数据集共包含8个类别的语义标签,囊括了丰富的户外场景,包括村庄、街道、足球场、广场、铁路等,目前该数据集大约有超过40亿个手工标记的点¹⁾。

SemanticKITTI^[10]数据集是基于KITTI Odometry Benchmark的里程数据集,该数据集展现了德国Karlsruhe周围的城市交通、居民区以及高速公路和农村道路场景。原始测量的数据集由22个序列组成,将序列00至10分割作为训练集,将11至21作为测试集。该数据集共包含28个类别,在注释数据过程中使用定位与地图构建系统进行闭环检测和点云的配准与重建,确保地图的一致性。数据集获取地址为<http://www.semantic-kitti.org/>。

S3DIS (Stanford Large-Scale 3D Indoor Spaces Dataset)^[11]数据集是由斯坦福大学计算机科学系研究人员发布的一个大规模室内场景点云数据集,该数据集包含约90多个室内场景,这些场景包含13个类别,超过2.15亿个点,涵盖了多种类型的环境,例如办公室、会议室、厨房和浴室等,每个场景都通过Matterport激光扫描仪获取了大量的三维点云数据,并配备了与之相关的语义标签。数据集获取地址为<http://3dsemantics.stanford.edu/>。

Campus3D^[12]数据集是在新加坡国立大学(NUS)校园1.58km²区域的无人机图像中构建的摄影点云数据集。在构建标签树的基础上,使用分层标注和实例标签对点进行详细的注释,对城市模型的建筑以及其他户外精细结构物的标注更加精细化。该数据集包含9.4亿个点,2530个情景实例和24个类别。数据集获取地址为<https://3d.dataset.site>。

Paris-CARLA-3D^[13]数据集是由移动LiDAR和摄像系统构建的户外环境密集彩色点云数据集。该数据集由两部分组成,一部分是由激光雷达和摄像系统生成的真实点云(6000万点),另一部分由开源CARLA模拟器合成数据(7亿点)。该数据集通过自动注释,将语义分为23类,并通过在图像上的投影对数据进行着色。数据集获取地址为<https://npm3d.fr/paris-carla-3d>。

Building3D^[14]是一个城市尺度的数据集,该数据集涵盖了爱沙尼亚16个城市,包括8.7亿个空中激光雷达点云和16万个建筑物以及相应的点云、网格和线框格式模型,同时还允许监督与自监督学习方法对数据集的评价²⁾。

1.2 评价指标

目前提出了许多定量评估指标,使得对比不同算法对点云数据的分类性能与分割性能时可以更加公平。评价指标一般包括准确性(Accuracy, Acc)、交并比(Intersection over Union, IoU)、F1分数、总体准确度(Overall Accuracy, OA)、平均精确率(Average Precision, AP)等,计算方法如表2所列。这些定量评价指标都与真阳性(TP)、真阴性(TN)、假阳性(FP)和假阴性(FN)的值相关,相关定义如表3所列,部分方法在数据集集中的验证结果如表4所列。

¹⁾ <https://semantic3d.net/>

²⁾ <http://building3d.ualgaly.ca/>

表2 常用评价指标

Table 2 Common evaluation indicators

评价指标	计算公式
Acc	$accuracy = \frac{TP+TN}{TP+TN+FP+FN}$
mAcc	$mAcc = \frac{1}{C+1} \sum_{i=0}^n accuracy$
IoU	$IoU = \frac{TP}{TP+FN+FP}$
mIoU	$mIoU = \frac{1}{C+1} \sum_{i=0}^n IoU$
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	$mAP = \frac{1}{C} \sum_{i=1}^C AP_C$
F1	$F1 = \frac{2TP}{2TP+FN+FP}$
Precision	$Precision = \frac{TP}{TP+FP}$
Recall	$Recall = \frac{TP}{TP+FN}$

表3 真阳性(TP)、真阴性(TN)、假阳性(FP)和假阴性(FN)的定义

Table 3 Definitions of true positive(TP), true negative(TN), false positive(FP) and false negative(FN)

TP(True Positives)	真正例,预测为正例而且实际上也是正例
FP(False Positives)	假正例,预测为正例然而实际上却是负例
FN(False Negatives)	假负例,预测为负例然而实际上却是正例
TN(True Negatives)	真负例,预测为负例而且实际上也是负例

表4 部分方法在数据集中的验证

Table 4 Validation of some methods in the data set

数据集	算法	mAP	Precision	Recall	OA	Acc	mIoU
Object-NN	3DCN-N	74.9	76.9	76.9	—	—	—
	MVCN-N	71.0	72.7	72.7	—	—	—
	CDTN-N	64.9	67.2	67.2	—	—	—
Model-Net	MVCN-N	79.5	—	—	—	90.1	—
	PointNet	—	—	—	—	89.2	—
	PVNet	89.5	—	—	—	93.2	—
Paris-Lille-3D	ConvP-oint	—	—	—	—	—	75.9
	RandL-A-Net	—	—	—	—	—	78.5
	KP-FC-NN	—	—	—	—	—	82.0
Semant3D	3DNet	—	—	—	93.8	—	73.2
	SnapNet	—	—	—	91.0	—	67.4
	RandL-A-Net	—	—	—	94.8	—	77.4
Semant3D KITTI	PointNet++	—	—	—	—	—	20.1
	PointNet	—	—	—	—	—	14.6
	RandL-A-Net	—	—	—	—	—	53.9
S3DIS	PointNet	—	—	—	78.6	—	47.6
	PointNet++	—	—	—	81.0	—	54.5
	PointC-NN	—	—	—	88.1	—	65.4
	DGCN-N	—	—	—	84.1	—	56.1
	RandL-A-Net	—	—	—	88.0	—	70.0
Build3D	PintNet++	—	84.0	33.0	—	—	—
	DGCN-N	—	81.0	30.0	—	—	—
	PointNet	—	81.0	26.0	—	—	—
	RandL-A-Net	—	67.0	16.0	—	—	—

1.3 典型应用

Yang等^[15]将图像融合引入到点云三维目标重建中,丰富了获取目标物的层次和细节,有效加强了数据获取信息的质量,提高了获取高质量点云的数量,但是该方法要求输入的图像集合满足在空间位置中的领域关系,面片模型的生成要参考空间法向量,满足一定阈值才能成功获取。Ding等^[16]根据线结构光法重建深海三维地貌,将获得的点云结合传感器

数据,计算探测器坐标偏移量,通过位姿变化调整图像最终获得三维地貌点云数据,该方法重建的地貌精度达到96.9%。Liu等^[3]通过点云处理得到海洋石油导管架三维模型,并根据激光点云的分布判定损伤区域,对损伤区域进行拼接处理可以测量损伤尺寸表征数据,但是深海中激光扫描易受水体、光线、表面材料和设备等因素影响,难以稳定获取高质量点云,且测量精度较差,适用于大区域损伤测量。Wu^[4]通过点云数据的拼接、坐标转换和建模,实现了海上钻井平台三维模型的搭建,对于平台上复杂管线、水罐、油罐和各种分离器形状规则的设备,通过点云直接拟合得到,实现了三维可视化,但是形状不规则的表面模型只能使用二维画线方法人工介入构建模型,且对于测站的性能要求较高,整体建模自动化水平有待提升,模型建立流畅度不高。

2 传统处理方法

点云数据一般是由激光雷达等3D扫描设备获取的空间若干点,包括XYZ位置信息、RGB颜色信息和强度信息等,因此是一种多维度复杂数据的集合。点云数据处理有很多方面,本文主要对主流经典的点云处理方法进行梳理。这些主流经典的3D点云处理方法都具有各自的优势和不足。传统点云处理方法一般对人工依赖较多,处理过程操作繁琐,工作效率较低且容易出现错误。

2.1 点云滤波

点云滤波的主要目的是将目标物点云与背景噪声点云分离,传统的点云滤波方法有基于数学形态滤波算法(Mathematical Morphology, MM)^[17]、基于坡度的点云滤波算法^[18-19]、基于曲面拟合的滤波算法^[20]、基于自适应三角不规则网的滤波算法(Triangulated Irregular Network, TIN)^[21]、基于分割的滤波算法^[22]和基于迭代线性最小二乘插值滤波算法等。

数学形态学(MM)主要是通过腐蚀(去除不必要的部分,简化物体形状)和膨胀(在原有基础上增加物体体积)或者二者相结合的方式产生开(先腐蚀后膨胀)、闭(先膨胀后腐蚀)操作,使得目标物体的骨架更为突出。Zhang等^[23]在此基础上提出了渐进式形态学滤波算法(Progressive Morphological, PM),通过逐渐增加过滤器的窗口大小并使用高程差阈值,来删除车辆、植被和建筑物的数据,同时保留地面数据。Balado等^[17]提出的数学形态滤波不需要将点云转换为点表面、体积物体、2D或3D网格,可以直接处理原始点云,从而显著提升局部案例的研究效率。

基于坡度的点云滤波算法通过利用地面点之间的高度差来确定最优滤波函数。该算法的基本思想是基于这样一种观察,即相邻两点之间的较大高差不一定是由地形的陡坡造成,还有可能是因为位置较高的点不是接地点。显然,对于预先设定的高差阈值,如果两点之间的距离减小,较高的点是接地点的概率就会减小。Wan等^[18]通过引入简单的地形起伏指数(TRI)转化为与地面滤波相关的各种重要参数,自动调整地面滤波算法的坡度相关参数,从而减少滤波器的工作量。

基于曲面拟合的滤波算法是通过6个移动窗口寻找每个移动窗口的最低点,从而计算出一个粗略的拟合曲面,然后判断这些窗口中的点与拟合曲面的高程差,再根据给定的阈值剔除超出阈值的高程差的点,从而得到地面点。Diao等^[24]提

出的改进移动窗口曲面拟合法可以自适应地调整网格尺寸大小,解决了滤波时难以确定高差阈值的问题。Sun 等^[25]提出的多级移动曲面拟合滤波算法,通过建立区域格网索引,设置自适应阈值,解决了粗点、差点以及阈值自动设置等问题。Zhu 等^[20]提出了多级移动曲面拟合的自适应阈值点云滤波算法。该算法增加了格网邻域并实现了格网大小、邻域大小和阈值的自动设置,有效提高了滤波效率,降低了滤波误差,提高了算法的自适应性。

基于自适应三角不规则网的滤波算法是一种迭代算法,其主要思想是通过局部随机分布初始种子点构成三角形网,用三角形网表示地面开始遍历其他点,根据随机点距离三角形最近顶点的高度夹角和垂距是否满足给定的阈值来判断该点是否为地面点。如果是地面点,则加密 TIN 模型,依次迭代直到没有新的地面点为止。其中的两个阈值参数指:到 TIN 表面的距离和到节点的角度,这两个阈值参数是依据滤波过程中数据和变化估计的。Sohn 等^[26]通过建立 TIN 四面体,以最小描述长度为判断准则,不断向上和向下加密 TIN 来提取地面点 Haugerud^[27],直接用原始点云数据建立 TIN 模型,然后通过 TIN 模型计算地形曲率参数,认为曲率急剧变化的点为非地面点。Sui 等^[28]提出了一种基于渐进三角网的机载 LiDAR 点云数据滤波方法。该算法结合了规则格网和不规则三角网处理点云数据,通过对整体区域进行分块,在每个区块内选取区域内最低点,以这类最低点为种子地面点建立初始 TIN 模型,进而对 TIN 内的点按照高程进行排序,

然后用渐进加密三角网进行地面点的提取。

基于分割的滤波算法不是在局部区域对点进行分类,而是直接将原始点云分割成小块,其中所有的点都可以通过平滑路径连接起来,再根据这些小块之间的拓扑关系进行分类(Sithole 等^[22])。Hu 等^[29]根据地形连续性对点集进行分割,删除少数粗、差点集后,对分割的点集建立缓冲区来区分地面点集和非地面点集,通过迭代过程可以删除体积较大的地物点集,再利用约束平面的方法去除地面点集中残留的小地物,最终完成整个滤波过程。

Pfeifer 等^[30]描述了一种基于迭代线性最小二乘插值的滤波方法,该方法基于线性预测^[31],每个测量单元都单独工作,也是一种迭代算法。利用将低权重赋给相对较高点的权重函数,获得了对地面的鲁棒估计,权重函数由 4 个参数描述。Liu 等^[32]基于此先根据所有数据计算得到一个趋势面,再对地面数据进行分层、滤波,减少了计算量,用分步原则过滤掉房屋点得到精化地面,利用多次回波数据剔除部分非地面点。

基于布料仿真的点云滤波方法(Cloth Simulation Filter, CSF)^[33]是对原始点云直接处理的一种方法,该方法通过将原始点云倒置,输入几个易于设置的整数和布尔参数,在倒置的表面覆盖上刚性布,然后分析布节点与相应点云之间的相互作用来确定布节点的位置,从而生成地面点的近似值,最后比较原始点云和生成的表面,再从原始点云中提取地面点。表 5 列出了上述方法的总结。

表 5 滤波算法
Table 5 Filtering algorithm

方法分类	优点	缺点
基于数学形态滤波	不需要将点云转换为二维或者三维图像;易于实现、速度快;准确率高	需要预先了解问题和输入点云;过滤窗口大小难以调整至最优
基于坡度的点云滤波	计算效率高	坡度变化较大的地区会产生较大的遗漏和误差;需要人工干预输入相关的阈值信息
基于曲面拟合滤波	适用于多种类型的地物;具有较强剔除噪声能力	种子点选择依赖于人工
基于自适应三角不规则网的滤波	只有两个重要阈值参数,操作简单	难以检测不连续地形
基于分割的滤波	可直接对原始点云进行处理,允许使用更多的背景信息;分割大型建筑点云性能可靠	斜坡地形难以检测;参数设置需要人工提前了解地形平滑度
基于迭代线性最小二乘插值滤波	平坦地形检测快速准确	在坡度和地形差异性大的地方结果不太可靠
基于布料仿真的点云滤波	使用参数少、易于理解;可直接用于原始点云数据	参数设置具有一定的主观性;难以处理特定的点云

2.2 对象识别和分类

目前广泛用于对象识别和分类的一般方法包括:霍夫变换、随机采样一致性(RANSAC)、主成分分析(PCA)、快速点特征直方图(FPFH)、区域增长、连通域、图分割和超体素化等。

3D 霍夫变换是 2D 霍夫变换的扩展,用于检测图像中的线条(1962 年),经典的霍夫变换最常用于检测规则曲线,之后由 Richard Duda & Peter Hart 推广使用到形状物体的识别,多为圆和椭圆。Ballard^[34]通过构建图像空间和霍夫变换空间之间的映射,使得霍夫变换成为一种通用变换,可以用于查找任意复杂的形状。Vosselman 等^[35]将霍夫变换扩展到从激光雷达点云数据中提取 3D 形状,3D 霍夫变换的结果可以直接用于对几何原型的场景建模。

随机采样一致性算法(RANSAC)是一种迭代方法,该方法于 1981 年由 Fischler 等^[36]首次提出,他们用 RANSAC 解

决空间中点的位置确定问题(LDP),即对一组已知位置地标的投影点图像,确定投影点图像的位置地标是从空间中的哪个点得到。RANSAC 用于从一组包含异常值的观测数据中估计数学模型的参数,此时异常值对估计值没有影响。因此,该算法是一种异常值检测算法和非确定性算法,仅以一定概率产生合理的结果,此概率会随着迭代次数的增加而增加。RANSAC 通常对异常值和噪声具有鲁棒性,因此根据该方法的基本概念衍生出许多特征提取、分割和建模的方法。Schnabel 等^[37]基于 RANSAC 提出了一种自动算法,用于检测一组不规则点云中所涉及的基本几何形状,如球体、圆柱体和圆环等。

主成分分析算法(PCA)是一种数据分析技术,广泛用于点云数据的特征提取^[38]。该方法使用了降维的思想,将多个信息点转化为一个综合信息点,在保留少信息的前提下,又能

反映整体数据的主要信息。这些综合信息点被称为主成分,每个主成分是原始变量的线性组合,并且各主成分之间互不相关。该方法在简化数据和提高数据分析效率方面有着显著的效果。本质上,PCA在某一点上的结果是由该点及其邻近点导出的协方差矩阵的特征值和特征向量。Weinmann等^[39]使用特征值和特征向量表征点云局部形状特征,从而获得不同的1D、2D和3D特征完成进一步的分析。

区域生长算法也是一种数据驱动的方法,本质上是基于区域的传统图像分割算法,主要用于分割激光雷达数据,特别是对于复杂物体(例如文献[40])。区域生长算法从一组种子点的选择开始,然后是一个迭代生长过程,在迭代的过程中,预先给定种子的区域生长规则来约束种子点与其相邻点之间的一致性,将相似的领域点不断添加到种子点上,直至满足区域生长的终止条件完成整个过程。与其他方法相比,区域增长的计算复杂度较低,只需要通过一个自定义参数就能控制整个分割过程,因此具有更高的效率和可操作性(见文献[41])。

连通域类似于区域增长的基本思想,处理对象一般是一张二值化后的图像,常用于图像分析处理的众多领域,也可以用于分割点云数据。它通常是按照分离地面点和非地面点的滤波过程来执行。该方法通过预先定义的标准(距离等)来调查相邻点之间的连接关系,可以将位于同一物体上的点分组成一个段。3D点云转换成2D网格的过程会造成很大的

信息损失,因此Vosselman等^[35]通过采用KNN或体素化方法来确定地面激光扫描(MLS)点云数据中的连接分量。

图分割技术指将图像根据自身不同的特性分割成不同区域并提取出感兴趣区域的过程。不同的特性指颜色、强度、灰度和纹理等,该技术打破了相邻点之间的弱连接,从而可以分离数据集中的连接对象。与没有进一步约束的连接组件不同,在某些情况下,当两个对象部分连接时,可以根据需要对点云进行分段,图分割可以作为一种改进方法。图分割算法的实现有很多方式,如Katz等^[42]使用诸如沿边界的凹度和部分紧度等线索对图进行聚类后再进行分割;Shapira等^[43]在网格表面上创建一个标量函数,然后使用基于最小切割的方法沿着函数中的不连续点分割网格。

超体素化也是处理点云的另一种常见分割方法^[44],可以将具有相似属性的点云或体素聚类成一个区域,从而减少处理三维数据的计算量,它是从计算机视觉中的超像素概念扩展而来。超体素化根据数据各种属性(例如法线、颜色、强度和形状等)将点云分组为超体素的同质片段,再对点云进行分割。超体素化可以作为数据的预处理过程,在处理海量MLS点云数据时降低计算复杂度(例如文献[45])。超体素化通常需要先无组织的点云体素化处理得到具有固定分辨率的体素云,然后利用种子体素遍历相邻体素,对每个体素中具有相似属性的相邻点迭代聚类,从而形成不规则形状的超体素。表6列出了经典的对象识别和分割方法。

表6 对象识别和分割方法

Table 6 Object recognition and segmentation methods

方法分类	优点	缺点
霍夫变换	抗干扰能力强、对噪声不敏感	时间和空间复杂度高
随机采样一致性	鲁棒性高;可以很好地估计出高精度参数	迭代次数不可控;迭代后的结果不一定最优;需要设置相关阈值
主成分分析	降低数据维度、去除噪声、结果容易理解、没有参数限制	结构信息存在一定损失;主成分解释具有一定的模糊性
区域增长	较低的计算复杂度、计算效率和可操作性较高;抗噪能力强	易产生过分分割或分割不足
连通域	原理简单;处理速度快	易受噪声的影响
图分割	普适于各种特征	需要选择很多分段;需要大量的存储空间和高时间复杂度
超体素化	提取多尺度、多层次的局部特征信息;运算效率高;得到高级的属性信息	信息丢失不可避免;对分辨率要求很高

2.3 点云配准

点云配准是计算机视觉、移动机器人学和计算机图形学等领域的一项基本任务,其在三维重建、三维定位、自动驾驶、位姿估计、逆向工程及虚拟现实等领域有着广泛应用。点云配准的实质是估计点云之间的刚体变换关系,通过变换关系将点云数据变换到统一参考坐标系。经典的配准方法主要有最近点迭代(ICP)算法正态分布变换算法(Normal Distribution Transform, NDT)、4PCS(4-Points Congruent Sets)算法以及基于特征的配准算法(点特征、线特征、面特征和纹理特征)。特征配准算法也是一个变换估计的过程,获得关键点(线、面或纹理)及关键点(线、面或纹理)的描述符之后,就能通过描述符之间的对应关系获得变换矩阵,将配准问题变成凸问题。

2.3.1 经典配准算法

最近点迭代(ICP)算法^[46]是点云数据配准中最经典的算法之一,该算法本质是一种非线性局部搜索算法和迭代优化

技术,它对应于两组匹配点之间均方距离的最小化,多年来得到广泛应用,其主要过程分两步进行:1)确定两个重叠曲面之间点对的对应关系;2)估计最佳刚性变换,使第二个曲面与第一个曲面配准。Zhu等^[47]通过提高建立点之间对应关系的可靠度来提高ICP算法的效率。Benjemaa等^[48]提出了一种全局匹配方法,提高了最近邻搜索速度,减少了点对应问题的计算量。Yang等^[49]提出了全局最优ICP(Go-ICP),依靠分支定界(branch-and-bound, BnB)更有效地搜索两个数集之间的对应关系,提高了计算效率。

正态分布变换算法(Normal Distribution Transform, NDT)使用直线体素单元划分点云,然后将每个单元内的点建模为一组高斯分布,最初是Biber等^[50]用于二维扫描数据无损检测而开发的。在此基础上,Magnusson等^[51]提出了用于点云配准的3D-NDT,是将参考点云转换成多维变量的正态分布来进行配准。Das等^[52]提出一种多尺度K均值NDT(multi-scale K-means normal distributions transform, MSKM-

NDT),该算法使用K均值聚类对点云进行划分,并在多个聚类尺度上进行优化,解决了NDT算法成本函数不连续的问题,对于初始误差较大的点云配准,该方法可以起到很好的配准效果。2014年Das等^[53]提出了一种分段区域生长NDT算法(Segmented Region Growing Normal Distributions Transform, SRG-NDT),先从扫描中去除地面点,然后使用区域生长算法对剩余点进行聚类,再从聚类结果中计算概率密度函数,相比基于体素化方法,用更少的高斯分布对环境进行精确建模,该方法在克服了成本函数不连续性的同时因为去除了地面点使得计算速度相应提高。

4PCS(4-Points Congruent Sets)算法^[54]是一种经典的粗配准方法,该算法是基于RANSAC(Random Sample Consensus)的设计理念,不需要提供初始位姿,可以通过直接处理原

始数据为后续的精配准提供一个良好基础,在处理有噪声和遮挡点云数据时也不需要去噪和过滤。Mellado等^[55]提出了super 4PCS算法,使得数据在低重叠扫描或者存在异常值情况下也能进行很好的配准,该算法还允许跨设备提取数据。Huang等^[56]提出了特征度量点云配准框架,在不需要搜索对应关系的情况下,使特征空间上的投影误差最小化,从而解决配准问题,该方法可以有效地处理噪声、密度差和部分重叠数据。Xu等^[57]提出voxle 4PCS,该方法没有迭代过程,通过将点云体素化就可以提取出没有精确边界但具有可靠方向信息的平面,再将共面的平面融合后代替点,使用角度关系代替长度关系作为在刚性变换中不变的关系判别特征的相似性,实现了更高的鲁棒性和速度。表7列出了一些经典配准算法。

表7 经典配准算法
Table 7 Classical registration algorithms

方法分类	典型算法	优点	缺点
ICP及其变体	Go-ICP	精度高,适用范围广	多数需要初始位姿,速度较慢(对比NDT),鲁棒性差,需要迭代
NDT及其变体	NDT; 3D-NDT; MSKM-NDT	精度高,适用范围广,处理速度快	需要初始位姿,鲁棒性较差,需要迭代
4PCS及其变体	4PCS; super-4PCS; voxel 4PCS	不需要初始位姿,鲁棒性好,适用范围广	速度慢,精度低,需要迭代

2.3.2 基于特征的配准算法

特征配准算法中点特征是最常用的点云特征, Masuda等^[58]通过随机采样法提取关键点,可以简单有效地控制关键点的数量。Kamoussi等^[59]提出了最远点采样法,该算法可以确保采样点均匀分布在点云上。Rusinkiewicz等^[60]提出了法向空间采样方法(Normal Space Sampling),根据法线在角度空间中的位置对点进行存储,再对存储的点均匀采样,使得在一些容易被忽视的区域也有机会选中关键点。Zhong^[61]采用协方差矩阵来提取关键点,提取协方差矩阵中特征值最小值变化大的区域中的点,这里的点可能是点云中的特殊点。前人对点特征的描述较多, Feldmar等^[62]提出用邻近点计算出的主曲率作为描述符。曲面的每个方向都有法曲率,其中最大和最小的法曲率就是主曲率,结合对应曲线的关键点的切线方向就是主曲率方向作为该关键点的描述符。主曲率是刚性变换不变的,由于法线方向存在歧义性,因此要考虑法线的两个方向。Chua等^[63]应用主成分分析法(PCA)提取特征,通过分析数据点三维坐标的加权协方差矩阵计算的3个特征向量获取关键点,把最终的主成分作为点的描述符。Huang等^[64]引入正弦绝对值(SiN)精简点云,降低运算量,通过点云法向量夹角的变化以及点云的几何特征(点局部法向量变化程度SiN值、点到邻域重心距离值及点与邻域重心连线到其法向量的夹角)作为描述符。Zhong^[61]提出内在形状特征(Intrinsic Shape Signature, ISS)描述符,使用从基本八面体递归计算的离散球面网格将球面角空间划分为相对均匀和均匀分布的单元,对领域的协方差矩阵进行特征值分解得到4个LRF(Local Reference Frame),对比关键点处的LRF,使用其极坐标对近邻点进行编码,离散的球面网络用来简化直方图。点特征直方图(Point Feature Histogram, PFH)由Rusu等^[65-66]在2008年提出,用于描述3D点云数据集某一点周围的局部几何形状,在一点上的结果是一个多维直方图,它本质上描述和概括了该点的局部曲率。在此基础上点快速特征

直方图(FPFH)是Rusu等^[67]于2009年对PFH的数学表达式的修改,广泛用来解决相互重叠点云视图的三维配准问题。对于每个点,在给定范围内搜索其K近邻(KNN),然后分析该邻域内每对点之间的法线变化和距离。其次,进一步优化邻域和点对,以细化局部区域几何特征的描述符。Chen等^[68]基于随机样本一致性(RANSAC)的数据对齐刚性约束穷举搜索(data-aligned rigidity-constrained exhaustive search, DARCES)方法可以解决部分重叠问题,对两个点集分别取3个点构成小三角形,再从另一个点集上寻找与目标点集相似的小三角形,以此重复得到大量与目标点集相似的点集,然后得到最佳变换矩阵。在选择点时加入特征的约束,通过构建搜索树可以加快具有相同特征点集的搜索速度,同时减少对应的特征三角形点集。Gelfand等^[69]开发了一种基于距离矩阵比较的快速分支定界算法,该算法对每个特征点使用模型的特征值来寻找潜在对应点,再选择最优对应点集使两个形状形成粗对齐。Theiler等^[70]提出了K-4PCS算法,该算法通过引入4PCS算法的思想,通过提取三维关键点,在保留特征的同时减少了数据量,再将关键点特征应用到4PCS中。

线特征也是一种常用特征。Stamos等^[71]提出从分段距离图像中提取三维特征,先提取分割模块相交产生的无限延伸曲线,再从这些曲线中生成三维线性线段作为特征值。Yang等^[72]先将地面点用Hernández和Marcotegui^[73]的方法去除,然后根据点云的密度使用一系列有着高度阈值间隔的水平面将非地面点进行分割,提取点云中的类极点、交叉点和顶点聚类为垂直特征线。Tao等^[74]提出了一种点云粗配准自动方法,采用降维方法对空间中的点云进行配准处理,首先将三维原始点云投影在水平面上变换成二维点云,再通过投影点密度(DoPP)方法^[75]来提取二维直线上的点,然后通过划分网格并约束网格中的点密度得到高密度点云线,最后基于点的区域生长方法得到线特征。Yang等^[76]利用空间曲线作为匹配的基元,克服了以点、线、块为基元的配准方法的

局限性,可以在自由曲面扫描的点云之间找到对应关系。该方法先对具有较大集合曲率的点进行聚类,使用波峰线描述这些点的特征。线特征中,常用的是直线描述符。Stamos等^[71]使用五元组(线特征编号、线起始点、线终端点、线所在平面大小和法线)表示线特征,只需要原始点云和目标点云之间的一个特征就可以估计变换矩阵。Yang等^[72]使用九元组(线的最高点、最低点、点的数量、线的长度、线的序号、线的类型、线的半径和线支撑平面的两个方向)描述线特征。Tao等^[74]通过线之间的夹角作为特征描述,利用二维直线进行二维变换,使用二维直线特征进行配准。线特征只需要较少的条件就可以得到变换条件。Stamos等^[71]提出的线特征每一组之间都可以确定一个变换矩阵,可以通过预先设置的阈值过滤掉不满足给定条件的特征,然后验证其他组是否满足匹配,最终迭代获得最佳匹配。Yang等^[72]用语义特征组合作为三角对,通过线特征的3种约束得到相似三角对,使用几何一致性^[77]检验消除错误的对应三角对,再对剩下的三角对进行分组,然后用最大组中的三角对计算得到转换矩阵。Tao等^[74]通过所得到的直线对之间的角度去寻找相互匹配的直线对。

面特征包含的信息量较多,同时对噪声不敏感,相比点特征所涉及的点范围,面特征考虑的范围更加广泛。Brenner等^[78]使用区域生长算法迭代了种子区域选择和区域扩展两个步骤,种子区域根据其局部平面度进行优先排序,然后得到平面特征。Chen等^[79]将场景的主要结构表示为平面集合,基于平面的描述符建立点云之间的结构级对应关系。该方法使用Schnabel等^[37]基于RANSAC算法的有效实现从点云中提取平面特征。Xu等^[57]通过将点云体素化,计算体素内点的曲率,对满足要求的平面块组合在一起得到平面特征,提取面特征可以加快特征匹配的速度。Brenner等^[78]认为已经提取的面特征(面积等)不够可靠,最终保留法线和特征面到原点的距离作为后续的特征步骤。Chen等^[79]通过非平行平面与平行平面之间的交线作为线特征,以此来确定刚性变换,完成后续配准。Xu等^[57]通过平面的法线以及法线组成的平面之间的角度构建特征。面特征需要更少的对应特征就可以确定变换矩阵。Brenner等^[78]先计算面特征构成的所有三元组的三重积,再进行排序,三重积越大则计算的平移误差就越小,然后使用三元组估计变换矩阵,同时给定变换次数的阈值,同一个变换出现次数到达阈值时就停止迭代。Chen等^[79]只需要通过一对面特征即可得到变换矩阵,再建立kd-tree寻找近似特征以及相似变换,得到相似变换的均值可以有效减少验证数量。

纹理特征是一种全局特征,反映的是图像中同质现象的

视觉特征,体现物体表面具有缓慢变化或者周期性变化的表面组织结构排列属性。基于此,提出了点云纹理特征的概念,该特征属性反映了点与其邻域点的属性值分布情况。Zhang等^[80]将反射强度转换成二维图像,在二维图像中取一个关键点同时根据相似度排序找到最接近目标点的关键点,最后使用尺度不变特征变换^[81](Scale-invariant Feature Transform, SIFT)算法的特征检测方法提取结合点,采用RANSAC算法去除伪匹配点后,保留精细结合点对应的空间点作为特征点。Wang等^[82]先生成点云金字塔,用3D高斯函数卷积每一层点云金字塔的强度图像,每个金字塔层减相邻高斯平滑强度图像生成DoG3d,最后取DoG3d的极值作为特征点。Jung等^[83]使用fast-Hessian detector检测关键点,通过加速鲁棒特征算法(Speed Up Robust Features, SURF)^[84]描述符寻找匹配关系,提高了计算效率。Yang等^[85]采用超体素的分割方法对点云进行下采样,将空间矢量和每个超体素中的颜色矩相结合来作为混合特征,以超体素中心作为检测到的特征点。纹理特征的描述可以借鉴一些经典图像特征描述方法。Zhang等^[80]通过SIFT方法描述反射强度生成的图像特征。Liu等^[86]通过SIFT方法描述RGB图像特征。Jung等^[83]通过SURF描述符描述检测到的特征。Yang等^[85]利用三阶颜色矩独立表示每一个超体素的颜色分布特征,再结合提取到的中心点空间坐标作为描述符。纹理特征的特征匹配方法同点特征的特征匹配方法有很多共通之处,二者都属于局部特征。Zhang等^[80]通过RANSAC来过滤掉从反射强度图像中提取错误匹配关系,保留特征匹配正确的匹配关系。Wang等^[82]使用CTNC(closest-to-next-closest)^[81,87]技术,通过计算最近欧几里得近距离和次最近欧几里得距离二者的比值大小来判断是否是正确的匹配。Liu等^[86]采用基于对极几何约束的RANSAC算法检测SIFT在配准后不匹配的纹理特征点。Jung等^[83]利用三维点云生成二维图像,通过改变图像的分辨率和方向,在给定范围的图像中生成多对合成图像进而获得大量的特征匹配关系,降低使用二维配准的错误风险,最后从多对二维图像中选择得票最多的匹配关系。Yang等^[85]给出适当的权重来平衡空间坐标表示的几何特征和颜色矩向量表示的局部颜色分布特征,再根据点云的不同位置进行合理的相似性度量,即当两个点云的空间位置相差较大时,使用颜色特征比使用空间特征更准确。当点云大致对齐时,更合适使用空间特征来匹配点云的几何细节。表8列出了基于特征的点云配准方法中各种形式的特征的特征检测、特征描述和特征匹配的经典方法。

表8 基于特征的配准方法

Table 8 Feature-based registration methods

特征方法	特征检测	特征描述	特征匹配
点特征	随机采样法;最远点采样法;法向空间采样法;协方差矩阵特征比较法	主曲率;主成分;3DSC;PFH;FPFH	RANSAC;分支定界;K-4PCS
线特征	平面的交线;语义线性特征;投影与区域生长;曲线特征	五元组描述;九元组描述;直线对的夹角	几何一致三角对;相同夹角直线组
面特征	区域生长法提取面特征;RANSAC法提取面特征;体素融合提取面特征	法线与到原点的距离;角度不变特征	三重积排序;验证变换均值;角度不变特征匹配
纹理特征	DoG和DoG3d;fast-Hessian detector;超体素	SIFT;SURF	CTNC;对极几何约束和RANSAC;最多投票

3 深度学习处理方法

随着计算机技术的发展,基于深度学习的点云处理方法

得到了广泛应用与发展,但是将深度学习用于点云处理依旧是一件具有挑战性的事情,首先点云是不规则、非结构化的,其次点与点之间的关系并不是固定明确的,最后通过设备扫

描述获得的点云密度难以做到均匀分布。基于深度学习的点云处理方法相比于经典传统点云处理方法有很多优势,如计算速度的提升、可获得更高级的点云特征等。在前人的基础上,本文将基于深度学习的点云处理方法分为基于点云的方法、基于体素的方法和基于多视图的方法。

3.1 基于点云的方法

基于点云的方法是直接对点云进行处理,不需要任何体素化或者投影,该方法的显著优势不会导致过多的信息丢失。

PointNet^[88]是第一个直接接收点云数据作为学习输入的神经网络架构。该算法不需要将点云进行任何格式的数据转换(3D体素或2D图像),直接使用点云数据,防止了点云信息丢失的同时,还避免了数据转换所消耗的时间。PointNet是一个统一的神经网络架构,通过直接将点云作为输入,学习每个点的空间编码,输出整个输入的类标签或者每个输入点的点段/部件标签。初始阶段,每个点都被相同独立地处理,每个点仅由3个坐标 (x, y, z) 表示。当然也可以通过算法线和其他全局/局部坐标添加额外的维度。PointNet的关键在于使用一个单一的对称函数输出相同的结果,而不考虑输入顺序(即加法和乘法)。使用多层感知器(Multilayer Perceptron, MLP)将每个点的信息作为多个通道的值独立输出,而最大池化层是一个对称函数,它独立于点的顺序提取所有输出点特征的每个通道的最大值,以累积所有输入点的全局特征。因此,PointNet可以结合每个点的特征和输入点的全局形状特征,直接对输入点进行标注。Qi等^[88]在PointNet的基础上进行了扩展,增加了层次结构,提出了PointNet++,在局部区域分层应用PointNet,以适应性地将来自多个尺度的特征,该方法还提出了多尺度分组和多分辨率分组的策略,解决了非均匀点采样的问题。Jiang等^[89]在二维形状描述子SIFT的基础上提出了PointSIFT,该方法有两个关键属性,对不同方向的信息进行编码和自适应形状尺度。具体来说就是设计了一个方向编码单元来描述8个关键的方向,并通过堆叠多个方向编码单元来实现尺度表示。Li等^[90]提出PointCNN,通过推广卷积神经网络(Convolutional Neural Network, CNN)的结构来学习空间中点之间的局部相关性。PointCNN采用与PointNet相同的方式使用未转换的点云数据,并且通过推广应用于图像网格的cnn原理,可以不考虑输入顺序进行学习,并学习空间中相邻点之间的相关性。对于图像,CNN通常会减少每个卷积(conv)层的输入范围,并增加通道,以递归地学习均匀排列的数据点与其周围环境之间的相关性。PointCNN还减少了每层的输入邻近点的数量,并增加了递归学习与周围点的相关性的通道,但使用x-conv,它使用KNN输入邻近点,而不是使用一般的conv层输入不规则形式的点云数据。Wang等^[91]提出了DGCNN,该方法是一种可以像CNN一样学习局部相关性的网络架构。它还使用网络每层的动态图来学习与相邻点或具有相似特征的点的相关性。DGCNN也接收未转换的点云数据作为输入,类似于PointNet,但是DGCNN使用从相邻点学习信息的结构取代MLP。与一般的CNN架构不同,在每一层基于特征的欧氏空间中获得相邻点,因此可以从不同的点学习边缘向量。与一般卷积层学习中心点的周围点信息不同,边缘卷积学习从中心点特征指向周围点特征的边缘向量信息。因此,DGCNN比其他形式的传统点云架构可以学习更加多样的数据

特征。Xu等^[92]提出了一种基于参数化卷积滤波器的卷积神经网络SpiderCNN,SpiderCNN由新卷积层SpiderConv单元组成,通过参数化一系列滤波器,将卷积操作从规则网格扩展到可以嵌入到不规则点集中,SpiderCNN继承了经典CNN的多尺度层次结构,使其可以提取深度语义特征,可以直接处理非常稀疏的点云。Li等^[93]提出了LIDAR-CNN,解决了由于点云自身不规则性导致的尺度模糊问题,基于PointNet或PointNet++的方法仅关注点的特征,但忽略了3D空间中的间距,这影响了目标物的细化工作。LIDAR-CNN则弥补了这方面的缺陷,优化了检测性能。Zhang等^[94]构建了IA-SSD检测器,基于PointNet++对点云实行大尺度下采样,在缩小数据规模的同时,保证了目标物的特征信息大量保留,因此在保证目标物识别精度的同时显著提升了计算速度。

3.2 基于体素的方法

基于体素化方法^[95]是一种结构化的表示方法,其将无序的点云分割成一系列占用一定空间的体素(Occupancy Voxels),Maturana等^[96]提出了VoxNet,一种3DCNN网络架构,在原始点云数据中提取特征并对对象进行分类,通过体积网格表示点云区分了自由空间和未知空间,对于给定的三维点云片段(包含背景、杂波和预测对象类别标签混乱等问题),使用估计空间占用率的体积网格和对占用网格预测类别标签的CNN,可以预测输入段的类别标签。Hegde等^[97]提出Volumetric CNN来学习训练集中的点云特征,通过FusionNets,结合了在体素模型上训练的卷积神经网络和在渲染对象视图上微调的预训练卷积神经网络。Brock等^[98]提出了用于生成和判别体素建模的深度卷积神经网络架构,使用VRN(Voxelception-ResNet)构架训练了多达45层的网络,以增强利用模型深度带来的表现力。He等^[99]提出了结构感知单级检测器(SA-SSD),通过张量计算的方法将点云划分成体素块,添加辅助网络的同时不增加额外的计算量,显著提高了模型计算效率。Ye等^[100]提出了混合体素网格(HVNet),在融合体素特征编码器(VFE)基础上,提出多尺度混合体素特征编码器(HVFE),解决了较小体素精度高但是耗时、较大体素效率高但识别不准确的问题。Deng等^[101]提出了Voxel R-CNN的体素框架,以体素作为输入,对体素进行2D鸟瞰图(BEV)投影,之后使用2DCNN对投影进行估计,从而降低了计算量。Chen等^[102]提出了Focals Conv以及Focals Conv-F替换原有的稀疏卷积网络,降低点云体素过程中的计算量,从而提升体素化效率。Shi等^[103]在基于点体素区域的卷积神经网络(PV-RCNN)的基础上提出了PV-RCNN++,根据点云的径向分布,改进体素块的采样方法;同时新的局部特征聚合模块VectorPool聚合,进一步提高了运行速度。Wu等^[104]提出了变换等变3D检测器(Transformation-Equivariant 3D Detector),通过SpConv将体素编码为变换等变体素特征,解决了常规稀疏卷积只能保证点云特征平移不变性,该方法可以保证点云特征的旋转和反射不变性。Yang等^[105]基于Transformer3D对象检测器,提出了单级三维检测点-体素转换器(PVT-SSD),该方法首先使用基于体素的稀疏卷积提取少量非空体素数据特征,然后使用Transformer结构提取各体素之间的全局信息,从而获得点云的局部细粒度几何信息以及整体信息。Kang等^[106]提出基于Transformer的体素化激光点云目标检测算法VoxTransNet,使用Transformer层和

三维卷积模块替代了MLP全连接网络,加强了算法对相邻体素间特征的学习能力。Yang等^[107]提出了结合点和体素的点云深度学习网络,主要分为两步,第一步是通过MLP直接提取单个点的特征,第二步是将点转换为体素网格后通过3D卷积聚合特征得到点云的局部信息,再利用三线插值去体素化把特征转换为点云域,最后将基于体素和基于点的特征整合在一起。

3.3 基于多视图的方法

基于多视图的方法是将三维非结构化点云通过多个方向的投影后转换为多个二维结构化图像,然后使用深度学习进行图像处理。基于多视图的方法可以细致划分图像,用较少的数据量即可包含丰富的纹理信息。Lawin等^[108]将三维点投影到二维图像中,用纹理信息进行渲染后,把颜色、深度和表面法线不同组合的合成图像作为输入,使用全卷积网络(Fully Convolutional Network,FCN)对合成图像进行处理并给出总的预测分数。Boulch等^[109]提出基于深度分割神经网络的三维点云语义标注框架,通过SnapNet对生成的场景

RGB视图和包含几何特征的深度合成视图进行分割,再用残差矫正的方法融合特征数据。Wu等^[110]提出了一个基于CNN的端到端的网络架构SqueezeSeg,使用CNN转换后的二维网格作为输入,再通过条件随机场(CRF)作为循环层对图像进行细化,再用聚类算法得到标签。Milioto等^[111]提出了一个可以在基于距离图像的CNN主干运行的网络架构RangeNet++,先采用投影的方式将三维转换为二维,使用2DCNN学习特征并完成语义分割,最后把语义转移从2D恢复到3D。Barrera等^[112]在BirdNet基础上提出了BirdNet+,该方法完全通过BEV输入对数据进行处理,取消了BirdNet对3D对象框的后处理过程,使用端到端处理方法完成对3D对象框架的检测,加快了对目标物的识别速度,同时还提高了检测精度。Zhou等^[113]提出了一种新的端到端多视图融合(MVF)算法,该算法结合了鸟瞰图和透视图两种不同角度的点云视图,利用两者的信息互补,引入了动态体素化方法提取点云的特征数据,显著提升了算法对模型的检测准确性。表9列出了基于深度学习的点云处理方法。

表9 基于深度学习的点云处理方法

Table 9 Point cloud processing methods based on deep learning

方法分类	典型方法	优点	缺点
基于点云的方法	PointNet; PointNet++; PointSIFT; PointCNN; LIDAR-CNN	避免数据转换损失结构信息;降低预处理时间	忽略了局部特征以及点云密度不均匀的影响
基于体素的方法	VoxNet; FusionNets; VoxTransNet; SA-SSD; HVNet; Voxel RCNN; PV-RCNN++; PVT-SSD	促进点云规则化;提取多尺度、多层次的点云信息;可以处理数量级大的点云	需要较高的计算和内存成本;容易导致数据错误划分;损失几何信息、分割精度不佳
基于多视图的方法	FCN; SnapNet; SqueezeSeg; RangeNet++; BirdNet; MVF	产生多属性、多时相和多尺度的高维点云;处理效率高、速度快;划分得更加细致	易受视角影响、几何结构信息利用不充分;对有遮挡场景难以处理;视点整合复杂

结束语 本文对现有的公开点云数据集以及常用评价指标进行整理,将点云处理方法分为传统点云处理方法和基于深度学习的点云处理方法。对传统处理方法做了介绍总结,对部分基于深度学习的处理方法给出了网络架构。目前的主流处理方法中,特征依旧起着相对重要的作用,在深度学习方法中为了减少结构信息的损失,直接对点云进行处理的研究成为比较热门的方向,无论是传统的处理方法还是基于深度学习的处理方法都还有很大的可研究空间,都有望取得更大的进展。

尽管已经有很多成熟的传统点云处理方法,基于深度学习的处理方法也发展了较长时间,但是在处理点云时依然面临很多问题和挑战。1)算法普适性。无论是传统算法还是基于深度学习的算法,在用于粗配准时的效果很好却不适用于精配准,反之也是如此;还有一些算法对于稀疏的点云能有较好的分割效果,但是对于密集的点云的分割效果往往不尽如人意。2)应用场景受限。基于深度学习的方法目前大都是应用于简单的物体上,对于大型复杂的物体适用性较差,传统的处理方法精确度往往难以得到保证,并且对于大型复杂的点云想要得到高精度的处理结果往往意味着需要巨大的计算量和大量的时间投入。3)公开数据集不全面。尽管已经有不少特定场景的数据集被公开使用,但是随着处理的数据场景类型不断增加,现有的公开数据集依旧难以满足深度学习对数据训练的需求。4)数据格式转换的问题。目前有很多设备都可以轻松得到想要的目标物点云,但是不同设备之间的数据难以相互转换或者转换会导致结构信息的丢失,对后续处

理产生不同程度的影响。5)处理计算量大。很多算法为了保证高分割精度和快速配准,不可避免地会产生巨大的计算量,但是硬件设备难以满足期望的处理效率。6)依赖人工标注的问题。想得到准确的标签数据,往往需要人工进行标注,但是人工标注不仅费时费力还难以保证准确度。

从当前所面临的这些挑战出发,本文对未来点云算法的发展趋势做出如下展望:1)现有方法在采样和数据转换过程中导致的细节信息丢失问题,可以通过优化采样和转换方法得到改善;2)对于人工标注大型数据费时费力的问题,可以在算法中结合深度学习的方法来弥补这方面的不足;3)解决噪声对于点云的影响,可以通过选择合适的滤波方法尽可能地将异常点从场景数据中分离出去,用清洗过的数据进行后续处理,可以有效降低噪声对分割等精度的影响;4)对于计算量大的问题,可以针对不同类型和场景点云,融合新算法来寻找更具代表性同时便于快速提取、存储量小、鲁棒性高和受环境影响小的点云局部和全局特征,以降低计算量;5)针对公开数据集不全的问题,可以在当前现有的数据集的基础上进行扩展,使用并融合现有的各种算法加速新的应用场景数据集的开发;6)对于设备之间所采集的数据兼容问题,可以开发数据转换平台并配合其他新的辅助设备辅助数据采集,采集过程添加新的重要信息,从而提高数据转换的效果。

参考文献

- [1] BAI Q P, SUN D H, ZHANG R, et al. Research on the application of 3D GIS in digital offshore drilling platforms [J]. Bulletin of Surveying and Mapping, 2011(6): 73-75, 79.

- [2] FAN C C, DE X W, GUO J J, et al. Laser line scanning three-dimensional surveying of seafloor terrain based on triangular displacement method attitude correction [J]. *Optical Precision Engineering*, 2022, 30(10): 1170-1180.
- [3] LIU B, LI X C G, ZENG J, et al. Application of underwater three-dimensional laser scanning in jacket platform damage measurement [J]. *Journal of Guangxi Academy of Sciences*, 2020, 36(4): 434-440.
- [4] WU S H. Research on the application of three-dimensional laser scanning technology in offshore drilling platforms [D]. Liaoning University of Engineering and Technology, 2013.
- [5] HUA B S, TRUONG Q T, TRAN M K, et al. Shrec'17: Rgb-d to cad retrieval with objectnn dataset [C] // Proc. Eurograph. Workshop 3D Object Retrieval. 2017: 25-32.
- [6] HUA B S, PHAM Q H, NGUYEN D T, et al. Scenenn: A scene meshes dataset with annotations [C] // 2016 Fourth International Conference on 3D vision (3DV). Ieee, 2016: 92-101.
- [7] WU Z, SONG S, KHOSLA A, et al. 3d shapenets: A deep representation for volumetric shapes [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 1912-1920.
- [8] ROYNARD X, DESCHAUD J E, GOULETTE F. Paris-Lille-3D: A large and high-quality ground-truth urban point cloud dataset for automatic segmentation and classification [J]. *The International Journal of Robotics Research*, 2018, 37(6): 545-557.
- [9] HACKEL T, SAVINOV N, LADICKY L, et al. Semantic3d. net: A new large-scale point cloud classification benchmark [J]. arXiv: 1704. 03847, 2017.
- [10] BEHLEY J, GARBADE M, MILIOTOA, et al. Semantickitti: A dataset for semantic scene understanding of lidar sequences [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019: 9297-9307.
- [11] ARMENI I, SENER O, ZAMIR A R, et al. 3d semantic parsing of large-scale indoor spaces [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 1534-1543.
- [12] LI X, LI C, TONG Z, et al. Campus3d: A photogrammetry point cloud benchmark for hierarchical understanding of outdoor scene [C] // Proceedings of the 28th ACM International Conference on Multimedia. 2020: 238-246.
- [13] DESCHAUD J E, DUQUE D, RICHA J P, et al. Paris-CARLA-3D: A real and synthetic outdoor point cloud dataset for challenging tasks in 3D mapping [J]. *Remote Sensing*, 2021, 13(22): 4713.
- [14] WANG R, HUANG S, YANG H. Building3D: A Urban-Scale Dataset and Benchmarks for Learning Roof Structures from Point Clouds [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2023: 20076-20086.
- [15] YANG H F, XIA H, CHEN X, et al. Application of image fusion in three-dimensional reconstruction of space targets [J]. *Infrared and Laser Engineering*, 2018, 47(9): 374-381.
- [16] DING Z J, ZHAO Z Y, ZHANG C T, et al. Structured light three-dimensional reconstruction of deep sea landform lines by manned submersible [J]. *Infrared and Laser Engineering*, 2019, 48(5): 11-19.
- [17] BALADO J, VAN OOSTEROM P, DÍAZ-VILARINOL, et al. Mathematical morphology directly applied to point cloud data [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 168: 208-220.
- [18] WAN P, ZHANG W, SKIDMORE A K, et al. A simple terrain relief index for tuning slope-related parameters of LiDAR ground filtering algorithms [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 143: 181-190.
- [19] VOSELMAN G. Slope based filtering of laser altimetry data [J]. *International Archives of Photogrammetry and Remote Sensing*, 2000, 33(B3/2; PART 3): 935-942.
- [20] ZHU X X, CHENG W, XI X H, et al. Hierarchical threshold adaptive for point cloud filter algorithm of moving surface fitting [J]. *Acta Geodaetica et Cartographica Sinica*, 2018, 47(2): 153.
- [21] AXELSSON P. DEM generation from laser scanner data using adaptive TIN models [J]. *International Archives of Photogrammetry and Remote Sensing*, 2000, 33(4): 110-117.
- [22] SITHOLE G, VOSELMAN G. Filtering of airborne laser scanner data based on segmented point clouds [J]. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2005, 36(part 3): W19.
- [23] ZHANG K, CHEN S C, WHITMAN D, et al. A progressive morphological filter for removing nonground measurements from airborne LIDAR data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(4): 872-882.
- [24] DIAO X P, WU K. Improved moving window surface fitting method point cloud data filtering processing [J]. *Modern Mining*, 2011, 27(6): 59-61.
- [25] SUN C L, SU W, WU H G, et al. Improved multi-level moving surface fitting lidar data filtering method [J]. *Infrared and Laser Engineering*, 2013, 42(2): 349-354.
- [26] SOHN G, DOWMAN I J. Terrain surface reconstruction by the use of tetrahedron model with the MDL criterion [C] // International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences. Natural Resources Canada, 2002, 34(3/A): 336-344.
- [27] HAUGERUD R A, HARDING D J. Some algorithms for virtual deforestation (VDF) of LIDAR topographic survey data [J]. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 2001, 34(3/W4): 211-218.
- [28] SUI L C, ZHANG Y B, ZHANG S, et al. Airborne LiDAR point cloud data filtering based on progressive triangulation network [J]. *Journal of Wuhan University Information Science Edition*, 2011, 36(10): 1159-1163.
- [29] HU J, YANG L, SHEN J X, et al. A segmentation-based airborne LiDAR point cloud data filtering [J]. *Journal of Wuhan University Information Science Edition*, 2012, 37(3): 318-321.
- [30] PFEIFER N, KÖSTLI A, KRAUS K. Interpolation and filtering of laser scanner data-implementation and first results [J]. *International Archives of Photogrammetry and Remote Sensing*, 1998, 32: 153-159.
- [31] KRAUS K. Linear least-squares interpolation [J]. *Photogrammetric Engineering*, 1972, 26: 487-493.
- [32] LIU X. Airborne LiDAR for DEM generation; some critical issues [J]. *Progress in Physical Geography*, 2008, 32(1): 31-49.
- [33] ZHANG W, QI J, WAN P, et al. An easy-to-use airborne Li-

- DAR data filtering method based on cloth simulation[J]. *Remote Sensing*,2016,8(6):501.
- [34] BALLARD D H. Generalizing the Hough transform to detect arbitrary shapes[J]. *Pattern Recognition*,1981,13(2):111-122.
- [35] VOSSELMAN G, GORTE B G H, SITHOLE G, et al. Recognising structure in laser scanner point clouds[J]. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*,2004,46(8):33-38.
- [36] FISCHLER M A, BOLLES R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography[J]. *Communications of the ACM*, 1981,24(6):381-395.
- [37] SCHNABEL R, WAHL R, KLEIN R. Efficient RANSAC for point-cloud shape detection[C]// *Computer graphics forum*. Oxford, UK: Blackwell Publishing Ltd,2007,26(2):214-226.
- [38] ABDI H, WILLIAMS L J. *Principal Component Analysis* [J]. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2010,2(4):433-459.
- [39] WEINMANN M, JUTZI B, HINZ S, et al. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*,2015,105:286-304.
- [40] RABBANI T, VAN DEN HEUVEL F, VOSSELMANN G. Segmentation of point clouds using smoothness constraint[J]. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*,2006,36(5):248-253.
- [41] KHALOO A, LATTANZI D. Robust normal estimation and region growing segmentation of infrastructure 3D point cloud models[J]. *Advanced Engineering Informatics*,2017,34:1-16.
- [42] KATZ S, TAL A. Hierarchical mesh decomposition using fuzzy clustering and cuts[J]. *ACM Transactions on Graphics (TOG)*, 2003,22(3):954-961.
- [43] SHAPIRA L, SHAMIR A, COHEN-OR D. Consistent mesh partitioning and skeletonisation using the shape diameter function[J]. *The Visual Computer*,2008,24:249-259.
- [44] PAPON J, ABRAMOV A, SCHOELER M, et al. Voxel cloud connectivity segmentation-supervoxels for point clouds [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2013:2027-2034.
- [45] YANG B, DONG Z, ZHAO G, et al. Hierarchical extraction of urban objects from mobile laser scanning data[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*,2015,99:45-57.
- [46] BESL P J, MCKAY N D. Method for registration of 3-D shapes [C]// *Sensor fusion IV: Control Paradigms and Data Structures*. Spie,1992,1611:586-606.
- [47] ZHU J, JIN C, JIANG Z, et al. Robust point cloud registration based on both hard and soft assignments[J]. *Optics & Laser Technology*,2019,110:202-208.
- [48] BENJEMAA R, SCHMITT F. Fast global registration of 3D sampled surfaces using a multi-z-buffer technique[J]. *Image and Vision Computing*,1999,17(2):113-123.
- [49] YANG J, LI H, JIA Y. Go-icp: Solving 3d registration efficiently and globally optimally[C]// *Proceedings of the IEEE International Conference on Computer Vision*. 2013:1457-1464.
- [50] BIBER P, STRABER W. The normal distributions transform: A new approach to laser scan matching [C] // *Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003)* (Cat. No. 03CH37453). IEEE, 2003, 3: 2743-2748.
- [51] MAGNUSSON M, LILIENTHAL A, DUCKETT T. Scan registration for autonomous mining vehicles using 3D-NDT[J]. *Journal of Field Robotics*,2007,24(10):803-827.
- [52] DAS A, WASLANDER S L. Scan registration with multi-scale k-means normal distributions transform [C] // *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE,2012:2705-2710.
- [53] DAS A, WASLANDER S L. Scan registration using segmented region growing NDT[J]. *The International Journal of Robotics Research*,2014,33(13):1645-1663.
- [54] AIGER D, MITRA N J, COHEN-ORD. 4-points congruent sets for robust pairwise surface registration[M]// *ACM SIGGRAPH 2008*. 2008:1-10.
- [55] MELLADO N, AIGER D, MITRA N J. Super 4 pcs fast global pointcloud registration via smart indexing [C] // *Computer Graphics Forum*. 2014,33(5):205-215.
- [56] HUANG X, MEI G, ZHANG J. Feature-metric registration: A fast semi-supervised approach for robust point cloud registration without correspondences [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020: 11366-11374.
- [57] XU Y, BOERNER R, YAO W, et al. Pairwise coarse registration of point clouds in urban scenes using voxel-based 4-planes congruent sets[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*,2019,151:106-123.
- [58] MASUDA T, SAKAUE K, YOKOYA N. Registration and integration of multiple range images for 3-D model construction [C]// *Proceedings of 13th International Conference on Pattern Recognition*. IEEE,1996,1:879-883.
- [59] KAMOUSHI P, LAZARD S, MAHESHWARI A, et al. Analysis of farthest point sampling for approximating geodesics in a graph[J]. *Computational Geometry*,2016,57:1-7.
- [60] RUSINKIEWICZ S, LEVOY M. Efficient variants of the ICP algorithm [C]// *Proceedings Third International Conference on 3-D Digital Imaging and Modeling*. IEEE,2001:145-152.
- [61] ZHONG Y. Intrinsic shape signatures: A shape descriptor for 3D object recognition [C] // *2009 IEEE 12th International Conference on Computer Vision Workshops, ICCV Workshops*. IEEE, 2009:689-696.
- [62] FELDMAR J, AYACHE N. Rigid, affine and locally affine registration of free-form surfaces[J]. *International Journal of Computer Vision*,1996,18(2):99-119.
- [63] CHUA C S, JARVIS R. Point signatures: A new representation for 3d object recognition[J]. *International Journal of Computer Vision*,1997,25:63-85.
- [64] HUANG Y, DA F P, TAO H J. An automatic point cloud registration algorithm based on feature extraction [J]. *China Laser*, 2015,42(3):250-256.
- [65] RUSU R B, MARTON Z C, BLODOW N, et al. Learning informative point classes for the acquisition of object model maps [C]// *2008 10th International Conference on Control, Automation, Robotics and Vision*. IEEE,2008:643-650.
- [66] RUSU R B, BLODOW N, MARTON Z C, et al. Aligning point

- cloud views using persistent feature histograms [C] // 2008 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2008; 3384-3391.
- [67] RUSU R B, BLODOW N, BEETZ M. Fast point feature histograms (FPFH) for 3D registration [C] // 2009 IEEE International Conference on Robotics and Automation. IEEE, 2009; 3212-3217.
- [68] CHEN C S, HUNG Y P, CHENG J B. RANSAC-based DARC-ES: A new approach to fast automatic registration of partially overlapping range images [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21(11): 1229-1234.
- [69] GELFAND N, MITRA N J, GUIBAS L J, et al. Robust global registration [C] // Symposium on Geometry Processing. 2005.
- [70] THEILER P W, WEGNER J D, SCHINDLER K. Keypoint-based 4-points congruent sets-automated marker-less registration of laser scans [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 96: 149-163.
- [71] STAMOS I, ALLEN P K. Geometry and texture recovery of scenes of large scale [J]. Computer Vision and Image Understanding, 2002, 88(2): 94-118.
- [72] YANG B, DONG Z, LIANG F, et al. Automatic registration of large-scale urban scene point clouds based on semantic feature points [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 113: 43-58.
- [73] HERNÁNDEZ J, MARCOTEGUI B. Point cloud segmentation towards urban ground modeling [C] // 2009 Joint Urban Remote Sensing Event. IEEE, 2009: 1-5.
- [74] TAO W, HUA X, CHEN Z, et al. Fast and automatic registration of terrestrial point clouds using 2D line features [J]. Remote Sensing, 2020, 12(8): 1283.
- [75] LI B J, LI Q Q, SHIW Z, et al. Feature extraction and modeling of urban building from vehicle-borne laser scanning data [J]. International Archives of Photogrammetry, Remote Sensing and Spatial Information Science, 2004, 35: 934-939.
- [76] YANG B, ZANG Y. Automated registration of dense terrestrial laser-scanning point clouds using curves [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 95: 109-121.
- [77] ALDOMA A, TOMBARI F, DI STEFANO L, et al. A global hypotheses verification method for 3d object recognition [C] // Computer Vision-ECCV 2012: 12th European Conference on Computer Vision. Florence, Italy, Part III 12. Springer Berlin Heidelberg, 2012: 511-524.
- [78] BRENNER C, DOLD C, RIPPERDA N. Coarse orientation of terrestrial laser scans in urban environments [J]. ISPRS Journal of Photogrammetry and Remote sensing, 2008, 63(1): 4-18.
- [79] CHEN S, NAN L, XIAR, et al. PLADE: A plane-based descriptor for point cloud registration with small overlap [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 58(4): 2530-2540.
- [80] ZHANG X, GAO R, SUN Q, et al. An automated rectification method for unmanned aerial vehicle lidar point cloud data based on laser intensity [J]. Remote Sensing, 2019, 11(7): 811.
- [81] LOWED G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60: 91-110.
- [82] WANG F, YE Y, HUX, et al. Point cloud registration by combining shape and intensity contexts [C] // 2016 9th IAPR Workshop on Pattern Recognition in Remote Sensing (PRRS). IEEE, 2016: 1-6.
- [83] JUNG S, SONG S, CHANG M, et al. Range image registration based on 2D synthetic images [J]. Computer-Aided Design, 2018, 94: 16-27.
- [84] HERBERT B. Surf: Speeded up robust features [J]. Computer vision and image understanding, 2008, 110(3): 346-359.
- [85] YANG Y, CHEN W, WANG M, et al. Color point cloud registration based on supervoxel correspondence [J]. IEEE Access, 2020, 8: 7362-7372.
- [86] LIU X, PENG X, YIN Y, et al. A coarse registration method of range image based on SIFT [C] // Electronic Imaging and Multimedia Technology V. SPIE, 2007, 6833: 249-256.
- [87] EO Y D, PYEON M W, KIMS W, et al. Coregistration of terrestrial lidar points by adaptive scale-invariant feature transformation with constrained geometry [J]. Automation in Construction, 2012, 25: 49-58.
- [88] QI C R, SU H, MO K, 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.
- [89] JIANG M, WU Y, ZHAOT, et al. Pointsift: A sift-like network module for 3d point cloud semantic segmentation [J]. arXiv: 1807.00652, 2018.
- [90] LI Y, BU R, SUN M, et al. Pointnet: Convolution on x-transformed points [J]. Advances in Neural Information Processing Systems, 2018, 31.
- [91] 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.
- [92] XU Y, FAN T, XUM, et al. Spidercnn: Deep learning on point sets with parameterized convolutional filters [C] // Proceedings of the European conference on computer vision (ECCV). 2018: 87-102.
- [93] LI Z, WANG F, WANG N. Lidar r-cnn: An efficient and universal 3d object detector [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 7546-7555.
- [94] ZHANG Y, HU Q, XU G, et al. Not all points are equal: Learning highly efficient point-based detectors for 3d lidar point clouds [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 18953-18962.
- [95] YUAN H, PANG J K, MO J W. Research on point cloud simplification algorithm based on voxelized grid subsampling [J]. Television Technology, 2015, 39(17): 43-47.
- [96] 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). IEEE, 2015: 922-928.
- [97] HEGDE V, ZADEH R. Fusionnet: 3d object classification using multiple data representations [J]. arXiv: 1607.05695, 2016.
- [98] BROCK A, LIM T, RITCHIE J M, et al. Generative and discriminative voxel modeling with convolutional neural networks

- [J]. arXiv:1608.04236,2016.
- [99] HE C,ZENG H,HUANG J,et al. Structure aware single-stage 3d object detection from point cloud[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:11873-11882.
- [100]YE M,XU S,CAO T. Hynet: Hybrid voxel network for lidar based 3d object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 1631-1640.
- [101]DENG J,SHI S,LI P,et al. Voxel r-cnn: Towards high performance voxel-based 3d object detection[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2021,35(2):1201-1209.
- [102]CHEN Y,LI Y,ZHANG X,et al. Focal sparse convolutional networks for 3d object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022:5428-5437.
- [103]SHI S,JIANG L,DENG J,et al. PV-RCNN++: Point-voxel feature set abstraction with local vector representation for 3D object detection[J]. International Journal of Computer Vision, 2023,131(2):531-551.
- [104]WU H,WEN C,LI W,et al. Transformation-equivariant 3d object detection for autonomous driving[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2023,37(3):2795-2802.
- [105]YANG H,WANG W,CHEN M,et al. Pvt-ssd: Single-stage 3d object detector with point-voxel transformer[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023:13476-13487.
- [106]KANG Z X,WANG S Z,CUI Y Y,et al. Transformer-based voxelized laser point cloud target detection algorithm [J]. Laser and Infrared,2023,53(2):202-207.
- [107]YANG Y K,WANG A H. Multi-scale laser point cloud learning network based on point-voxel combination [J]. Laser Magazine, 2023,44(4):134-139.
- [108]LAWIN F J,DANELLIAN M,TSOSTEBERG P,et al. Deep projective 3D semantic segmentation[C]// 17th International Conference Computer Analysis of Images and Patterns(CAIP 2017). Ystad, Sweden, Part I 17. Springer International Publishing,2017:95-107.
- [109]BOULCH A,GUERRY J,LE SAUX B,et al. SnapNet: 3D point cloud semantic labeling with 2D deep segmentation networks [J]. Computers & Graphics,2018,71:189-198.
- [110]WU B,WAN A,YUE X,et al. SqueezeSeg: Convolutional neural nets with recurrent crf for real-time road-object segmentation from 3d lidar point cloud[C]// 2018 IEEE International Conference on Robotics and Automation(ICRA). IEEE,2018:1887-1893.
- [111]MILIOTO A,VIZZO I,BEHLEY J,et al. Rangenet++: Fast and accurate lidar semantic segmentation[C]// 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE,2019:4213-4220.
- [112]BARRERA A,GUINDEL C,BELTRÁN J,et al. Birdnet+: End-to-end 3d object detection in lidar bird's eye view[C]// 2020 IEEE 23rd International Conference on Intelligent Transportation Systems(ITSC). IEEE,2020:1-6.
- [113]ZHOU Y,SUN P,ZHANG Y,et al. End-to-end multi-view fusion for 3d object detection in lidar point clouds[C]// Conference on Robot Learning. PMLR,2020:923-932.



GUO Zhangxiang, born in 1998, master candidate. His main research interests include three-dimensional visual detection of damage evaluation of marine floating platforms.



YAN Tianhong, born in 1982, associate professor, master's supervisor. Her main research interests include safety evaluation of offshore platform structure and equipment.